

**UNIVERSIDAD AUTONOMA DE NUEVO LEON**  
**FACULTAD DE INGENIERIA MECANICA Y ELECTRICA**  
**DIVISION DE ESTUDIOS DE POSTGRADO**



**NUEVO PRINCIPIO DE PROTECCION DIFERENCIAL  
DE TRANSFORMADORES APLICANDO REDES  
NEURONALES DE BASE RADIAL (RBF)**

**TESIS**

**EN OPCION AL GRADO DE MAESTRO EN CIENCIAS  
DE LA INGENIERIA ELECTRICA CON  
ESPECIALIDAD EN POTENCIA**

**P R E S E N T A**

**RAUL DE JESUS GOMEZ MORALES**


**SAN NICOLAS DE LOS GARZA, N. L.**

**FEBRERO 2004**





1020149864



# UANL


---

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS

UNIVERSIDAD AUTONOMA DE NUEVO LEON  
FACULTAD DE INGENIERIA MECANICA Y ELECTRICA  
DIVISION DE ESTUDIOS DE POSTGRADO



NUEVO PRINCIPIO DE PROTECCION DIFERENCIAL  
DE TRANSFORMADORES APLICANDO REDES  
NEURONALES DE BASE RADIAL (RBF)

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

TESIS

DIRECCIÓN GENERAL DE BIBLIOTECAS  
EN OPCION AL GRADO DE MAESTRO EN CIENCIAS  
DE LA INGENIERIA ELECTRICA CON  
ESPECIALIDAD EN POTENCIA

PRESENTA

RAUL DE JESUS GOMEZ MORALES

SAN NICOLAS DE LOS GARZA, N. L.

FEBRERO 2004



981466


TH  
25853

.M2

FIHE

2004

.G65



# UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS




FONDO  
TESIS

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**

**FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA**

**DIVISIÓN DE ESTUDIOS DE POSTGRADO**



**NUEVO PRINCIPIO DE PROTECCIÓN DIFERENCIAL DE  
TRANSFORMADORES APLICANDO REDES NEURONALES DE  
BASE RADIAL (RBF)**

**TESIS**

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**

**EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS**

**DIRECCIÓN GENERAL DE BIBLIOTECAS**

**DE LA INGENIERÍA ELÉCTRICA CON**

**ESPECIALIDAD EN POTENCIA**


**PRESENTA**

**RAÚL DE JESÚS GÓMEZ MORALES**

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**

**FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA**

**DIVISIÓN DE ESTUDIOS DE POSTGRADO**



**NUEVO PRINCIPIO DE PROTECCIÓN DIFERENCIAL DE  
TRANSFORMADORES APLICANDO REDES NEURONALES DE  
BASE RADIAL (RBF)**

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN**

**TESIS**

**EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS  
DE LA INGENIERÍA ELÉCTRICA CON**

**ESPECIALIDAD EN POTENCIA**

**PRESENTA**

**RAÚL DE JESÚS GÓMEZ MORALES**

Universidad Autónoma de Nuevo León  
Facultad de Ingeniería Mecánica y Eléctrica  
Subdirección de Estudios de Postgrado

Los miembros de comité de tesis recomendamos que la tesis **NUEVO PRINCIPIO DE PROTECCIÓN DIFERENCIAL DE TRANSFORMADORES APLICANDO REDES NEURONALES DE BASE RADIAL (RBF)**, realizada por el alumno Raúl de Jesús Gómez Morales, matrícula 1115156, sea aceptada para su defensa como opción al grado de Maestro en Ciencias de la Ingeniería Eléctrica con especialidad en Potencia.



El comité de Tesis

Asesor

Dr. Ernesto Vázquez Martínez

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS

Coasesor

Dr. Arturo Conde Enríquez

Coasesor

Dr. Efraín Alcorta García


Vo. Bó.

Dr. Guadalupe Alan Castillo Rodríguez  
División de Estudios de Postgrado



# DEDICATORIA

Quiero agradecer el esfuerzo dedicado para la realización de esta tesis a mis padres Guadalupe y Roberto, quienes han sido un ejemplo absoluto en mi vida y me han apoyado y brindado con su confianza incondicionalmente. Además quiero agradecer con mucho cariño y amor esta tesis a mi novia Karla y a mis hermanos: Roberto, Ricardo y Rogelio, quienes son para mí la razón de superación, esfuerzo y dedicación constante.



# UANL

---

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS

# AGRADECIMIENTOS

A toda mi familia por estar siempre pendiente de lo que ocurre en mi vida, y de quienes no escribo sus nombres porque no alcanzaría esta página, pero ellos saben a quienes me refiero.

Al Dr. Ernesto Vázquez Martínez por su paciencia, comprensión y asesoría en la realización de este trabajo.

Al Dr. Arturo Conde Enríquez y al Dr. Efraín Alcorta García, por sus valiosos comentarios que enriquecieron el contenido de esta tesis.

A todos los profesores del Programa Doctoral en Ingeniería Eléctrica, de la Universidad Autónoma de Nuevo León, de quienes me llevo algo muy valioso que son sus conocimientos.

A todos mis compañeros de la maestría por la amistad que me otorgaron, a mis primos y a todos mis amigos que donde quiera que estén siempre ocupan un lugar muy importante de mi vida.

A las siguientes personas que de alguna forma me han ayudado: Ing. Fernando Macias Quintero, Ing. Mario Lezama Fernández.

Al Consejo Nacional de Ciencia y Tecnología por el apoyo brindado durante la realización de mis estudios de Postgrado.

A mi alma mater el Instituto Tecnológico de Tuxtla Gutiérrez y a la Universidad Autónoma de Nuevo León, por permitirme ser parte de ellas.

# RESUMEN

Publicación No. \_\_\_\_\_

Raúl de Jesús Gómez Morales, M.C. en Ingeniería Eléctrica

Universidad Autónoma de Nuevo León, 2004

**Profesor Asesor: Dr. Ernesto Vázquez Martínez**

Los transformadores de potencia están expuestos a condiciones transitorias durante la operación en el SEP, tales como cortocircuitos, corrientes de magnetización (*inrush*), condiciones de sobreexcitación, sobrecargas, depresiones de voltaje, etc. Esto ha impulsado el desarrollo de nuevos principios para la protección diferencial del transformador que cumplan los requerimientos de confiabilidad y seguridad.

En la presente tesis se realiza una comparación de algunos algoritmos que se han propuesto para la protección diferencial de transformadores. Algunos algoritmos basan su información en el contenido armónico de la corriente diferencial del transformador y otros se basan en técnicas de reconocimiento de patrones, a fin de resaltar las diferencias entre las formas de onda de las corrientes de magnetización y de cortocircuito.

Se desarrolla un nuevo principio de protección diferencial de transformadores aplicando redes neuronales de base radial RBF (*Radial Basis Functions*), con el objetivo de discriminar entre una corriente de magnetización y una corriente de cortocircuito. Las principales ventajas de la RBF para el reconocimiento de patrones esta en su simplicidad funcional, generalidad y rapidez de aprendizaje.

Se usaron 2 modelos de transformadores monofásicos para formar los grupos de patrones de entrenamiento y prueba. Cada grupo de patrones se conforma a través de la simulación de 4 casos de operación del transformador (energización con carga, energización sin carga, cortocircuito en el lado secundario del transformador y depresión de voltaje en el lado primario del transformador). El proceso de formación de los patrones considera las etapas de pre-procesamiento de las señales que existe en un relevador digital, como son el filtrado anti-aliasing y la conversión A/D.

El nuevo principio de protección diferencial de transformadores propuesto en esta tesis basado en RBF, no requiere ningún ajuste debido a la normalización de las señales de corriente de operación, con la ventaja de que una vez entrenada la red pueda ser utilizada en cualquier otro transformador siempre y cuando las señales de corriente se normalicen con el mismo rango.

Se analiza el desempeño de la red utilizando la información de un caso real de la operación incorrecta del esquema de protección diferencial de un transformador debido a la corriente de magnetización, ocurrido en Colombia en el 2003. El resultado de esta prueba fue satisfactoria, ya que la red reconoció que se trataba de una condición de magnetización.

En la parte final de la tesis se presentan las conclusiones de esta investigación así como las recomendaciones para la realización de trabajos de investigación futuros en esta área.



# ÍNDICE

<b>Resumen</b> .....	vi
<b>Índice de figuras</b> .....	xi
<b>Índice de tablas</b> .....	xiv

## Capítulo 1.

### INTRODUCCIÓN

1.1 Motivación.....	1
1.2 Antecedentes.....	3
1.3 Objetivos.....	6
1.4 Limitaciones.....	7
1.5 Estructura de la tesis.....	7

## Capítulo 2.

### PROTECCIÓN DIFERENCIAL EN TRANSFORMADORES DE POTENCIA

2.1 Introducción.....	9
2.2 Tipos de fallas.....	10
2.3 Transitorio de energización de un transformador de potencia.....	11
2.4 Corrientes de magnetización en transformadores.....	14
2.5 Esquemas para la protección diferencial de transformadores.....	22
2.5.1 Métodos de retención de la protección diferencial basados en armónicas.....	26
2.5.2 Métodos de retención basados en el reconocimiento de la forma de onda.....	30
2.6 Algoritmos de estimación fasorial para la protección diferencial de transformadores.....	34
2.6.1 Comparación de algoritmos.....	37
2.7 Método propuesto.....	38

## ÍNDICE (continuación)

2.8 Conclusiones del capítulo.....	39
------------------------------------	----

### Capítulo 3.

#### REDES NEURONALES ARTIFICIALES DE BASE RADIAL (RBF)

3.1 Introducción.....	40
3.2 Definición de una red neuronal artificial.....	41
3.3 Redes neuronales de base radial.....	47
3.4 Proceso de entrenamiento de la red neuronal.....	52
3.5 Ventajas de las redes RBF para su clasificación.....	61
3.6 Planteamiento del algoritmo RBF.....	61
3.7 Conclusiones del capítulo.....	65

### Capítulo 4.

#### ESQUEMAS DE PROTECCIÓN DIFERENCIAL DE TRANSFORMADORES UTILIZANDO RBF

4.1 Introducción.....	66
4.2 Discriminación entre corrientes de magnetización y de cortocircuito utilizando RBF.....	67
4.3 Selección de la estructura de la red.....	68
4.4 Patrones de entrenamiento de la RBF.....	70
4.4.1 Etapas de pre-procesamiento.....	72
4.4.2 Normalización.....	75
4.5 Metodología para el entrenamiento de la red.....	76
4.6 Metodología para analizar el desempeño de la red.....	78
4.7 Conclusiones del capítulo.....	78

### Capítulo 5.

#### RESULTADOS

5.1 Introducción.....	80
-----------------------	----

## ÍNDICE (continuación)

5.2	Metodología de evaluación.....	81
5.3	Análisis del desempeño de la RBF.....	84
5.3.1	Primer grupo de patrones de entrenamiento y prueba.....	85
5.3.2	Segundo grupo de patrones de entrenamiento y prueba.....	89
5.4	Análisis de un caso real.....	93
5.5	Conclusiones del capítulo.....	96

### Capítulo 6.

#### CONCLUSIONES Y RECOMENDACIONES

6.1	Conclusiones.....	97
6.2	Aportaciones del trabajo.....	100
6.3	Recomendaciones para trabajos futuros.....	101

<b>REFERENCIAS</b> .....	102
--------------------------	-----

<b>APÉNDICE A</b>	Formulación del modelo matemático del transformador para la generación de los patrones de entrenamiento.....	107
-------------------	--	-----

<b>APÉNDICE B</b>	Parámetros eléctricos de los transformadores.....	115
-------------------	---	-----

# ÍNDICE DE FIGURAS

Figura	Página	
2.1	Avalancha de corriente de magnetización debido a la conexión inicial de operación del transformador de potencia.....	14
2.2	Corriente de magnetización requerida para establecer un flujo magnético en el transformador.....	16
2.3	Corriente de magnetización en donde se presenta corriente de avalancha..	17
2.4	Corriente de magnetización y sus componente armónicas.....	18
2.5	Corriente de avalancha con ángulos de energización de 0°, 45° y 90°.....	19
2.6	Condición no ideal de energización.....	21
2.7	Condición deseada de energización.....	21
2.8	Diagrama de conexión típico para el relevador diferencial.....	24
2.9	Condición de falla; (a) externa, (b) interna.....	24
2.10	Característica del relevador de porcentaje diferencial.....	25
2.11	Relevador diferencial para un transformador con restricción de armónicos.....	27
2.12	Relevador diferencial para transformadores con bloqueo armónicas.....	29
2.13	Diagrama lógico de un relevador con bloqueo y retención por segundo y quinto armónico.....	30
2.14	Bloqueo del relevador diferencial basado en reconocer el tiempo de duración de bajos intervalos de corriente.....	31
2.15	Lógica de bloqueo CD.....	34
3.1	Interacción entre una neurona presináptica y otra postsináptica.....	42
3.2	Modelo genérico de una neurona artificial.....	42
3.3	Modelo de neurona estándar.....	43



## ÍNDICE DE FIGURAS (continuación)

3.4	Clasificación de las RNA por el tipo de aprendizaje y la arquitectura.....	48
3.5	Funciones de activación de la capa oculta y la capa de salida de la RBF...	49
3.6	Arquitectura del RBF.....	50
3.7	Respuesta localizada de las neuronas ocultas en el RBF (nodos gaussianos). Los puntos representan patrones en el espacio de las entradas, que en su mayoría se agrupan en torno a dos centros.....	51
3.8	Repr̄sentación de cuatro nodos gaussianos que cubren el espacio de trabajo.....	52
3.9	Estructura de una red multicapa RBF con conexiones hacia adelante.....	55
3.10	Diagrama de flujo del proceso de entrenamiento de la RBF.....	56
3.11	Representación de 4 patrones de entrenamiento linealmente no separables.....	57
3.12	Representación de los patrones linealmente separables.....	58
3.13	Representación de los patrones de salida deseados.....	60
3.14	Descripción del proceso de reconocimiento/clasificación.....	62
<hr/>		
4.1	Representación de la corriente de cortocircuito en un transformador de potencia.....	68
4.2	Representación de una corriente de inrush en un transformador de potencia.....	68
4.3	Sistema de potencia de prueba.....	71
4.4	Componentes básicos de un relevador digital.....	73
4.5	Comparación del espectro de frecuencia de la corriente primaria de un transformador durante una falla.....	74
4.6	Etapas del procesamiento de la señal antes del entrenamiento de la RBF...	74
4.7	Sección de corriente diferencial utilizada para el entrenamiento de la RBF.....	75

## ÍNDICE DE FIGURAS (continuación)


4.8	Estructura de la RNA de base radial para el entrenamiento y clasificación.....	77
5.1	Diagrama de flujo del algoritmo de protección diferencial utilizando RBF.....	82
5.2	Primer grupo de patrones de entrenamiento correspondiente a los casos A,B,C y D.....	86
5.3	Respuesta de la RBF con el primer grupo de patrones de entrenamiento....	87
5.4	Primer grupo de patrones de prueba correspondiente a los casos A,B,C y D.....	88
5.5	Respuesta de la RBF del primer grupo de patrones de prueba.....	89
5.6	Segundo grupo de patrones de entrenamiento correspondiente a los casos A,B,C y D.....	90
5.7	Respuesta de la RNA de base radial para el segundo grupo de patrones de entrenamiento.....	91
5.8	Segundo grupo de patrones de prueba correspondientes a los casos A,B,C y D.....	92
5.9	Respuesta de la RBF del segundo grupo de patrones de prueba.....	93
5.10	Corriente primaria y secundaria de un evento real de la operación incorrecta de una protección diferencial.....	94
5.11	Corriente de operación normalizada (a) y salida de la RBF para un caso real de operación incorrecta de transformador por corriente de inrush (b)..	95
A.1	Representación de un transformador monofásico.....	108
A.2	Representación del modelo del transformador monofásico saturable.....	111
B.1	Representación de la curva de magnetización del transformador 1.....	117
B.2	Modelo del transformador saturable monofásico del ATP.....	118
B.3	Representación de la curva de magnetización del transformador 2.....	119

# ÍNDICE DE TABLAS

Tabla	Página
2.1 Magnitudes de la corriente de inrush para 3 diferentes ángulos de energización.....	20
2.2 Comparación de algoritmos de acuerdo a los requerimientos computacionales.....	38
3.1 Funciones de activación.....	45
3.2 Resultados del mapeo no lineal de la capa oculta.....	58
3.3 Métodos de reconocimiento de patrones.....	63
5.1 Descripción de los casos de operación simulados.....	84
5.2 Descripción de los patrones de prueba.....	84
B.1 Parámetros del transformador 1 desarrollado en MATLAB.....	116
<hr/>	
B.2 Datos de la curva de saturación del transformador 1.....	117
B.3 Parámetros del transformador monofásico del ATP.....	118
B.4 Datos de la curva de saturación del transformador 2.....	119

# CAPÍTULO 1

## INTRODUCCIÓN



### 1.1 MOTIVACIÓN

El estudio de fenómenos de energización en los transformadores en los sistemas eléctricos de potencia es de suma importancia debido a las corrientes excesivas que se observan durante ese período transitorio, originadas por las características no lineales asociadas al núcleo ferromagnético con que están construidas. Esta corriente se reconoce como la avalancha de la corriente de magnetización (*inrush*).

La corriente de energización en un transformador es de una magnitud considerable mayor a la corriente nominal, llegando a ser de 10 a 25 veces mayor. La corriente de avalancha puede ocasionar efectos indeseables en los sistemas eléctricos, tales como; operaciones erróneas de los dispositivos de protección debido a las magnitudes excesivas de las corrientes.



Una característica de las corrientes de avalancha es que también presentan un amplio contenido armónico, en donde destaca la componente de corriente directa y la segunda armónica.

El principio de protección diferencial [1] es comúnmente utilizado para la protección de transformadores de potencia, se basa en la comparación de las corrientes del lado primario y secundario del transformador; estas corrientes tienen una relación bien definida en condiciones normales de operación.

Cuando estas corrientes exhiben un comportamiento distinto al de estado estable se asume que ha ocurrido un cortocircuito en el transformador, y éste debe ser puesto fuera de servicio para revisión y mantenimiento. Este procedimiento funciona correctamente en la mayoría de los casos, sin embargo, puede ocasionar operaciones incorrectas (y desconexión innecesaria del transformador) en presencia de la corriente transitoria de magnetización, la cual solo está presente cuando el transformador está siendo energizado. Esta corriente circula solamente por el devanado primario del transformador (el devanado que es energizado) y por lo tanto representa una condición de falla interna para la protección diferencial. El método más común para evitar estas operaciones incorrectas es el uso del contenido de armónicas para discriminar entre corrientes de magnetización y de cortocircuito, lo que se denomina restricción de armónicas [2].

En general, la corriente de magnetización presenta diferencias con la corriente de cortocircuito en la forma de onda debido a presencia de armónicas, especialmente de la segunda. Este comportamiento ha sido utilizado para el diseño de relevadores de protección diferencial con restricción de armónicas, de tal forma que si la magnitud de la segunda armónica en la corriente diferencial excede un porcentaje pre-definido de la componente fundamental, se asume que se trata de la energización del transformador y la protección es bloqueada para evitar una operación incorrecta.

En esta tesis se propone la utilización de redes de neuronales artificiales para evaluar el desempeño de la RNA en el reconocimiento de patrones [18] para identificar o discriminar el comportamiento de la corriente en un transformador en diferentes condiciones de operación en transformadores monofásicos. Para ello se desarrollará el modelo matemático de un transformador monofásico que incluya el efecto de las corrientes de magnetización. También se analizará y implementará las RNA de base radial para la discriminación de las corrientes de cortocircuito y las corrientes de magnetización en un transformador monofásico.

## 1.2 ANTECEDENTES

Actualmente existen distintos tipos de algoritmos para la protección diferencial de transformadores con restricción de armónicas [3]. En general la decisión de operación o bloqueo se determina en base a las magnitudes relativas de la componente fundamental y de segunda armónica presentes en la corriente diferencial. Sykes y Morrison [4] sugirieron el uso de un grupo de filtros recursivos pasa banda para calcular la fundamental y la segunda armónica. Malik, Dash y Hope [5] propusieron la aplicación de una función de correlación basada en técnicas de Fourier. Schweitzer [6] propuso el uso de filtros de respuesta impulso finita (FIR) para calcular la magnitud de la fundamental y la segunda armónica. Así mismo, Degens [7] y Arman [8] propusieron el uso de algoritmos basados en el ajuste de curvas por mínimos cuadrados para determinar las magnitudes de ambas componentes en la corriente diferencial. Rahman y Dash [9] propusieron el uso de algoritmos basados en el ajuste de curvas por mínimos cuadrados para determinar las magnitudes de ambas componentes en la corriente diferencial. Rahman y Dash [9] presentaron un algoritmo basado en una técnica de transformada rectangular para reducir el número de multiplicaciones necesarias para hacer el cálculo. De igual forma, Fakruddin [10] ha investigado la aplicación de funciones Haar para protección diferencial de transformadores. Por último, las funciones Walsh fueron propuestas por Rahman [11,12] con el mismo fin.

Estos algoritmos basan su operación en el contenido armónico de la corriente diferencial del transformador como un indicador para determinar si se trata de una energización o de una falla interna. Sin embargo, estudios recientes han demostrado que las corrientes de cortocircuito pueden contener una magnitud considerable de componentes armónicas, en especial de segunda y quinta [13]. Además, se han reportado que los materiales magnéticos amorfos, que se caracterizan por tener bajos niveles de pérdidas por corrientes parásitas, utilizados en los actuales transformadores reducen el contenido de armónicas en las corrientes de magnetización [14]. Considerando estos factores, se han comenzado a desarrollar trabajos de investigación enfocados a desarrollar nuevos algoritmos de protección de transformadores [13,14,15,16].

Algunos de los nuevos algoritmos se basan en técnicas de reconocimiento de patrones a fin de resaltar las diferencias que existen entre las formas de onda de las corrientes de magnetización y de cortocircuito. La aplicación de redes de neuronas artificiales y lógica difusa forman parte de este grupo de algoritmos [17].

En trabajos recientes para la aplicación de redes neuronales artificiales Pérez, Flechsing, Meador y Obradovic [20] propusieron un método para discriminar entre una corriente de *inrush* y una falla en el transformador de potencia, utilizando redes neuronales artificiales hacia adelante con funciones de activación tipo sigmoideal, usando como método de entrenamiento el algoritmo de *back propagation*.

La principal ventaja de la aplicación de las redes de neuronas sobre los métodos convencionales es su procesamiento de información en paralelo en forma no algorítmica [18]. En este caso, el problema de discriminación de corrientes de magnetización y cortocircuito se plantea como un problema de reconocimiento de forma de onda. De esta forma, la red es entrenada como un sistema de decisión binario (energización/cortocircuito). No obstante, los resultados obtenidos hasta el momento indican que la respuesta de la red depende en cierta medida de los parámetros del

transformador, lo que significa re-entrenar la red para su aplicación en otro transformador [19,20].

La aplicación de técnicas de agregación multi-criterio basadas en lógica difusa también han sido estudiadas como base de algoritmos de protección de transformadores. En este caso se define un grupo de criterios para el reconocimiento del tipo de corriente, los cuales son agrupados en dos conjuntos difusos correspondientes a las condiciones de energización y de cortocircuito. Así la decisión de disparo y/o bloqueo se reduce a una decisión binaria, en dependencia del conjunto seleccionado a partir de la información de entrada fuzificada [21]. Este método presenta dos ventajas, la primera es que los criterios de agrupamiento se basan en información estadística, y segundo, debido a que su estructura de operación es basada en reglas, se considera que esta técnica no es lo suficientemente robusta para considerar todos los aspectos del fenómeno transitorio de un transformador.

En los últimos años se han desarrollado investigaciones sobre la aplicación de wavelets en protección de transformadores [22]. La motivación principal es el hecho de que la transformada de wavelet, además de proporcionar la composición en frecuencia de la forma de onda de una señal como la transformada de Fourier, tiene la ventaja de que puede ser aplicada a señales no periódicas de banda ancha, típicas de los transitorios electromagnéticos. Al respecto, Mao y Aggarwal [23] han propuesto aplicar la transformada de wavelet a la corriente diferencial del transformador y realzar las diferencias en el dominio de la frecuencia de la forma de onda de las corrientes en el dominio del tiempo de acuerdo a la magnitud de ciertas componentes de frecuencia. Así mismo, Gómez y Nicoletti [24] utilizan la distribución de energía en una determinada banda de frecuencias como medio discriminación.

Más recientemente, Bo, Séller y Lomas [25] han propuesto la identificación de componentes de alta frecuencia en la corriente para resolver el problema. En este caso, el nivel de energía almacenado en las componentes de frecuencias se utiliza para formar

dos señales, una de operación y una de retención, tal y como se hace en un relevador diferencial con retención de armónicas. La comparación en la magnitud de ambas señales determinada si la condición transitoria corresponde a una energización o a un cortocircuito.

No obstante, los métodos descritos [3,16] no han demostrado aún ser lo suficientemente confiables para su implementación en relevadores de protección, por lo que es necesario continuar en las investigaciones en este campo.

### 1.3 OBJETIVOS

Los objetivos de este trabajo de tesis se puede resumir en los siguientes cuatro aspectos:

- Desarrollo de un modelo matemático de un transformador monofásico que incluya el efecto de las corrientes de magnetización.
- Realizar un estudio comparativo de los métodos utilizados para insensibilizar la protección diferencial a la corriente transitoria de magnetización presente durante la energización de un transformador.
- Propuesta y desarrollo de un nuevo algoritmo de protección diferencial de transformadores basado en técnicas de reconocimiento de patrones, que discrimine las diferencias entre las formas de onda de las corrientes de magnetización y de cortocircuito.
- Diseñar y entrenar una RNA de base radial para que realice la función de discriminar entre una condición de magnetización y una falla en el transformador de potencia utilizando la información de corrientes medida por un relevador diferencial.

## 1.4 LIMITACIONES

En la presente tesis se presenta el desarrollo de un nuevo principio de identificación de fallas en transformadores de potencia basado en redes neuronales artificiales de base radial, el cual consiste en discriminar entre una condición de magnetización debido a la no linealidad del núcleo del transformador y una falla interna en un sistema de potencia.

De acuerdo a lo anterior, este trabajo presenta las siguientes limitaciones:

- Los procedimientos que se realizaron para el entrenamiento y prueba de RNA de base radial se basan en simulaciones digitales en los cuales no se considera la saturación de los transformadores de corriente.
- En el modelo del transformador monofásico para el estudio de simulaciones y generación de patrones de la RNA, no se considera la condición de sobreexcitación y ferresonancia.

## 1.5 ESTRUCTURA DE LA TESIS

Este trabajo de investigación consta de 6 capítulos, en el primer capítulo se define el problema de la operación incorrecta de los esquemas de la protección diferencial de transformadores durante condiciones de energización debido a la corriente de magnetización. Se hace una breve descripción de los distintos tipos de algoritmos para la operación de bloqueo o no bloqueo de la protección diferencial de transformadores y se indican los objetivos y limitaciones de este trabajo de tesis.

El capítulo 2 contiene un análisis de la corriente de magnetización y de la protección diferencial, se describen los métodos y algoritmos utilizados para insensibilizar la protección diferencial a la corriente transitoria de magnetización durante la energización

de un transformador de potencia así como sus deficiencias, y se propone el método propuesto de este trabajo.

En el capítulo 3 se presenta brevemente el concepto de inteligencia artificial con un enfoque específicamente en redes neuronales de base radial, así como los aspectos generales relacionados con la regla de aprendizaje, las estructuras, la reducción de la complejidad de las redes y el análisis de la información de entrada a la red.


En el capítulo 4 se presenta la selección de la estructura de la red utilizada, se definen los patrones de entrenamiento y las etapas del procesamiento de la señal antes del reconocimiento y clasificación de la RBF; por último se plantea la metodología para el entrenamiento y análisis del desempeño de la red.

En el capítulo 5 se presenta la metodología de evaluación. Se describen los aspectos básicos de reconocimiento de patrones con RNA de base radial para el proceso de entrenamiento utilizado. Se analiza el desempeño de la red considerando los dos grupos de patrones de entrenamiento para su clasificación de bloqueo o no bloqueo de la protección. Se muestran los resultados de las pruebas de validación realizadas al esquema de la protección diferencial de transformadores durante condiciones de energización basado en redes neuronales propuesto en esta tesis. Se analiza el desempeño de la red utilizando la información de un caso real ocurrido en Colombia en el 2003.

Finalmente, en el capítulo 6 se presentan las conclusiones, se establecen las aportaciones del trabajo, así como un conjunto de recomendaciones respecto a extensiones futuras de este trabajo y las alternativas de desarrollo del mismo.

## CAPÍTULO 2

# PROTECCIÓN DIFERENCIAL EN TRANSFORMADORES DE POTENCIA



# UANL

## 2.1 INTRODUCCIÓN

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN<sup>®</sup>  
DIRECCIÓN GENERAL DE BIBLIOTECAS

El propósito de este capítulo es analizar el estado del arte de los algoritmos de la protección diferencial de transformadores de potencia. Los relevadores diferenciales para transformadores deben operar cuando ocurre una falla y se debe impedir la operación incorrecta en caso de corriente de magnetización (*inrush*). La operación incorrecta de los relevadores es debido a que al energizar el transformador aparece esta corriente de magnetización que entra por primario del transformador y no sale por secundario en un instante de tiempo, por lo que estos flujos de corriente pueden engañar a la protección diferencial del transformador por una condición de falla interna.



En este capítulo se analiza el concepto de la protección diferencial de transformadores de potencia, se describen los métodos y algoritmos utilizados para este tipo de protección, y se propone la aplicación de redes neuronales de base radial para identificar y discriminar entre una falla o una condición de *inrush* en el transformador de potencia.

## 2.2 TIPOS DE FALLAS

El transformador es un elemento con un índice de fallas menor en comparación con otros elementos del sistema. Cuando el transformador falla, generalmente es en forma severa y muchas veces se producen incendios, de ahí la importancia de contar con esquemas rápidos y seguros. Los tipos de fallas que pueden ocurrir en un transformador se pueden dividir en 2 clases: fallas externas y fallas internas.

### Fallas externas

Las fallas externas ocurren fuera de la zona protegida de la protección diferencial del transformador de potencia y acortan la vida útil del transformador debido al posible daño térmico y mecánico en los devanados. Entre los tipos de fallas externas están:

1. Sobrecargas causada por la demanda eléctrica en el sistema.
2. Sobrevoltaje causada por descargas atmosféricas.
3. Baja frecuencia en el sistema.
4. Cortocircuitos fuera del área protegida en el transformador.

### Fallas internas

Las fallas internas ocurren dentro de la zona de protección del transformador y en general todas las fallas internas son muy serias, sobre todo porque siempre está presente el peligro de incendio. Las fallas internas pueden ser subdivididas en dos grupos: fallas incipientes y fallas activas. Así mismo las fallas incipientes son las siguientes:

- Sobrecalentamiento interno en el transformador.

- Sobreflujo en el núcleo.
- Sobrepresión en el tanque del transformador.
- Arqueo entre un devanado y el núcleo, debido a sobretensiones causadas por descargas atmosféricas, fallas externas y maniobras de switcheo en el sistema.
- Arqueo entre devanados o entre espiras contiguas de capas diferentes de un mismo devanado, debida a la misma causa anterior o por movimiento de los devanados bajo la acción de fuerzas electromagnéticas durante cortocircuitos externos.
- Fallas en los contactos de cambiadores de derivaciones produciéndose calentamiento o cortocircuito de vueltas entre derivaciones.

Las fallas activas requieren de una acción rápida para la desconexión del transformador para no causar algún daño severo en el transformador. Este tipo de fallas se clasifican como:

- Cortocircuito en el devanado primario del transformador.
- Cortocircuito en el devanado secundario del transformador.
- Cortocircuito entre fases.
- Cortocircuito entre arrollamientos de los devanados.
- Fallas en el núcleo.
- Fallas en el tanque del transformador.

### **2.3 TRANSITORIO DE ENERGIZACIÓN DE UN TRANSFORMADOR DE POTENCIA**

Los transformadores se definen como máquinas estáticas que tienen la misión de transmitir potencia, mediante un campo electromagnético alterno, la energía eléctrica de un sistema con determinado voltaje a otro sistema con voltaje deseado.

Un análisis de gran importancia para la operación del transformador es su conexión inicial en el sistema; en la Fig. 2.1 se representa el análisis de un transformador que se conecta a la fuente de alimentación en un instante en que el voltaje es cero. Por consiguiente el flujo magnético, que está atrasado prácticamente  $90^\circ$  al voltaje (onda senoidal con línea discontinua), debía estar en ese instante en su valor máximo negativo  $\phi_m$  (o cerca de él), pero realmente es cero, ya que el transformador estaba desconectado. Ello da lugar a un desplazamiento hacia arriba de la onda de flujo magnético, que llega a alcanzar un valor de  $2\phi_m$  dentro del primer ciclo; esta onda es una cosenoidal desplazada, y su componente periódica es de naturaleza exponencial con una constante de tiempo  $L/R$ , donde  $L$  y  $R$  son respectivamente, la inductancia y resistencia equivalentes del transformador y de la fuente. Este valor máximo que alcanza el flujo magnético es muy superior al de saturación del transformador, por lo que origina una saturación muy severa y valores muy elevados de la corriente de magnetización  $i_m$  [47].

En el análisis se ha supuesto que el flujo inicial en el transformador era nulo, pero realmente pudo haber tenido cierto valor  $\phi_r$  residual, resultante de su última desconexión. Este flujo puede ser positivo o negativo, y se suma algebraicamente al flujo, dando un máximo  $2\phi_m \pm \phi_r$ , que puede ser mayor o menor que si no hay flujo remanente. Por tanto, la presencia de  $\phi_r$  puede incrementar o reducir aleatoriamente el valor de la corriente de magnetización. Por lo tanto, si la conexión del transformador se hace en un instante diferente al mostrado (caso más crítico), la componente aperiódica del flujo es menor, y la corriente de magnetización tiene un valor más pequeño. Puede incluso darse el caso de que la conexión se haga en el momento en el cruce de la onda de flujo, lo que elimina por completo el proceso transitorio, y la corriente de magnetización tiene su valor nominal del orden del 2 al 3% de la nominal del transformador. En un transformador trifásico, aún suponiendo un cierre totalmente simultáneo de las tres fases del interruptor, cada fase tiene su propio proceso, y son de esperar corrientes de avalancha en al menos dos fases, y generalmente en las tres.

Las reducciones transitorias de voltaje también es un problema para la operación del transformador. El caso más crítico es el de una falla externa trifásica limpia cercana al transformador, el voltaje se reduce prácticamente a cero; cuando se elimina la falla, el voltaje recupera su valor nominal y tiene lugar a una avalancha de corriente de magnetización. Sin embargo, como el transformador no está totalmente desconectado de la red, los valores de corriente son menores que en el caso de su conexión inicial.

Otro problema en la operación del transformador es cuando se hace la conexión inicial de un transformador para ponerlo en paralelo con otro que ya está en servicio, se originan avalanchas de corriente de magnetización en ambos transformadores. El problema consiste en que el transformador que se conecta experimenta la avalancha de corriente por condición inicial, y la componente aperiódica de esta corriente da lugar a una caída de voltaje que afecta al otro transformador, y origina en él una avalancha de corriente.

Por otro lado, cuando el transformador esta en operación y ocurre una falla interna en él, es necesaria la desconexión del transformador para evitar daños severos, afectar la estabilidad del sistema de potencia y la calidad del suministro de energía. Los esquemas de protección en transformadores normalmente usados para la detección de fallas son: i) protección diferencial contra fallas internas, ii) protección de sobrecorriente de fase como respaldo para fallas externas y sobrecargas, iii) y protección para fallas internas incipientes tipo Buchholz (acumulación de gases).




Fig. 2.1. Avalancha de corriente de magnetización debido a la conexión inicial de operación del transformador de potencia.

## 2.4 CORRIENTE DE MAGNETIZACIÓN EN TRANSFORMADORES

Al energizar un transformador, el cual es un elemento que contiene un núcleo ferromagnético con característica no lineal, puede presentarse una corriente denominada “corriente de avalancha” como se describió en la sección anterior. Los factores de los que depende la magnitud y duración de esta corriente son las siguientes:

1. Instante de inicio de energización del transformador.
2. Capacidad del transformador.
3. Capacidad del sistema.
4. Relaciones L/R del transformador y del sistema.
5. Tipo de hierro del transformador.
6. Nivel de flujo magnético residual del transformador.
7. Condiciones en que se realiza el proceso, que puede identificarse por tres casos diferentes, la conexión inicial del transformador, su recuperación posterior a una

reducción transitoria de voltaje y la conexión inicial de un transformador en paralelo con otro que ya esta en servicio.

La corriente de energización (o corriente de *inrush*) en un transformador es de una magnitud considerablemente mayor a la corriente nominal. Las corrientes de avalancha pueden ocasionar efectos indeseables en los sistemas eléctricos de potencia, tales como; deterioro en la calidad de la energía del sistema, operaciones erróneas de los dispositivos de protección. Una característica de las corrientes de avalancha es que también presentan un amplio contenido de armónicos, en donde destacan la componente de corriente directa y la segunda armónica.

La corriente de avalancha se presenta cuando se energiza el núcleo saturable de un transformador y se debe a la presencia de una gran componente de corriente directa, la cual se manifiesta en el espectro armónico de esta corriente.

Si se observa la corriente que circula en el devanado primario de un transformador en vacío y la que circula en una condición de estado estable, se tendrán dos componentes de corriente, una corriente es debida a la histéresis y otra que se conoce como corriente de magnetización.

La corriente de magnetización es necesaria para generar un flujo en el núcleo del transformador, y se puede determinar a partir del flujo en el núcleo y la característica de saturación como se muestra en forma esquemática en la Fig. 2.2.

Se considera que el transformador se alimenta de una fuente tipo coseno y se puede obtener las siguientes relaciones:

$$v(t) = V_m \cos(\omega t) \quad (2.1)$$

$$\phi = \frac{1}{N} \int_0^t V_m \cos(\omega\tau) d\tau = \frac{V_m}{\omega N} \quad (2.2)$$

$$\phi_{\max} = \frac{V_m}{\omega N} \quad (2.3)$$

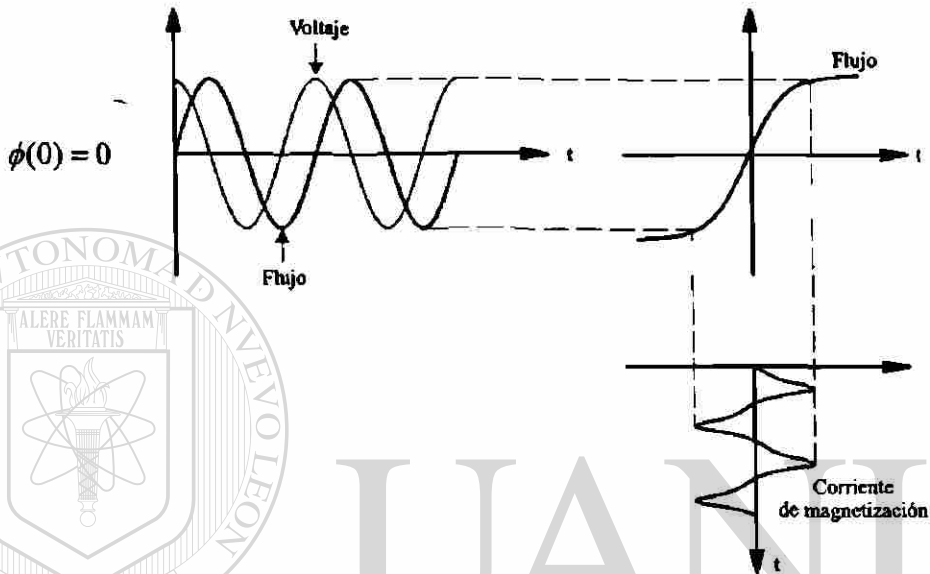


Fig. 2.2. Corriente de magnetización requerida para establecer un flujo magnético en el transformador.

Como la fuente se considera senoidal se puede obtener una expresión para el flujo magnético en el núcleo, dado por (2.4) y por lo tanto se puede determinar el flujo máximo durante el primer ciclo, lo cual resulta en (2.5).

$$\phi = \frac{1}{N} \int V_m \sin(\omega t) dt + k = -\frac{V_m}{\omega N} \cos(\omega t) + k \quad k = \frac{V_m}{\omega N} \quad (2.4)$$

$$\phi(\pi) = \frac{2V_m}{\omega N} \quad (2.5)$$

En la Fig. 2.3 se observa que si la magnitud del flujo en el núcleo es de dos veces su valor nominal, esta condición requiere de una corriente de magnetización con un valor considerablemente mayor.




Fig. 2.3. Corriente de magnetización, en donde se presenta corriente de avalancha.

La magnitud de la corriente de avalancha al energizar el elemento no lineal, depende del ángulo de fase de la fuente que alimenta al transformador, es decir, depende del instante de cierre del interruptor con respecto a la onda de voltaje. El caso más severo se presenta cuando el interruptor cierra en el instante en que la onda de tensión tiene su cruce por cero y para otros instantes, la magnitud de la corriente de avalancha es menor, hasta tener un valor mínimo, lo cual ocurre cuando el ángulo de energización es de 90 grados.

Otro factor que influye en la corriente de avalancha, es la magnitud del voltaje de la fuente de energización del circuito, y se observa que al incrementarse el flujo magnético requerido en el núcleo, la corriente presenta un pico ya que se opera en la zona de saturación.

En la Fig. 2.4 se muestran señales de corriente obtenidas por el modelo matemático del transformador desarrollado en MATLAB (ver apéndice A), donde se energiza el transformador a un ángulo de cero grados con respecto a la onda del voltaje, la



componente de corriente directa y la segunda armónica tienen valores considerables, llegando a valores de más de un 50% del valor de la componente fundamental, lo que explica la distorsión en la forma de onda de corriente.

Las componentes armónicas son normalizadas en base al valor de la amplitud máxima de la componente fundamental de la corriente. El valor de estado estable se alcanza después de transcurrir cierto tiempo una vez que el transitorio de energización termina.

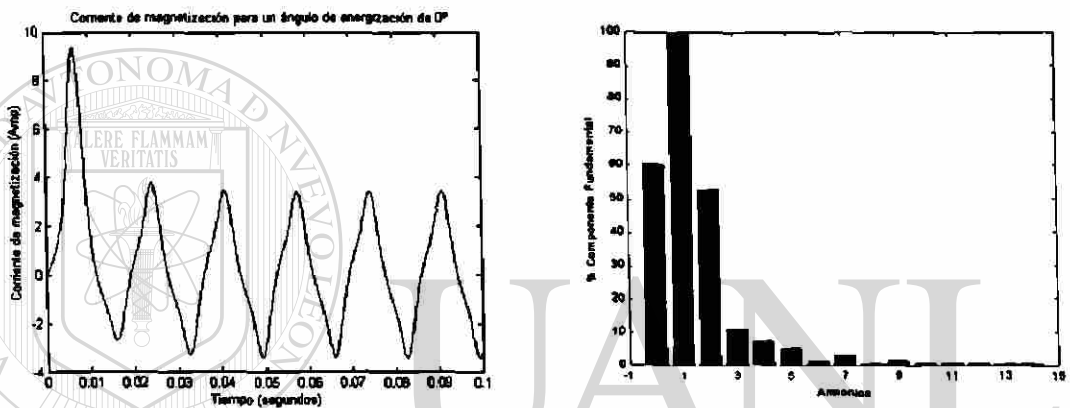


Fig. 2.4. Corriente de magnetización y sus componentes armónicas.

La magnitud de la corriente de avalancha al energizar el transformador depende en gran parte del ángulo de energización. En la Fig. 2.5 se presentan tres casos con diferente ángulo de energización.

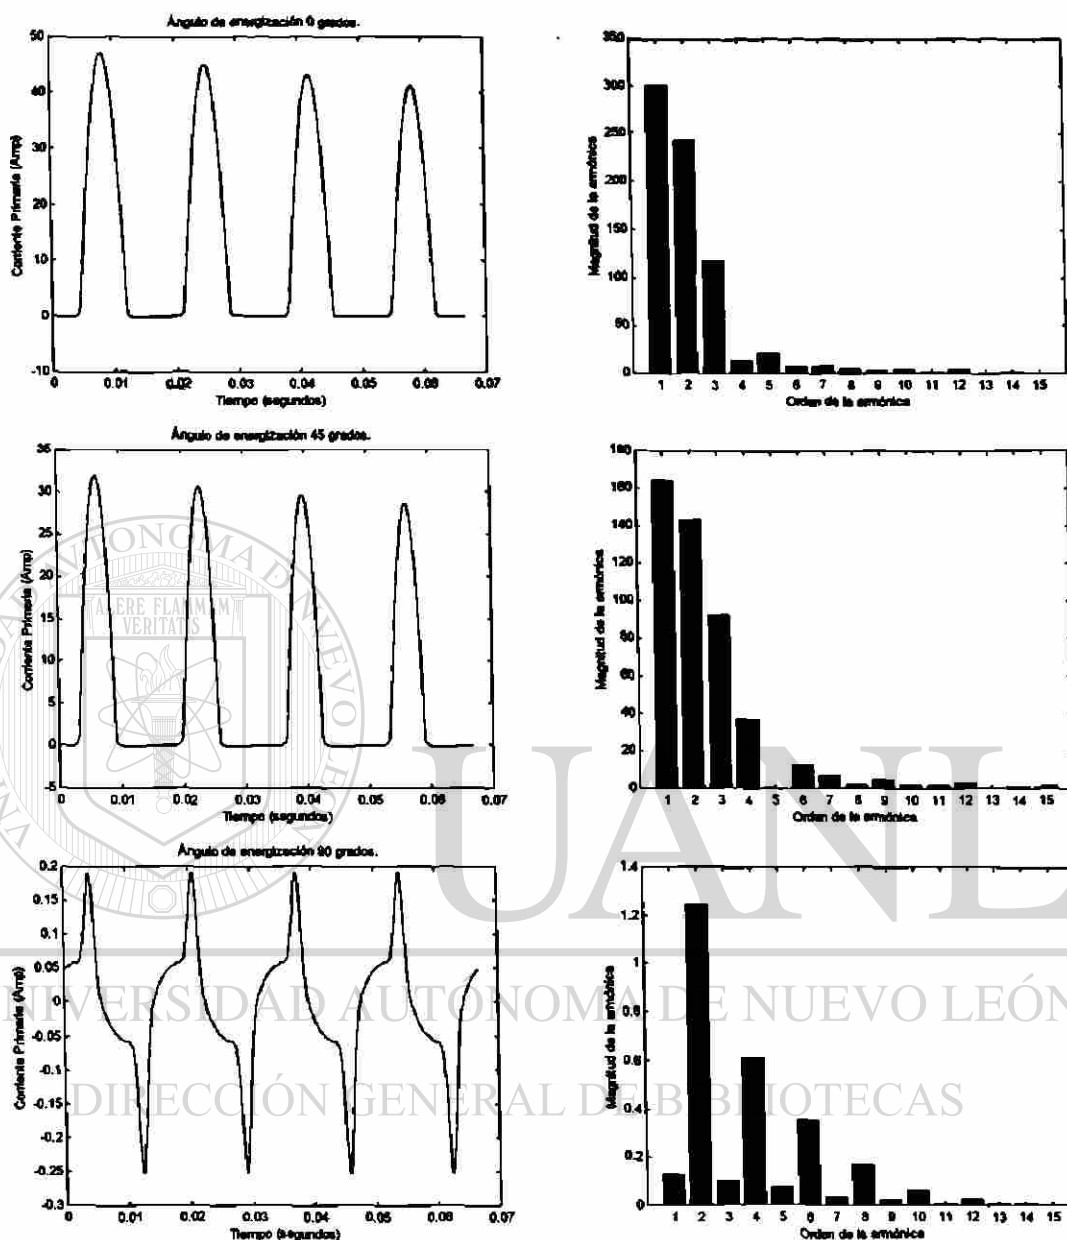


Fig. 2.5 Corriente de avalancha con ángulos de energización de  $0^\circ$ ,  $45^\circ$  y  $90^\circ$ .

Se observa que la magnitud de la corriente va disminuyendo al incrementarse el ángulo de cierre del interruptor. En la Tabla 2.1 se muestra el comportamiento de la magnitud de la corriente de avalancha, al variar el ángulo de energización.

Tabla 2.1. Magnitudes de la corriente de *inrush* para 3 diferentes ángulos de energización.

Ángulo (Grados)	0°	45°	90°
Magnitud (Amp.)	47.3	31.8	0.19

Es interesante notar que en la Fig. 2.5 como la componente de corriente directa en el espectro armónico de la señal de corriente va disminuyendo conforme se incrementa el ángulo de energización, hasta llegar a un ángulo igual a 90°. La corriente que se obtiene es la corriente de estado estable, la cual no tiene componente de corriente directa y muy poca aportación de otras componentes armónicas por lo que presenta una ligera distorsión con respecto a la onda senoidal de la fuente de alimentación.

Otro aspecto importante es observar que al incrementar el ángulo de energización, componentes como la 2<sup>a</sup>, 3<sup>a</sup>, 4<sup>a</sup> y 5<sup>a</sup> disminuyen con respecto a la componente fundamental, además su ángulo de fase varía por lo que la corriente va tomando valores negativos adquiriendo una forma oscilante entre valores positivos y negativos como una forma de onda senoidal, hasta el ángulo de energización de 90° para la cual la forma de onda de la corriente presenta poca participación de dichas componentes.

La corriente de avalancha depende del momento de cierre del interruptor para energizar las fases de un transformador [26]. Por consiguiente si el transformador monofásico se energiza en el momento en que la onda de voltaje cruza por cero y con pendiente positiva, a su vez el flujo magnético se incrementa en el tiempo hasta llegar a un valor de dos veces el flujo nominal o un valor mayor si se tiene un flujo residual. Para obtener estos valores de flujo magnético se requiere de una gran corriente debido a que en esos puntos el núcleo se encuentra saturado, ver Fig. 2.6.




Fig. 2.6 Condición no ideal de energización.

Por consiguiente es importante notar que si se energiza el núcleo magnético en el instante preciso, es decir, aquel en el cual el flujo dinámico es igual al flujo esperado en estado estable, la forma de onda del flujo magnético en el núcleo toma la forma final, como se muestra en la Fig. 2.7. Por tanto esto significa que no existe flujo transitorio y por consecuencia tampoco se observa un fenómeno transitorio en las otras variables del transformador.

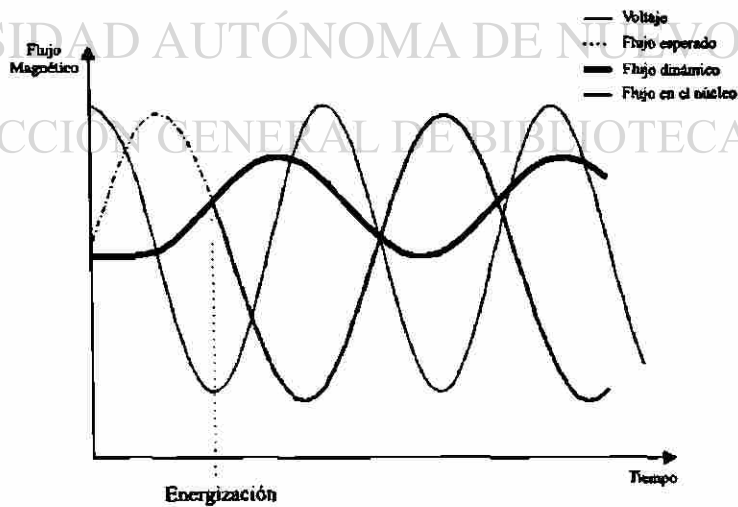


Fig. 2.7 Condición deseada de energización.

En conclusión las corrientes de avalanchas o *inrush* pueden reducirse y ser eliminadas [26], siempre y cuando se logre que el núcleo no llegue a estar saturado. Para lograr esta condición se debería controlar el instante en el que se energiza el transformador, lo que actualmente no se realiza en la práctica.

## 2.5 ESQUEMAS PARA LA PROTECCIÓN DIFERENCIAL DE TRANSFORMADORES

La protección diferencial de transformadores se basa en la comparación de las corrientes primaria y secundaria disponibles en el secundario de los TC instalados en ambos extremos del transformador principal. En condición normal ambas corrientes son iguales, expresadas en un sistema por unidad, es decir:

$$\underline{I}_p + \underline{I}_s = 0$$

(2.6)

En el caso de ocurrir un cortocircuito en el transformador, la corriente total del cortocircuito es igual a la suma de ambas corrientes:

$$\underline{I}_p + \underline{I}_s = \underline{I}_{CC}$$

(2.7)

Estas diferencias en magnitud es la base del funcionamiento de la protección diferencial. No obstante, las corrientes primaria y secundaria no son exactamente iguales, debido a diversas circunstancias, entre las que se pueden mencionar:

1. Hay diferencias de fase entre las corrientes en transformadores con conexión estrella-delta.
2. Tienen distintos niveles de voltaje, lo que implica que los transformadores de corriente pueden ser de distintos tipos, y tener relaciones de transformación y características diferentes.

3. Puede no haber concordancia entre las relaciones de transformación de los transformadores de corriente disponibles y la del transformador protegido.
4. La relación de transformación puede ser variable para fines de regulación de voltaje.
5. La corriente de magnetización del transformador puede tener un valor transitorio alto en algunos casos, que la protección puede interpretar erróneamente como indicativo de una falla interna.
6. Alta corriente de excitación causado por sobreexcitación de transformadores.

Los primeros cuatro puntos anteriores se resuelven por conexión de los TC's y la selección de los parámetros de ajuste del relevador, sin embargo las altas corrientes debido al efecto de *inrush* y la sobreexcitación del transformador se resuelven por diseño del relevador, y no por ajuste.

Los relevadores de protección diferencial basan su principio de funcionamiento en la comparación de dos corrientes, una denominada corriente de operación ( $\underline{I}_{op}$ ) y la segunda se conoce como corriente de retención ( $\underline{I}_R$ ).

La corriente de operación  $\underline{I}_{op}$  esta constituida por la suma fasorial de las corrientes del lado primario y secundario del transformador, disponibles en los secundarios de los TC's. (ver Fig. 2.8). En el caso de la corriente de retención,  $\underline{I}_R$ , existen distintas formas para definirla en función del diseño del relevador, siendo la más típica la diferencia fasorial de las corrientes secundarias de los TC's. Ambas corrientes se expresan como:

$$\underline{I}_{OP} = \left| \underline{I}_{W1} + \underline{I}_{W2} \right| \quad (2.8)$$

$$\underline{I}_{RT} = \left| \underline{I}_{W1} - \underline{I}_{W2} \right| \quad (2.9)$$




Fig. 2.8 Diagrama de conexión típico para el relevador diferencial.

En condiciones ideales, para una falla interna, se tendrá que  $\underline{I}_R = 0$ , lo que asegura la operación del relevador; en cambio para una falla externa, se presenta la condición de  $\underline{I}_{op} = 0$ , con lo cual se asegura la no operación de la protección.




Fig. 2.9 Condición de falla; (a) externa, (b) interna.

En el caso de una falla interna, la corriente de operación es la corriente de cortocircuito ( $\underline{I}_{op} \approx \underline{I}_{cc}$ ) y la corriente de retención es muy pequeña y aproximadamente igual a la corriente de desbalance ( $\underline{I}_R \approx \underline{I}_d$ ); como  $\underline{I}_{cc} \gg \underline{I}_d$ , se asegura la operación del relevador independientemente del error de transformación en los TC's.

En condiciones reales, las corrientes por secundario de los TC no son iguales, debido principalmente a los errores de transformación de los TC originados por el grado de

saturación de los mismos; esto significa que  $I_{op} > 0$ , con un valor aproximadamente igual a la diferencia entre las corrientes secundarias de los TC, este valor es conocido como la corriente de desbalance, es decir:

$$I_{op} = I_d \quad (2.10)$$

Con el objetivo de evitar operaciones incorrectas para fallas externas debido a los errores en los TC, la característica de operación del relevador es de la forma:

$$I_{op} = k I_R + I_{op\min} \quad (2.11)$$

donde  $k$  es la pendiente de la característica de operación del relevador e  $I_{op\min}$  es la corriente de operación mínima para que el relevador opere para una corriente de retención cero (ver Fig. 2.10).




Fig. 2.10 Característica del relevador de porcentaje diferencial.

Debido a la forma de la característica de operación, estos relevadores son conocidos como relevadores de porcentaje diferencial, ya que por lo general el parámetro de ajuste



$k$  se expresa en por ciento. Una de las características principales de este relevador es que es relativamente inmune a los errores de transformación de los TC, ya que mientras mayor sea la corriente de desbalance en una falla externa, la corriente de retención será mayor, evitando así la operación incorrecta del relevador.

La técnica más común usada para prevenir falsos disparos de la protección durante la energización o sobreexcitación es el bloqueo o restricción de armónicos en el relevador. Las corrientes de *inrush* difieren de las corrientes de fallas internas por el alto porcentaje de armónicos y el segundo armónico es de mayor magnitud bajo condiciones de energización. Una forma de operar el relevador es que si el contenido del segundo armónico de la corriente diferencial excede un porcentaje predefinido de la fundamental, esta corriente de magnetización es asumida y la protección es bloqueada para evitar una operación incorrecta.

No obstante, estos algoritmos presentan problemas para discriminar entre las corrientes de *inrush* y de cortocircuito en condiciones de energización y sobreexcitación del transformador en que la corriente de magnetización es altamente simétrica, y en consecuencia presenta un bajo contenido de armónicas.

### 2.5.1 MÉTODOS DE RETENCIÓN DE LA PROTECCIÓN DIFERENCIAL BASADOS EN ARMÓNICAS

Se puede usar el contenido armónico de la corriente diferencial para bloquear la operación del relevador con el fin de discriminar entre fallas internas y condiciones de *inrush*. La Fig. 2.11 muestra el esquema simplificado para el relevador diferencial con restricción de armónicos.

La corriente a través del transformador tiene dos circuitos primarios que forma la corriente de restricción para dos embobinados del transformador. Cada uno de los circuitos primarios a través de la corriente del transformador es conectado en el circuito principal de corriente del transformador. El resultado de la corriente de restricción es la

diferencia fasorial de las corrientes entrantes del transformador ecuación. El relevador rectifica cada una de las corrientes secundarias a través de los transformadores de corriente independientes y la suma de ellos forman la corriente de restricción.

$$I_{RT} = K(|I_{W1}| + |I_{W2}| + |I_{W3}|) \quad (2.12)$$

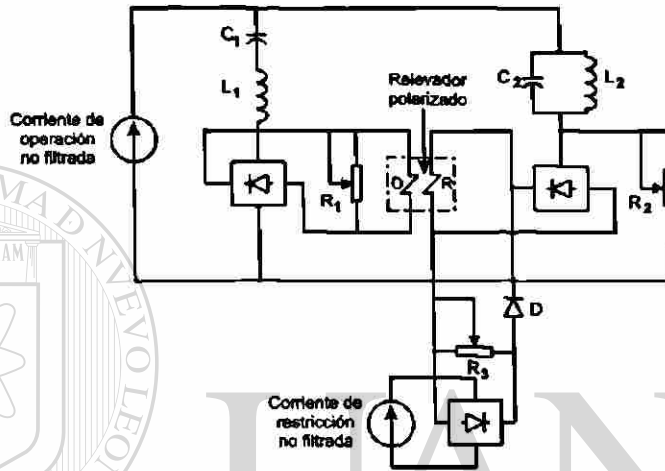


Figura 2.11 Relevador diferencial para un transformador con restricción de armónicos.

El objetivo es polarizar el relevador y realizar una comparación de amplitud de la corriente rectificadas de operación, O, y restricción, R, ver Fig. 2.11. La condición de operación del relevador diferencial se puede expresar como:

$$I_{OP} > SLP \cdot I_{RT} + K_2 I_2 + K_3 I_3 + \dots \quad (2.13)$$

donde  $I_{OP}$  representa la componente fundamental de la corriente de operación;  $I_2, I_3, \dots$  son las componentes armónicas,  $I_{RT}$  es la corriente de restricción no filtrada y  $K_2, K_3, \dots$  son coeficientes constantes. La resistencia  $R_1$  proporciona el ajuste para la corriente mínima de arranque  $I_{PU}$  del relevador diferencial, la resistencia  $R_2$  controla el

nivel de restricción de armónicas en el relevador y la resistencia  $R_3$  proporciona el ajuste de porcentaje del relevador.

El circuito  $L_1$  y  $C_1$  (filtro pasa bajo) solo permite que la corriente de operación este constituida por la componente fundamental, mientras que las armónicas superiores presentes en la corriente de operación no filtrada son inyectadas en el circuito de retención del relevador, a través del filtro pasa alto  $L_2$  y  $C_2$ .

### ✓ Método de restricción de segunda y quinta armónica

Einval y Linders [27], diseñaron un relevador diferencial trifásico con restricción de segunda y quinta armónica. Este diseño consiste en usar la segunda armónica para identificar la corriente de *inrush* y usaba la quinta armónica para evitar la operación en falso para condiciones de sobreexcitación del transformador. También introdujeron el primer concepto común para la restricción de armónicos. El concepto fundamental es que la cantidad de armónicos restringidos es proporcional a la suma de los componentes del segundo y quinto armónico de los tres elementos del relevador. La ecuación de operación del relevador se escribe como:

$$I_{OP} > SLP \cdot I_{RT} + \sum_{n=1}^3 (K_2 I_{2n} + K_5 I_{5n}) \quad (2.14)$$

DIRECCIÓN GENERAL DE BIBLIOTECAS

### Método de bloqueo de armónicos

Sharp y Glassburn [28] propusieron el bloqueo de armónicos. La Fig. 2.12 simplifica el diagrama esquemático para el relevador diferencial con bloqueo de segunda armónica. El relevador consiste en una unidad diferencial, DU, y una unidad de bloqueo de armónicos, HBU. Ambas unidades son de alta velocidad.

En la unidad diferencial (Fig. 2.12(a)) un transformador de corriente auxiliar forma la corriente de operación, esta es rectificadora y aplicada a la bobina de operación para polarizar la unidad del relevador. El resistor  $R_1$  proporciona el ajuste de porcentaje para el relevador diferencial. En la unidad de bloqueo de armónicos (Fig. 2.12(b)) del

transformador de corriente auxiliar, se genera la corriente de operación sin la componente de DC misma que es bloqueada por el transformador auxiliar. Cuenta con un circuito pasabajos ( $L_1, C_1$ ) y un circuito pasaaltos ( $L_2, C_2, L_3$ ). Estos filtros dejan pasar la segunda armónica y parte de la componente fundamental como parte de la corriente de operación.

La condición de operación para la unidad de bloqueo de armónicos HBU, se expresa como:

$$I_{OP} + K_3 I_3 + K_4 I_4 + \dots > K_2 I_2 \quad (2.15)$$

La Fig. 2.12(c) muestra el diagrama simplificado del contacto lógico del relevador. La respuesta transitoria de los filtros durante la corriente de *inrush* con bajo contenidos de armónicos puede causar que el relevador diferencial opere en falso por lo que un relevador auxiliar retrasa un tiempo la operación (T), el relevador también incluye una unidad de sobrecorriente instantáneo que incluye disparos rápidos para fallas internas severas.

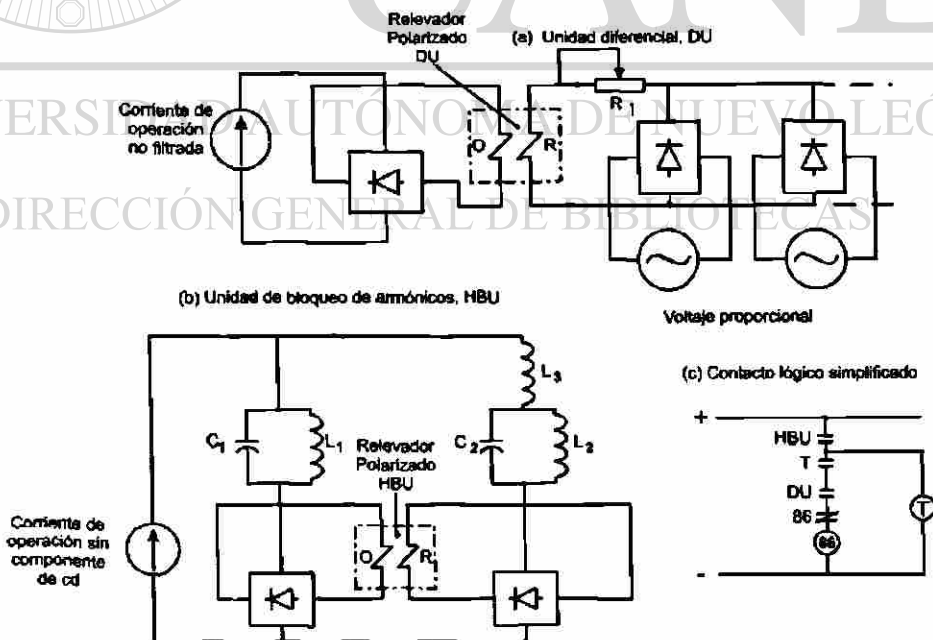


Figura 2.12 Relevador diferencial para transformadores con bloqueo por armónicos.

Otra alternativa es utilizar el segundo y el quinto armónico para la lógica de bloqueo. La Fig. 2.13(a) muestra el diagrama lógico del elemento diferencial con bloqueo por segundo y el quinto armónico.

$$I_{OP} < K_2 I_2 \quad (2.16)$$

$$I_{OP} < K_5 I_5 \quad (2.17)$$

La Fig. 2.13(b) muestra el diagrama lógico del elemento diferencial usando la restricción por segundo y quinto armónico.

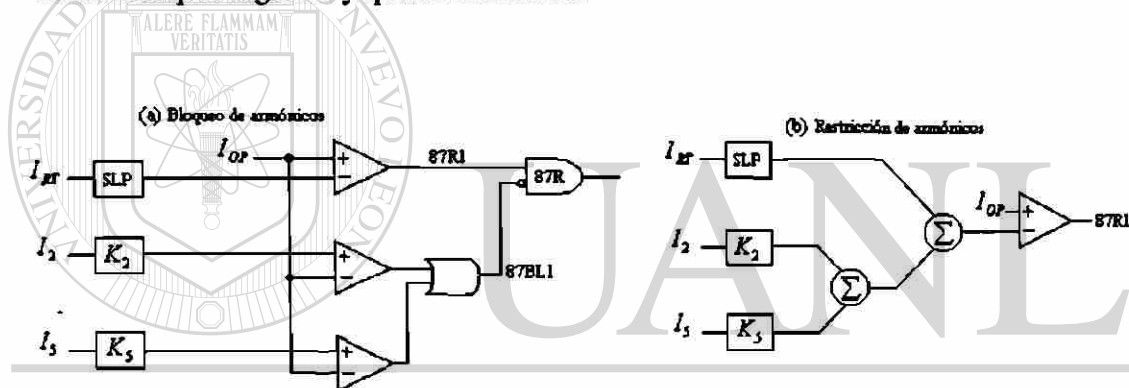


Figura 2.13 Diagrama lógico de un relevador con bloqueo-retención por segundo y quinto armónico.®  
DIRECCIÓN GENERAL DE BIBLIOTECAS

## 2.5.2 MÉTODOS DE RETENCIÓN BASADOS EN EL RECONOCIMIENTO DE LA FORMA DE ONDA

Otro método para discriminar fallas internas de condiciones de *inrush* es directamente el reconocimiento de distorsiones de formas de onda de la corriente diferencial. La identificación de la separación de picos de la corriente diferencial representa la base de los métodos de reconocimiento de formas de onda.




Fig. 2.14 Bloqueo del relevador diferencial basado en reconocer el tiempo de duración de bajos intervalos de corriente.

La corriente diferencial es comparada con umbrales positivos y negativos de iguales magnitudes. Esta comparación ayuda a determinar la duración de intervalos en que el valor absoluto de la corriente es menor que el valor absoluto de los umbrales. El intervalo de tiempo es entonces comparado con un parámetro de ajuste de un cuarto de ciclo. Para corrientes de *inrush* (Fig. 2.14(a)) el intervalo  $t_A$  es mayor que un cuarto de ciclo, y el relevador es bloqueado.

Para fallas internas (Fig. 2.14(b)) el intervalo  $t_B$  es menor que un cuarto de ciclo, y se permite la operación del relevador. Este método se puede aplicar con la corriente diferencial rectificadas. Otra alternativa es la comparación de la corriente diferencial rectificadas con un cierto umbral de operación para generar la señal de disparo.

Otro grupo de métodos usan el reconocimiento de la componente de DC de salida o la asimetría en la corriente diferencial. Algunos relevadores electrónicos analógicos usaban la saturación de un transformador auxiliar debido a la componente de DC de la corriente diferencial como un método de bloqueo.

Otros métodos comparan la amplitud del semiciclo positivo y negativo de la corriente diferencial en base a dos umbrales de operación en dos elementos diferenciales polarizados. Rockefeller [29] sugirió la extensión de esta idea para el relevador digital. Otra alternativa es usar la diferencia del valor absoluto de semiciclos positivos y negativos de la corriente diferencial por restricción. Más recientemente, Wikilson [30] propone separar la comparación de porcentaje diferencial en ambos semiciclos de la corriente diferencial.

En general las técnicas de reconocimiento de formas de onda representan otra alternativa para discriminar fallas internas para condiciones de *inrush*, sin embargo tienen problemas para identificar condiciones de sobreexcitación.

En la práctica es común usar la quinta armónica en la corriente de operación para evitar la operación del relevador diferencial para condiciones de sobreexcitación en el transformador. Más recientemente, se ha propuesto un método que tenga la capacidad de discriminar la condición de sobreexcitación [16]. El propósito de este método es incluir la restricción de armónicos y bloquear la quinta armónica proporcionando así muy alta seguridad para condiciones de *inrush* y sobreexcitación, sin embargo en los casos donde la corriente es altamente simétrica puede operar incorrectamente. El propósito de este método es incluir la restricción de armónicos y bloquear el quinto armónico proporcionando muy alta seguridad para *inrush* y condiciones de sobreexcitación, sin embargo algunos casos de *inrush* se parece a una onda puramente senoidal.

La componente de DC de la corriente de *inrush* tiene una constante de tiempo mayor que para fallas internas. La presencia de la componente de DC en la corriente de *inrush* es un indicador adicional que puede ser usado para garantizar la seguridad del relevador para corrientes de *inrush*. Este método de reconocimiento de onda es relativamente fácil de aplicar en un relevador digital, ya que la extracción de la componente de DC es un proceso de filtrado pasabajos.

Este método propone dividir la corriente diferencial en semiciclos positivos y negativos y calcular el área bajo la curva para ambos semiciclos; de esta forma, se puede utilizar la razón de las áreas calculadas para bloquear la operación del relevador. Se puede demostrar que el área bajo la curva de corriente es proporcional a la suma de las muestras de corriente en el mismo período de tiempo, tanto para el semiciclo positivo ( $A^+$ ) como para el negativo ( $A^-$ ). Así para el semiciclo positivo:

$$S^+ = \left| \sum_{k=1}^N i_k \right| \rightarrow (i_k \geq \varepsilon) \quad (2.18)$$

$$S^+ = 0 \rightarrow (i_k < \varepsilon) \quad (2.19)$$

donde  $i_k$  representa las muestras de corriente,  $N$  es el número de muestras por ciclo, y  $\varepsilon$  es el valor de umbral dado.  $S^+$  es proporcional al área  $A^+$  de el semiciclo positivo de la corriente de operación. En el semiciclo negativo:

$$S^- = \left| \sum_{k=1}^N i_k \right| \rightarrow (i_k \leq -\varepsilon) \quad (2.20)$$

$$S^- = 0 \rightarrow (i_k < \varepsilon) \quad (2.21)$$

donde  $S^-$  es proporcional al área  $A^-$  del semiciclo negativo. A partir de estos valores se calcula el índice DCR según:

$$DCR = \frac{\text{Min}(S^+, S^-)}{\text{Max}(S^+, S^-)} \quad (2.22)$$

La ecuación (2.22) proporciona un DCR normalizado (su valor es entre 0 y 1). Comparando DCR con un umbral de 0.1, se implementa un esquema de bloqueo por corriente directa como:



$$\text{DCR} < 0.1 \quad (2.23)$$

La respuesta de este método de bloqueo de DC depende del contenido de corriente directa además del contenido de armónicos de la corriente diferencial. Por ejemplo, el método asegura dependabilidad para fallas internas con saturación de TC's y mantiene esta seguridad durante condiciones de *inrush* con bajo contenido de armónicos.

Lã Fig. 2.15 muestra el diagrama esquemático del método de bloqueo por CD. Para corrientes altamente simétricas, la razón DCR tiende a 1.0, permitiendo así la operación del relevador. Por el contrario, para corrientes de *inrush* o de sobreexcitación con un alto contenido de CD, la razón DCR tiende a ser muy pequeña, y cuando supera el umbral de operación de 0.1, se emite una señal de bloqueo al relevador.




Fig. 2.15 Lógica de bloqueo CD.

## 2.6 ALGORITMOS DE ESTIMACIÓN FASORIAL PARA LA PROTECCIÓN DIFERENCIAL DE TRANSFORMADORES

La literatura publicada para la protección digital de transformadores de potencia ha recibido mucha atención en el desarrollo de algoritmos para la protección diferencial que esta involucra. Estos algoritmos muestran la corriente diferencial en intervalos de tiempo para determinar la componente fundamental y el contenido armónico.

Los algoritmos estiman los parámetros de determinadas componentes de frecuencia en dependencia del tipo de protección. La protección diferencial de transformadores utiliza como información las componentes de frecuencia fundamental de las señales y todas las demás componentes sin ruido. Sin embargo, se requiere adicionalmente identificar ciertas armónicas para propósitos de retención en el relevador.

En la mayor parte de los relevadores se requiere, un filtrado que permita el paso de la componente fundamental (y de algunas armónicas, si son necesarias para retención), y que además rechace la componente aperiódica, las subarmónicas y las armónicas superiores.

Las señales de entrada a los relevadores están contaminadas con distintos tipos de ruidos y la capacidad de un algoritmo para rechazarlos depende de gran medida de la longitud de ventana de datos. Un algoritmo de ventana corta cruza rápidamente por el punto de discontinuidad, pero su respuesta en el estado de falla puede demorar mucho en converger a los valores correctos por el efecto del ruido presente. Esto constituye una manifestación de la relación de naturaleza inversa que existe entre velocidad y precisión.

El aumento de la frecuencia de muestreo eleva marginalmente la velocidad del relevador, ya que el relevador tiene que esperar como mínimo un tiempo igual a la longitud de ventana de datos para tomar la primera decisión, con independencia del número de muestras que contenga la ventana.

Algunos de los algoritmos usados para la protección digital de transformadores son los siguientes:

- Algoritmo basado con técnicas de Fourier.
- Algoritmo basado con transformación rectangular.
- Algoritmo basado con funciones Walsh.
- Algoritmo basado con funciones Haar.
- Algoritmo basado con mínimos Cuadrados.

- Algoritmo basado con respuesta al impulso finito.
- Restricción del flujo en la corriente diferencial.

Las técnicas de Fourier [5] se basan en que cualquier forma de onda periódica tiene una energía finita en el intervalo  $(0,T)$ , y puede ser expresada en intervalos con sus coeficientes. Usando este concepto la corriente diferencial es analizada para obtener el espectro de frecuencia donde se analiza la componente fundamental y el contenido armónico.

Las técnicas con transformación rectangular [8] utilizan las muestras de la corriente diferencial medida por el filtro de Fourier y definen coeficientes de senos y cosenos para remplazarlos con funciones equivalentes denominadas transformaciones rectangulares. Por consiguiente los coeficientes rectangulares se obtienen de pruebas de corriente diferencial donde se calculan la componente fundamental y el segundo armónico para su estudio.

Las funciones Walsh [11] son conjuntos de  $N = 2^n$  (donde  $n$  es un número entero) y son funciones ortogonales definidas en el intervalo  $[0,1]$ , que toman solamente los valores de  $\pm 1$ . La propiedad de ortogonalidad permite calcular fasores por Walsh en la misma forma que se generan con el par seno-coseno en el algoritmo de Fourier. Las funciones Walsh carecen de habilidad para rechazar las armónicas pares, lo que coloca en desventaja con respecto a los de Fourier. Por otro lado puede lograrse una respuesta de frecuencia idéntica a la de Fourier si se utiliza un número elevado de funciones Walsh, pero ello afecta la eficiencia computacional que se pretende obtener con la utilización de este tipo de funciones.

Las funciones Haar [10] se expresan de forma completa como funciones rectangulares ortogonales, donde se obtienen los coeficientes de Haar en términos de la función de Fourier en un intervalo de  $(0,T)$ . Los coeficientes de Haar se obtienen por la correlación

de muestras de la corriente diferencial para obtener los coeficientes de Fourier ( $F_1, \dots, F_n$ ), y así determinar la componente fundamental y la segunda armónica.

El algoritmo de mínimos cuadrados [8-9] considera todos los errores posibles en la señales de entrada y se basa en la técnica de estimación mínima cuadrática. En este algoritmo puede considerarse cualquier conjunto de señales elementales y pueden incluir la componente fundamental, armónicas superiores y la componente aperiódica exponencial. La selección del conjunto de señales elementales es de gran importancia, pues aquellas que no sean consideradas, y estén realmente presentes en la señal de entrada, constituyen un error. Una ventaja del algoritmo de mínimos cuadrados es la posibilidad de rechazar la componente aperiódica exponencial mediante una inclusión explícita, pero el precio de esto es una mayor carga computacional para el procesador que en los algoritmos de Fourier.

El algoritmo basado en respuesta al impulso finito (FIR) [6] utiliza dos filtros, uno para la componente fundamental y otro para la segunda armónica. Usando muestras de la corriente diferencial en un ciclo, los filtros pueden ser calculados por muestras por periodos, por lo tanto la componente fundamental y la segunda armónica pueden calcularse por amplitudes de cálculos de los coeficientes de Fourier.

El algoritmo basado en restricción del flujo [44] en la corriente diferencial usa la relación flujo-corriente para obtener la función de restricción del relevador. Si el flujo puede ser estimado correctamente, se puede detectar la condición de sobreexcitación y también la condición de *inrush*. Un aspecto importante de esta técnica es que requiere menos tiempo de cómputo a las basadas en el análisis de Fourier.

### 2.6.1 COMPARACIÓN DE ALGORITMOS

Antes de utilizar un algoritmo para la protección de transformadores, se debe considerar los requerimientos computacionales para los diferentes algoritmos y evaluar

la capacidad para el microprocesador en el mercado. En un relevador digital, las señales son muestreadas en intervalos regulares y es guardada en la memoria del microprocesador a través de circuitos lógicos y convertidores analógicos y digitales. Los requerimientos fundamentales para los algoritmos descritos se muestran en la Tabla 2.2.

Estos datos son tomados de un microprocesador, como puede verse en esta tabla, todos los algoritmos pueden ser completados computacionalmente, dentro de las especificaciones de intervalos muestreados.

Tabla 2.2 Comparación de algoritmos de acuerdo a los requerimientos computacionales.

Algoritmos	Intervalos muestreados ( $\mu\text{s}$ )	Número de operaciones aritméticas			Tiempo para la aritmética computacional (1 fase) ( $\mu\text{s}$ )	Porcentaje para intervalos Muestreados
		+/-	$\times / \div$	$\sqrt{\quad}$		
<i>Fourier</i>	1042	51	14	2	380	36%
<i>Rectangular</i>	1042	106	8	2	410	39%
<i>F. Walsh</i>	1042	116	14	2	526	50%
<i>F. Haar</i>	1042	96	16	2	512	49%
<i>Impulso F.</i>	1042	84	4	2	298	29%
<i>Mínimos C.</i>	1389	46	19	2	447	32%

## 2.7 MÉTODO PROPUESTO

El método propuesto en esta tesis consiste en diseñar y entrenar una RNA de base radial para que realice la función de discriminar entre una condición de *inrush* y una falla en el transformador de potencia utilizando la información de corrientes secundarias de los TC's.

A fin de evaluar el impacto del procesamiento digital de señales utilizado en los modernos relevadores diferenciales, se simuló el filtrado analógico anti-aliasing, el proceso de muestreo, el filtrado digital [6-16] y la normalización de datos como etapas previas de la señal para la clasificación y entrenamiento de la RNA.

Los resultados obtenidos ponen de manifiesto la capacidad de generalización de la RNA de base radial para discriminar entre una condición de *inrush* y una falla en el transformador de potencia, lo que representa la base de un nuevo método de protección (bloqueo o no bloqueo) en transformadores de potencia.

## 2.8 CONCLUSIONES DEL CAPITULO

Los métodos descritos para la protección diferencial de transformadores no han demostrado en su totalidad ser lo suficientemente confiables. Investigaciones demuestran que las corrientes de cortocircuito contienen una magnitud considerable de componentes armónicas. También se ha reportado que los materiales magnéticos amorfos reducen el contenido de armónicas en las corrientes de magnetización. Esto lleva a desarrollar trabajos de investigación con la finalidad de desarrollar nuevos algoritmos de protección de transformadores.

La discriminación entre una condición de *inrush* y una falla en el transformador de potencia puede visualizarse como un problema de reconocimiento de patrones [31,32,33,34]. En base a ello, el problema de identificación se puede realizar mediante la aplicación de redes neuronales, dadas sus características de generalización, robustez e inmunidad al ruido, que han sido demostradas previamente.

## CAPÍTULO 3



# REDES NEURONALES ARTIFICIALES DE BASE RADIAL (RBF)

### 3.1 INTRODUCCIÓN

---

Las redes de neuronas artificiales se definen como un sistema masivo de elementos básicos de procesamiento altamente interconectados que procesan la información de una manera distribuida y en paralelo, donde todas las unidades básicas de procesamiento actúan al mismo tiempo. Son una rama de la inteligencia artificial, y de ahí que se le defina como procesamiento de información en paralelo en forma no algorítmica.

En este capítulo se presenta una breve descripción de la RNA, así como los aspectos generales relacionados con los tipos de RNA que existen, su proceso de entrenamiento, el análisis de la información de entrada a la red y en especial se tratará el concepto detallado de las RNA de base radial (RBF).

### 3.2 DEFINICIÓN DE UNA RED NEURONAL ARTIFICIAL

Las redes neuronales son modelos que intentan reproducir el comportamiento del cerebro a través del procesamiento masivo de información utilizando un esquema distribuido en procesamiento paralelo. Una elección adecuada de sus características, más una estructura conveniente es el procedimiento convencional utilizado para construir redes, capaces de realizar una determinada tarea.

Cualquier modelo de red neuronal consta de dispositivos elementales de procesamiento (neuronas). Se denomina procesador elemental o neurona a un dispositivo simple de cálculo que a partir de una información de entrada procedente del exterior o de otras neuronas, proporciona una única respuesta o salida. Los elementos que constituyen una neurona son las siguientes:

- Conjunto de entradas,  $x_i(t)$
- Pesos sinápticos de la neurona  $i$ ,  $w_{ij}$  que representa la intensidad de interacción entre cada neurona presináptica y la neurona postsináptica (Fig. 3.1).
- Regla de propagación  $\sigma(w_{ij}, x_j(t))$ , que proporciona el valor del potencial postsináptico  $h_i(t) = \sigma(w_{ij}, x_j(t))$  de la neurona  $i$ , en función de sus pesos y entradas.
- Función de activación  $f_i(a_i(t-1), h_i(t))$ , que proporciona el estado de activación actual  $a_i(t) = f_i(a_i(t-1), h_i(t))$  de la neurona  $i$ , en función de su estado anterior  $a_i(t-1)$  y de su potencial postsináptico actual.
- Función de salida  $F_i(a_i(t))$ , que proporciona la salida actual  $y_i(t) = F_i(a_i(t))$  de la neurona  $i$  en función de su estado de activación.

De este modo, la operación de la neurona  $i$  puede expresarse como:

$$y_i(t) = F_i(f_i[a_i(t-1), \sigma(w_{ij}, x_j(t))]) \quad (3.1)$$






Fig. 3.1 Interacción entre una neurona presináptica y otra postsináptica.

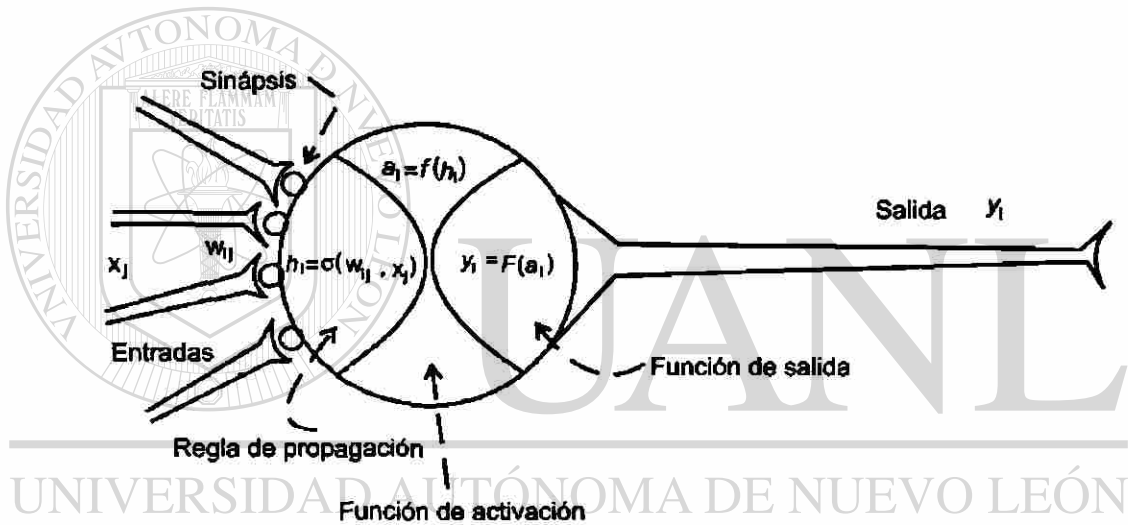


Fig. 3.2 Modelo genérico de una neurona artificial.

El modelo de neurona expuesto en la Fig. 3.2 es general; en la práctica suele utilizarse uno más simple, que se denomina neurona estándar (Fig. 3.3). Considerando que la regla de propagación es la suma ponderada y que la función de salida es la identidad. De esta forma, la neurona estándar consiste en:

- Un conjunto de entradas  $x_j(t)$  y pesos sinápticos  $w_{ij}$ .
- Una regla de propagación  $h_i(t) = \sigma(w_{ij}, x_j(t))$ ;  $h_i(t) = \sum w_{ij} x_j$  es la más común.

- Una función de activación  $y_i(t) = f_i(h_i(t))$ , que representa simultáneamente la salida de la neurona y su estado de activación.

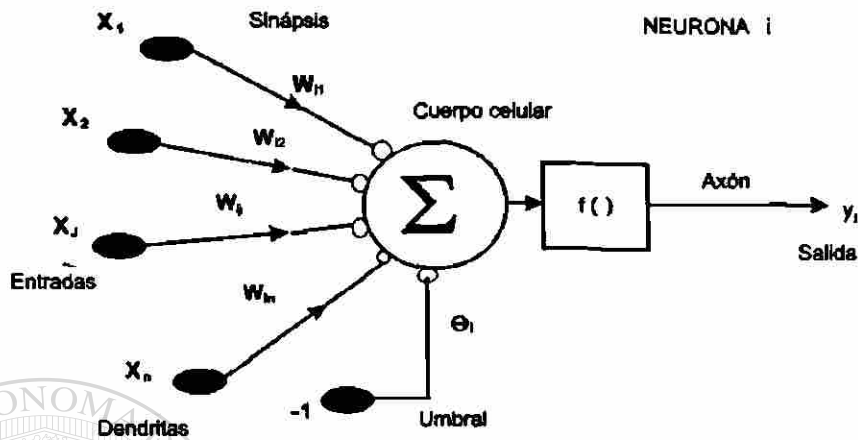


Fig. 3.3 Modelo de neurona estándar.

Con frecuencia se añade al conjunto de pesos de la neurona un parámetro adicional  $\theta_i$  que denominaremos umbral, que resta información del potencial postsináptico, por lo que el argumento de la función queda como:

$$y_i(t) = f_i(\sum w_{ij} X_j - \theta_i) \quad (3.2)$$

Si  $w_{ij}$  es positivo indica que la interacción entre las neuronas  $i$  y  $j$  es excitadora; es decir, siempre que la neurona  $i$  esté activada, la neurona  $j$  recibirá una señal de  $i$  que tenderá a activarla. Si  $w_{ij}$  es negativo, la sinapsis será inhibitoria. En este caso, si  $i$  está activada, enviará una señal a  $j$  que tenderá a desactivar a ésta. Finalmente, si  $w_{ij} = 0$ , se asume que no hay conexión entre ambas.

La ecuación (3.2) se conoce como la función de activación  $f(W,X)$  y puede variar en dependencia de la función que realice la red, entre algunas se puede mencionar las siguientes:

- Lineal.

$$f_i(W, X) = \sum_{j=1}^n W_{ij} X_j - \theta_i \quad (3.3)$$

- Cuadrática.

$$f_i(W, X) = \sum_{j=1}^n W_{ij} X_j^2 - \theta_i \quad (3.4)$$

- Esférica.

$$f_i(W, X) = \frac{1}{\rho^2} \sum_{j=1}^n (X_j - W_{ij})^2 - \theta_i \quad (3.5)$$

- Polinomial.

$$f_i(W, X) = \sum_{j=1}^n \sum_{k=1}^n W_{ijk} X_j X_k + X_j^{\alpha_j} + X_k^{\alpha_k} - \theta_i \quad (3.6)$$

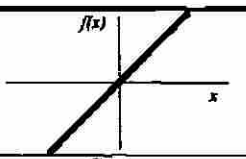
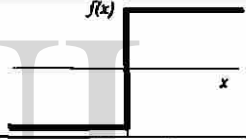
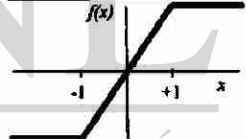
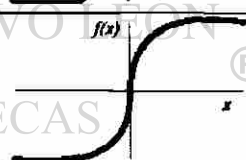
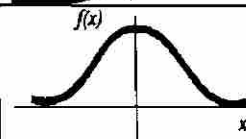
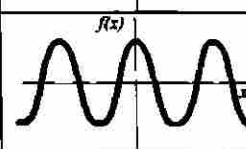
La función de activación proporciona el estado de activación actual  $a_i(t)$  a partir del potencial postsináptico  $h_i(t)$  y del propio estado de activación anterior,  $a_i(t-1)$ . Sin embargo, en muchos modelos se considera que el estado actual de la neurona no depende de su estado anterior, sino únicamente del actual.

$$a_i(t) = f_i(h_i(t)) \quad (3.7)$$

Las funciones de activación se suelen considerar deterministas, y en la mayor parte de los modelos es monótonica creciente y continua. La forma de las funciones de activación más empleadas se muestran en la Tabla 3.1. Para abreviar, en ella se designa con  $x$  al potencial postsináptico, y con  $y$  el estado de activación. La más simple de todas es la función identidad (que se puede generalizar al caso de una función lineal cualquiera), empleada por ejemplo en la adeline [48,49]. Otro caso también muy simple es la función escalón, empleada en el perceptrón simple [34,40,48,49]. La función lineal mixta [48,49] se puede considerar como una línea saturada en sus extremos, es de gran sencillez computacional.

En ocasiones los algoritmos de aprendizaje requieren que la función de activación cumpla la condición de ser variable. Las más empleadas en este sentido son las funciones de tipo sigmoidal [20,48,49]. En ocasiones se emplean funciones sinusoidales, como en aquellos casos en los que se requiere expresar explícitamente una periodicidad temporal. Otra función de mayor atención es la gaussiana, que se utiliza con reglas de propagación que involucran el cálculo de cuadrados de distancias (por ejemplo, la euclídea) entre los vectores de entradas y pesos que más adelante trataremos más detalladamente para la aplicación de la protección diferencial en transformadores.

Tabla 3.1 Funciones de activación

	Función	Rango	Gráfica
<b>Identidad</b>	$y = x$	$[-\infty, +\infty]$	
<b>Escalón</b>	$y = \text{signo}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
<b>Lineal a Tramos</b>	$y = \begin{cases} -1, & \text{si } x < -1 \\ x, & \text{si } -1 \leq x \leq +1 \\ +1, & \text{si } x > +1 \end{cases}$	$[-1, +1]$	
<b>Sigmoidal</b>	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
<b>Gaussiana</b>	$y = A e^{-Bx^2}$	$[0, +1]$	
<b>Sinusoidal</b>	$y = A \text{sen}(wx + \varphi)$	$[-1, +1]$	

De acuerdo a lo anterior, un nuevo estado de activación se obtiene con una regla  $F$  que combine las entradas con el estado actual de la neurona. Esta función  $F$  produce un nuevo estado de activación en una neurona a partir del estado  $(a_i)$  que existía y la combinación de las entradas con los pesos de las conexiones.

Existen distintos tipos de función de activación; algunas de ellas son:

a) *Función de activación lineal o identidad*

El estado de activación coincide con la entrada total a la unidad (El conjunto de estados puede contener cualquier número real).

$$y_i(t+1) = Net_i - \theta_i \quad (3.8)$$

b) *Función de activación escalón*

Si el conjunto de los estados de activación es  $E = \{0,1\}$ :

$$y_i(t+1) = \begin{cases} 1 & \text{si } [Net_i > \theta_i] \\ y(t) & \text{si } [Net_i = \theta_i] \\ 0 & \text{si } [Net_i < \theta_i] \end{cases} \quad (3.9)$$

si el conjunto es  $E = \{-1,1\}$ :

$$y_i(t+1) = \begin{cases} +1 & \text{si } [Net_i > \theta_i] \\ y(t) & \text{si } [Net_i = \theta_i] \\ -1 & \text{si } [Net_i < \theta_i] \end{cases} \quad (3.10)$$

c) *Función de activación lineal-mixta*

En esta función, el estado de activación de la unidad está obligado a permanecer dentro de un intervalo  $[b,B]$  de valores reales prefijados.

$$y_i(t+1) = \begin{cases} b & Net_i \leq B + \theta \\ Net_i - \theta & b + \theta < Net_i < B + \theta \\ B & Net_i \geq B + \theta \end{cases} \quad (3.11)$$

d) *Función de activación sigmoideal*

Es una función continua en el espacio de los estados de activación sobre el eje real. Para un conjunto de estados de activación  $[0,1]$ :

$$y_i(t+1) = \frac{1}{(1 + e^{-(Net_i - \theta_i)})} \quad (3.12)$$

Para un conjunto de estados de activación [-1,1]:

$$y_i(t+1) = \frac{2}{(1 + e^{-(Net_i - \theta_i)})} - 1 \quad (3.13)$$

Para la salida de una neurona  $i$ , es habitual considerar la existencia de una neurona ficticia ( $N+1$ ), con valor de salida igual a la unidad ( $Y_{N+1}=1$ ), asociada a la entrada de cada neurona  $i$  mediante una conexión con peso valor  $-\theta_i$ . La expresión queda de la siguiente manera:

$$y_i(t+1) = f\left(\sum_{j=1}^N w_{ij} y_j(t) - \theta_i \cdot 1\right) = f\left(\sum_{j=1}^{N+1} w_{ij} y_j(t)\right) = f(Net_i) \quad (3.14)$$

e) *Función de activación Gaussiana*

Si el vector de entradas coincide con el centroide de la neurona ( $x = c_j$ ), ésta responde con máxima salida (la unidad). Es decir, cuando el vector de entradas se sitúa en una región próxima al centroide de la neurona, ésta se activa, indicando que reconoce el patrón de entrada; si el patrón de entrada es muy diferente al centroide, la respuesta tiende a cero. La salida de la neurona oculta  $j$  está definida como:

$$y_j = e^{-r_j^2 / 2\sigma_j^2} = e^{-\sum_i (x_i - c_{ji})^2 / 2\sigma_j^2} \quad (3.15)$$

### 3.3 REDES NEURONALES DE BASE RADIAL

A partir de lo visto hasta el momento puede decirse que dependiendo del modelo de neurona que se utilice, de la arquitectura o topología de conexión y del algoritmo del aprendizaje, existen distintos modelos de redes neuronales. La clasificación se muestra en la Fig. 3.4.

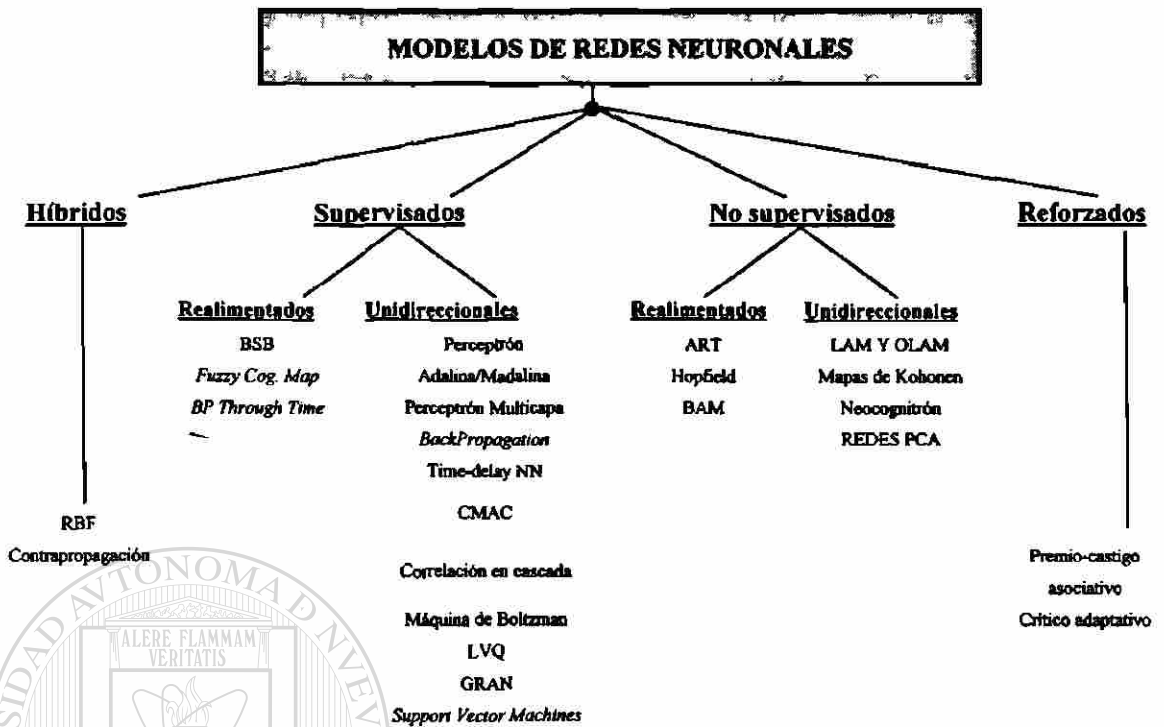


Fig. 3.4 Clasificación de las RNA por el tipo de aprendizaje y la arquitectura.

En esta sección se analiza el modelo de funciones de base radial o RBF (*Radial Basis Functions*) que, aunque de reciente introducción, tiene diversas aplicaciones prácticas debido a su simplicidad, generalidad y rapidez de aprendizaje. Se trata de un modelo que a menudo se estudia junto al MLP (*Multi-Layer Perceptron*) por ser una red unidireccional para aproximación funcional, pero que puede considerarse de tipo híbrido por incorporar aprendizaje supervisado y no supervisado.

Como sucede en el caso MLP, las RBF permiten modelar con relativa facilidad sistemas no lineales arbitrarios, con la particularidad de que el tiempo requerido para su entrenamiento suele ser mucho más reducido que el algoritmo BP (*backpropogación*) clásico [34,36,37].

La arquitectura de una RBF cuenta con tres capas de neuronas, la capa de entrada, la capa oculta y la capa de salida (similar a un MLP de una sola capa oculta). Las neuronas de entrada, en forma similar envían la información del exterior hacia las neuronas de la

capa oculta. Las neuronas de la capa de salida son lineales, y esencialmente calculan la suma ponderada de las salidas que proporcionan la capa oculta.

La diferencia fundamental entre la arquitectura de este modelo y la MLP se centra en la operación de las neuronas ocultas. Estas, en vez de calcular la suma ponderada de las entradas y aplicar una función de activación para determinar la salida, operan en base a la distancia que separa el vector de entradas respecto al vector sináptico que cada neurona almacena (denominado centroide, ver Fig. 3.5) [41]. Mientras que en el MLP las neuronas ocultas poseen una respuesta de rango infinito (cualquier vector de entrada, con independencia del lugar del espacio de entrada de donde proceda puede causar que la neurona se active), en la RBF las neuronas son de respuesta localizada, ya que solo responden con una intensidad apreciable cuando el vector de entradas presentado y el centroide de la neurona pertenecen a una zona próxima del espacio de entradas.




Figura 3.5 Funciones de las funciones de activación de la capa oculta y la capa de salida de la RBF.

A continuación se describe matemáticamente el modelo. Se denominará  $x_i$  a las entradas de la red,  $y_j$  son las salidas de la capa oculta,  $z_k$  son las salidas de la capa final (y globales de la red) (Fig. 3.6). Cada neurona  $j$  de la capa oculta almacena un vector  $c_{ji}$ , y cada una de estas neuronas calcula la distancia euclídiana  $r_j$  que separa el vector de entradas  $x_i$  de su centroide:

$$r_j^2 = \|x - c_j\|^2 = \sum_i (x_i - c_{ji})^2 \quad (3.16)$$






Figura 3.6 Arquitectura de la RBF.

La salida de la neurona  $y_j$  se calcula a partir de una función de activación denominada función radial  $\phi(r)$ . Una de las más típicas es la función gaussiana.

$$\phi(r) = e^{-r^2/2\sigma^2}$$

(3.17)

En ocasiones se emplean funciones diferentes, aunque de similar dependencia radial, como la que presentamos a continuación.

$$\phi(r) = r^2 \ln(r)$$

(3.18)

El término *función de base radial* procede precisamente de la simetría radial de estas funciones (el nodo da una salida idéntica para aquellos patrones que están a la misma distancia del centroide). En principio, en este trabajo de tesis se utiliza la función gaussiana descrita en (3.17).

El parámetro de normalización  $\sigma$  (o factor de escala) mide la anchura de la función gaussiana, y equivale al radio de influencia de la neurona en el espacio de las entradas; a mayor  $\sigma$  la región que la neurona domina en torno al centroide es más amplia (Fig. 3.7).

En base a lo anterior, la salida de la neurona oculta  $j$  esta dada por:

$$y_j = e^{-r_j^2 / 2\sigma^2} = e^{-\sum (x_i - c_{ij})^2 / 2\sigma^2} \quad (3.19)$$

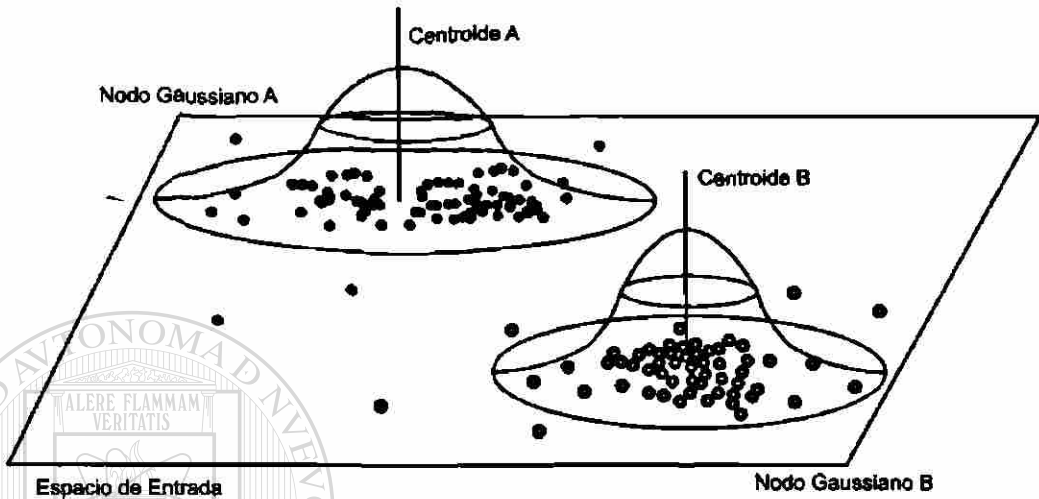


Fig. 3.7. Respuesta localizada de las neuronas ocultas en la RBF (nodos gaussianos). Los puntos representan patrones en el espacio de las entradas, que en su mayoría se agrupan en torno a los centros.

Así, si el vector de entradas coincide con el centroide de la neurona  $j$  ( $x = c_j$ ), ésta responde con un valor de salida máximo de 1.0. Es decir, cuando el vector de entradas se sitúa en una región próxima al centroide de la neurona, ésta se activa, indicando que reconoce el patrón de entrada; si el patrón de entrada es muy diferente al centroide, la respuesta tiende a cero. Las funciones descritas  $\phi(\cdot)$  pueden ser simétricas, sin embargo se puede seleccionar una  $\sigma$  diferente para cada dirección,  $\sigma_{ij}$ , con lo que la función adquiere formas elipsoidales. Las salidas de las neuronas ocultas son a su vez las entradas de las neuronas de salida, las cuales calculan su respuesta  $z_k$  de la forma:

$$z_k = \sum_j w_{kj} y_j + \theta_k = \sum_j w_{kj} \phi(r_j) + \theta_k \quad (3.20)$$

donde  $w_{kj}$  es el peso que conecta la neurona oculta  $j$  con la salida  $k$ , y  $\theta_k$  es el umbral de operación de la neurona  $k$ , similar al utilizado en un perceptrón.

En la RBF, cada nodo gaussiano se ocupa de una zona del espacio, y el conjunto de nodos debe cubrir totalmente la zona de interés (ver Fig. 3.8). Esta cobertura debe llevarse a cabo de la forma más suave posible, lo cual se controla con el número de nodos de la capa oculta y con la anchura  $\sigma$  [49].




Fig. 3.8 Representación de cuatro nodos gaussianos que cubren un espacio de patrones.

### 3.4 PROCESO DE ENTRENAMIENTO DE LA RED NEURONAL

Existen distintos aspectos en el entrenamiento de la RBF. La primera es como elegir el número de nodos radiales (ocultos). Cada nodo radial cubre una parte del espacio de entrada (Fig. 3.8), de modo que hay que elegir el número de nodos adecuados que cubra suficientemente (para una aplicación dada) dicho espacio. El problema surge al tratar con espacios de entrada de muchas variables, pues el número de nodos necesarios crece exponencialmente al hacerlo la dimensión. De este modo debe existir un compromiso entre el número de nodos radiales seleccionado, el error que se alcanza en el ajuste de los patrones de aprendizaje, y la capacidad de generalización; al igual que en las MLP, puede aparecer un sobreentrenamiento al aumentar el número de neuronas ocultas.

Además de hacer uso del método de prueba y error, utilizado en el algoritmo BP, existen otros métodos para determinar el número de neuronas ocultas en una RBF. Por ejemplo, puede comenzarse con un determinado (reducido) número de nodos

gaussianos, y si algún patrón de entrada no activa en suficiente medida ninguna de estas neuronas ocultas, consideramos que es necesario introducir una nueva que dé cuenta de la presencia de una nueva clase de patrones. Un procedimiento así aplica en el modelo denominado algoritmo autoorganizado jerárquico.

Definido el número de nodos radiales, se deben seleccionar los parámetros de la arquitectura. En principio puede tomarse una aproximación global al problema, aplicando a la arquitectura de una red RBF el método de descenso por el gradiente, de forma similar a como se hace para determinar el algoritmo BP.

No obstante, suele emplearse un aprendizaje por etapas, en el que en primer lugar se realiza el entrenamiento de las neuronas ocultas gaussianas, para finalmente proceder al entrenamiento de las neuronas de salida.

En el entrenamiento de los nodos gaussianos debe determinarse en primer lugar el valor de los centroides  $c_{\mu}$ , pudiéndose aplicar para ello el algoritmo de las  $k$ -medias ( $k$ -means) [34], o cualquier otro algoritmo no supervisado para agrupamiento (*clustering*). En el caso de las  $k$ -medias,  $k$  hace referencia al número de grupos (*clusters*) que se trata de encontrar, que en nuestro caso se corresponderá con el número de nodos gaussianos propuesto de inicio de acuerdo a las características del problema. Así, en este procedimiento se propone en un número  $k$  de grupos, es decir, de neuronas, y el proceso es el siguiente:

1. Se eligen los valores de los  $k$  centroides  $c_j$  de inicio. Suelen tomarse como centroides los primeros  $k$  patrones de aprendizaje (la elección concreta no es relevante para el resultado final).
2. En cada iteración  $t$  se reparten los patrones de aprendizaje  $x$  entre las  $k$  neuronas. Cada patrón se asigna a la neurona de cuyo centroide dista menos.
3. Se calculan los nuevos centroides de cada neurona como promedio de los patrones de aprendizaje asignados en el paso (2). Así, definiendo  $N_j$  al número de patrones que han correspondido a la neurona  $j$  en el reparto, se tiene:

$$c_{j'} = \frac{1}{N_j} \sum_{x \in \text{neur}m_{aj}} x \quad (3.21)$$

4. Si los valores de los centroides no han variado respecto de la iteración anterior, el algoritmo ya ha convergido. Si no es así, se repite el paso (2).

Existen otros procedimientos para calcular el valor de las centroides, por ejemplo, puede emplearse reglas de aprendizaje pertenecientes al campo de las redes neuronales, como el algoritmo de *Kohonen simple* (sin tener en cuenta la función de vecindad), cuyo paralelismo con el algoritmo de las *k*-medias ha sido señalado con frecuencia [39].

Obtenidos los centroides, se procederá al cálculo de los parámetros de escala  $\sigma_j$  de cada neurona, para lo cual suele hacerse uso de criterios heurísticos. Un procedimiento se basa en calcular de forma aproximada el radio de influencia en el espacio de la entradas de cada neurona en relación a las demás, para lo cual se procede de la siguiente forma: para calcular el  $\sigma_j$  de la neurona *j* se seleccionan los centroides de las *N* neuronas que estén más próximos al del nodo *j*, y a continuación se calculan el promedio de las distancias cuadráticas entre ellos [36,37], es decir:

$$\sigma_j^2 = \frac{1}{N} \sum_{l=1}^N \|c_l - c_j\|^2 = \frac{1}{N} \sum_{l=1}^N \sum_k (c_{lk} - c_{jk})^2 \quad (3.22)$$

El caso extremo  $N=1$ , que consiste en tener en cuenta únicamente el nodo más cercano, obviamente resulta el más rápido de calcular y en general proporciona buenos resultados en muchos casos [36].

Otro procedimiento consiste en el cálculo del promedio de la distancia de diversos patrones representativos al centroide, respecto al número de patrones tomados para el cálculo del factor de escala del nodo. Se calculan los factores de escala, y con ello finaliza el entrenamiento de las neuronas de la capa oculta, es decir:

$$\sigma_j^2 = \frac{1}{N_j} \sum_{x \in \text{nodo}j} \|x - c_j\|^2 \quad (3.23)$$

En la segunda etapa se realiza el entrenamiento de las neuronas de salida. Se debe hacer notar que las cantidades  $\phi(r_j)$  son valores numéricos conocidos, puesto que son función de los valores de las entradas, centroides y factores de escala (cantidades todas ya conocidas), los pesos  $w_{kj}$  y umbrales  $\theta_k$  se calculan aplicando el algoritmo LMS (el de *Adaline*) a la expresión de salida de la capa final, que queda de la forma:

$$z_k = \sum_j w_{kj} \phi(r_j) + \theta_k \quad (3.24)$$

$$w_{kj}(t+1) = w_{kj}(t) + \varepsilon(t_k - z_k) \phi(r_j) \quad (3.25)$$

donde  $t_k$  son los patrones de salida (objetivos), ver Fig. 3.9. Los umbrales se actualizan siguiendo el mismo esquema, considerando que se trata de pesos con entradas de valor constante  $-1$ .




Fig. 3.9 Estructura de una red multicapa RBF con conexiones hacia adelante.

Al dividir el proceso de aprendizaje en dos etapas (el cálculo de los parámetros de la capa oculta, y el cálculo de los de la capa de salida), se consigue acelerar notablemente el proceso de aprendizaje respecto del BP, el cual opera globalmente (se suele indicar que el BP es unas tres veces más lento). Es muy importante tener en cuenta que de las dos etapas que conforman el aprendizaje, la primera hace uso de un algoritmo no

supervisado, sea el de *Kohonen* o el de *k-medias*, mientras que en la segunda se emplea el algoritmo de tipo supervisado. Al conjugar un tipo de aprendizaje no supervisado en la capa oculta, con otro supervisado en la salida, este modelo de RNA es una red híbrida. En la Fig. 3.10 se muestra el diagrama de flujo de entrenamiento de la RBF.

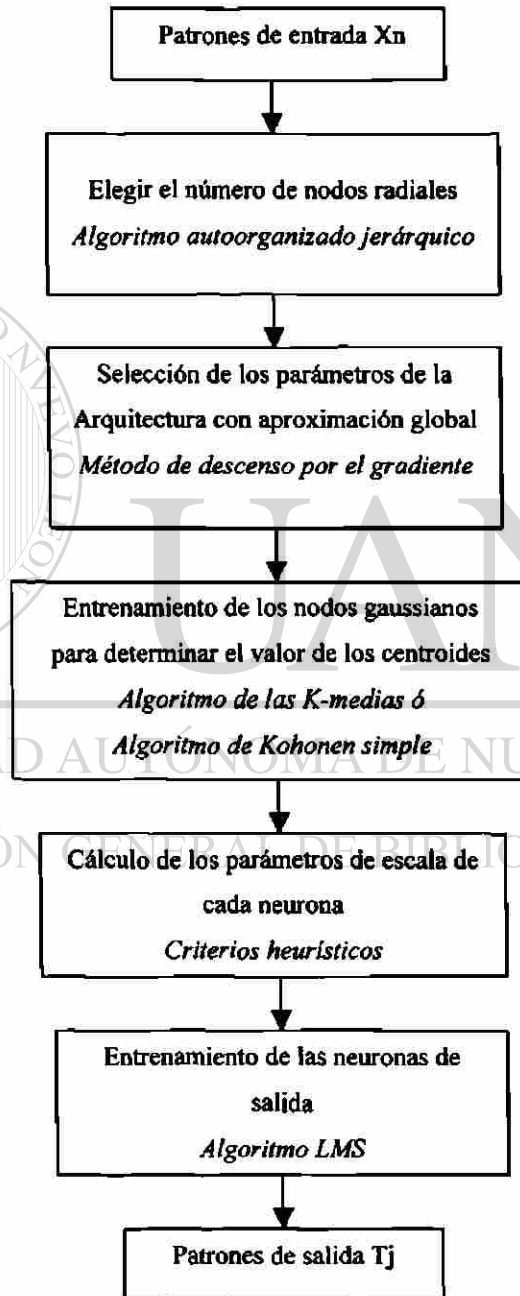


Fig. 3.10 Diagrama de flujo del proceso de entrenamiento de la RBF.

Un ejemplo simple del algoritmo RBF se puede plantear como un caso *XOR*, que es muy popular para un problema de clasificación no lineal; si se tiene como patrones de entrada (1,1), (0,1), (0,0) y (1,0), en un espacio de 2 dimensiones (ver Fig. 3.11), donde para las entradas (1,1) ó (0,0), se desea una salida binaria de 0 y para las entradas (0,1) ó (1,0) se desea una salida binaria de 1.




Fig. 3.11 Representación de 4 patrones de entrenamiento linealmente no separables.

El par de funciones de la capa oculta se escriben como:

$$\varphi_1 = e^{-\|x-t_1\|}, \quad t_1 = [1,1]^T \quad (3.26)$$

$$\varphi_2 = e^{-\|x-t_2\|}, \quad t_2 = [0,0]^T \quad (2.27)$$

donde  $t_1$  y  $t_2$  son los centros de las funciones gaussianas. Los patrones de entradas son mapeados en el plano  $\varphi_1$  y  $\varphi_2$  (ver Fig. 3.12). El mapeo no lineal en la capa oculta separa los patrones linealmente no separables a linealmente separables. El resultado se muestra en la Tabla 3.2 para los 4 patrones de entrada.



Tabla 3.2 Resultados del mapeo no lineal de la capa oculta.

Patrones X	$\varphi_1(x)$	$\varphi_2(x)$
(1,1)	1	0.1353
(0,1)	0.3678	0.3678
(0,0)	0.1353	1
(1,0)	0.3678	0.3678

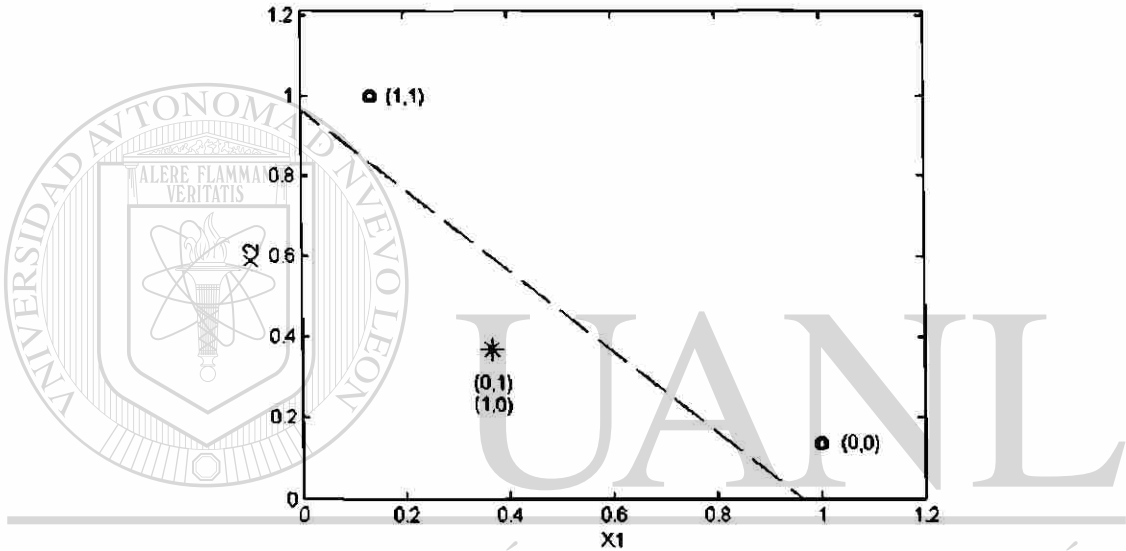


Fig. 3.12 Representación de los patrones linealmente separables.

## DIRECCIÓN GENERAL DE BIBLIOTECAS

La estructura óptima de la RBF se obtiene por la matriz  $G$  como:

$$G(\|x - t_i\|) = \exp(-\|x - t_i\|^2), \quad i = 1, 2. \quad (3.28)$$

La relación entre la entrada y la salida de la red se expresa como:

$$y(x) = \sum_{i=1}^2 w_i G(\|x - t_i\|) + b \quad (3.29)$$

$$y(x_j) = d_j, \quad j = 1 \dots 4; \quad (3.30)$$

donde  $b$  es el bias,  $x_j$  es el vector de entradas y  $d_j$  son los valores de las salidas deseadas. Los elementos de la matriz  $G$  son las salidas de la capa oculta correspondientes a los patrones de entrada. Estos elementos se calculan como:

$$g_{jk} = G(\|x_j - t_i\|), \quad j = 1 \dots 4; \quad i = 1, 2. \quad (3.31)$$

La siguiente ecuación matricial [34] muestra la relación de las salidas deseadas con la matriz  $G$  y los pesos asociados, donde los valores de la matriz  $G$  se obtienen sustituyendo los valores de la Tabla 3.2 en (3.32):

$$Gw = d \quad (3.32)$$

$$G = \begin{bmatrix} g_{11} & g_{12} & 1 \\ g_{21} & g_{12} & 1 \\ g_{31} & g_{32} & 1 \\ g_{41} & g_{42} & 1 \end{bmatrix} = \begin{bmatrix} 1 & 0.1353 & 1 \\ 0.3678 & 0.3678 & 1 \\ 0.1353 & 1 & 1 \\ 0.3678 & 0.3678 & 1 \end{bmatrix} \quad (3.33)$$

$$D = [1 \ 0 \ 1 \ 0]^T \quad (3.34)$$

$$W = [w \ w \ b]^T \quad (3.35)$$

Para obtener los pesos se debe calcular la pseudoinversa de la matriz  $G$  [34], debido a que la matriz no es cuadrada:

$$G^+ = (G^T G)^{-1} G^T d \quad (3.36)$$

donde  $G^T$  es la transpuesta de la matriz  $G$ , de tal forma los pesos se pueden calcular de forma matricial como:

$$w = G^+ d \quad (3.37)$$

Los valores de la matriz  $G$  son los siguientes:

$$G = \begin{bmatrix} 1.656 & -1.158 & -0.628 & -1.158 \\ 0.628 & -1.158 & -1.656 & -1.158 \\ 0.846 & -1.301 & 0.846 & -1.301 \end{bmatrix} \quad (3.38)$$

Finalmente, usando (3.33) y (3.38), los pesos pueden ser calculados. La salida de la RBF se muestra en la Fig. 3.13.

$$w = \begin{bmatrix} 2.284 \\ 2.284 \\ -1.692 \end{bmatrix} \quad (3.39)$$




Fig. 3.13 Representación de los patrones de salida deseados.

### 3.5 VENTAJAS DE LAS REDES RBF PARA SU CLASIFICACIÓN

Las redes neuronales de base radial son redes de ajuste funcional muy relacionadas, con arquitecturas en capas, unidireccionales y aproximadores universales. Una de las ventajas principales de la RBF es su rapidez de aprendizaje para su clasificación, aunque cuando se simula sobre sistemas serie (computadores convencionales) en fase de ejecución las RBF son mas lentas, debido a que normalmente precisan de un elevado número de nodos ocultos [34]. La razón es que las neuronas intermedias de las RBF actúan localmente, mientras que las de perceptrón multicapa (MLP) lo hacen globalmente, por lo que un nodo MLP cubre una mayor parte del espacio de entradas, requiriéndose por lo tanto menos nodos (hablando en términos generales). Recientemente se han demostrado la equivalencia de las RBF con un cierto tipo de lógica difusa [41].

### 3.6 PLANTEAMIENTO DEL ALGORITMO RBF

En general, el reconocimiento de patrones consiste en determinar si un elemento de una población  $P$  pertenece a una subpoblación  $S$  conocida. Cuando el reconocimiento de un elemento es sobre una clase única, el proceso se denomina identificación. Así mismo, el proceso de clasificación consiste en agrupar elementos en clases (subpoblaciones) de acuerdo a criterios de similaridad. De esta forma, el reconocimiento de patrones incluye los procesos de clasificación y reconocimiento. En la Fig. 3.14 se describe un conjunto de subpoblaciones  $S_1, \dots, S_4$  de una población  $P$ . A partir de un elemento  $x$ , sus atributos son “medidos” para generar un vector patrón, el cual es transformado y reducido en un conjunto de rasgos distintivos y el objeto es reconocido sobre la base de esta información.

Definiendo  $m_i, i = 1, \dots, P$  como las variables a medir de un elemento  $x$  para formar los vectores patrón; un extractor de rasgos distintivos  $T$  transforma el vector patrón  $m = (m_1, \dots, m_p)$  en un vector de rasgos distintivos  $X = (X_1, \dots, X_N) = T(m)$ . Por último, un reconocedor de patrones es un sistema que a partir de un vector de rasgos distintivos genera una salida que es una identificación única asociada con la clase a la

cual pertenece el objeto. De acuerdo a esto, el reconocimiento de patrones se puede llevar a cabo sobre atributos físicos y conceptos abstractos.

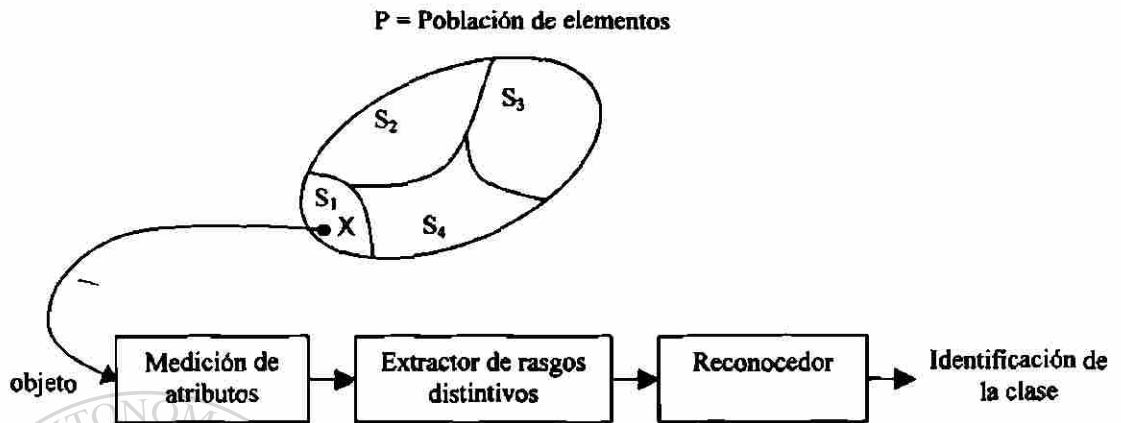


Fig. 3.14. Descripción del proceso de reconocimiento/clasificación.

De manera formal, en una población  $P$  de elementos no idénticos, cada elemento está representado por un vector patrón de mediciones de dimensión  $N$ . Estos vectores son convertidos en un conjunto de vectores de rasgos distintivos de dimensión  $N$ . Por tanto,  $P$  se puede representar mediante un conjunto de vectores de rasgos distintivos de dimensión  $N$ . Además, asuma que  $P$  es dividida en un conjunto de clases no conocidas  $S_1, \dots, S_k$ . En este caso, el problema de clasificación consiste en decidir si un conjunto de vectores de rasgos distintivos pertenece a una misma clase o clases diferentes. De igual forma, el problema de reconocimiento consiste en definir si un vector de rasgos distintivos es un vector representativo de una clase determinada. En la actualidad existen diferentes metodologías para reconocimiento y clasificación, cada una con distintas taxonomías y áreas de aplicación. En la Tabla 3.3 se enlistan los diferentes métodos de reconocimiento que se han desarrollado [32,51].

Uno de los métodos más recientes es el reconocimiento con redes de neuronas artificiales con estructura de propagación hacia delante. Este método consiste en un mapeo no lineal  $T$  sobre un cubo de dimensión  $N$  en un cubo de dimensión  $M$ :  $T: [a, b]^N \rightarrow [a, b]^M$ , es decir  $(x_1, \dots, x_N) \rightarrow (y_1, \dots, y_M)$ , donde  $a \leq (x_n, y_n) \leq b$ . Esto

significa que una red de neuronas con propagación hacia delante mapea vectores de entrada en vectores de salida,  $X \rightarrow Z$ , con las siguientes propiedades: (i) es un mapeo no lineal y (ii) es un mapeo estable en el sentido que si  $N: X^{(q)} \rightarrow Z^{(k(q))}$  y  $x$  es similar a  $X^{(q)}$ , entonces  $x$  será mapeado en un vector  $Z$ , muy similar a  $Z^{(k(q))}$ , es decir, errores pequeños son mapeados en errores pequeños. También es posible mapear un vector  $X'$ , diferente a  $X^{(q)}$  en un vector similar a  $Z^{(k(q))}$ .

Tabla 3.3 Métodos de reconocimiento de patrones.

- Decisión teórica
<ul style="list-style-type: none"> <li>Estadístico Paramétrico, no paramétrico, estimación Bayesiana.</li> </ul>
<ul style="list-style-type: none"> <li>Grafos</li> </ul>
<ul style="list-style-type: none"> <li>Basados en reglas Reglas lógicas binarias. Reglas difusas.</li> </ul>
<ul style="list-style-type: none"> <li>Autómatas Determinístico. Estocástico.</li> </ul>
<ul style="list-style-type: none"> <li>Redes neuronales recurrentes (Hopfield).</li> </ul>
<ul style="list-style-type: none"> <li>Mapas asociativos bidireccionales.</li> </ul>
- Mapas asociativos (redes neuronales y lógica difusa).
<ul style="list-style-type: none"> <li>Redes neuronales con propagación hacia delante. Redes multicapa. Redes de base radial.</li> </ul>
<ul style="list-style-type: none"> <li>Redes de auto-organización. Mapas de auto-organización. Algoritmos de agrupamiento difuso. Mapas difusos de auto-organización. Teoría de resonancia adaptiva.</li> </ul>
<ul style="list-style-type: none"> <li>Redes híbridas Aprendizaje de vectores de cuantización. Redes neuronales probabilísticas. Mapas asociativos difusos. Aprendizaje difuso de vectores de cuantización.</li> </ul>

En realidad, una red neuronal es un interpolador y extrapolador no lineal. Solo es necesario ajustar los pesos de interconexión apropiadamente para que la red sea capaz de mapear vectores de rasgos distintivos característicos de cierta clase en un vector identificador de salida de la clase correspondiente.

Para utilizar una red de neuronas como un reconocedor de patrones (Fig. 3.14), es necesario (a) obtener una muestra de  $Q$  vectores de rasgos distintivos  $S = \{X^{(1)}, \dots, X^{(Q)}\}$  que contenga uno o más elementos de  $k$  clases, (b) definir un conjunto de  $K$  vectores identificadores de salida  $\{t^{(1)}, \dots, t^{(K)}\}$  para las  $k$  clases y asociar un vector identificador con cada vector de rasgos distintivos para formar pares entrada/salida  $\{X^{(q)}, t^{(k(q))}\}$  y (c) ajustar los pesos de interconexión internos  $\{w_{nm} : n = 1, \dots, N, m = 1, \dots, M\}$  y de salida  $\{u_{mj} : m = 1, \dots, M, j = 1, \dots, J\}$  hasta que todos los vectores de entrada sean mapeados en los vectores identificadores correspondientes. La distancia en cada salida obtenida por la red  $Z^{(q)}$  y el vector identificador correspondiente  $t^{(k(q))}$  es denominado el error de clasificación  $\|Z^{(q)} - t^{(k(q))}\|$ , y debe ser menor que la distancia  $Z^{(q)}$  a cualquier otro vector de entrenamiento (incorrecto)  $t^{(p)}$ ; esto es,  $\|Z^{(q)} - t^{(k(q))}\| < \|Z^{(q)} - t^{(p)}\|$  para  $p \neq k$ .

El error medio cuadrático total se define  $E = \|Z^{(1)} - t^{(k(1))}\| + \|Z^{(Q)} - t^{(k(Q))}\|$ . El error medio cuadrático para un vector de entrada  $X^{(q)}$  es  $E^{(q)} = \|Z^{(q)} - t^{(k(q))}\|$ . Por lo tanto,

$$E = \sum_{q=1}^Q \|Z^{(q)} - t^{(k(q))}\|^2 = \sum_{q=1}^Q E^{(q)}.$$

La tercera etapa para diseñar un reconocedor de patrones utilizando redes neuronales no es un problema trivial. Como la red realiza un mapeo no lineal, no existe una manera analítica para determinar los pesos de interconexión que producen el mejor mapeo entrada/salida. Por lo tanto, es necesario implementar un método iterativo (regla delta generalizada, Levenberg-Marquardt, etc.).

Para un problema específico, existe un gran número de vectores de rasgos distintivos en  $k$  clases, lo que significa que diferentes vectores de rasgos distintivos de la  $k_i$  clase

tienen asociado un mismo vector de salida. El proceso de ajuste de los pesos de interconexión continua hasta que todas las entradas sean mapeadas en forma aproximada a los vectores identificadores de salida.

Una vez que la etapa de entrenamiento minimiza la función de error, la red neuronal puede ser utilizada en un modo operacional para mapear los vectores de rasgos distintivos de una población  $P$  (de donde se generaron los vectores de entrenamiento  $S$ ), en vectores identificadores de salida para las diferentes clases de la población. Este es el proceso de reconocimiento.

### 3.7 CONCLUSIONES DEL CAPÍTULO

Actualmente las redes neuronales se utilizan en la resolución de problemas complejos que no han sido bien resueltos mediante sistemas más tradicionales o cuyas soluciones son computacionalmente imprácticas. Debido a su capacidad de aprendizaje, robustez, no linealidad y tolerancia a la incertidumbre del entorno, las redes neuronales han demostrado ser útiles en aplicaciones diversas.


El proceso de aprendizaje de la RBF se efectúa en dos etapas, la primera es por medio de un algoritmo no supervisado y la segunda es de tipo supervisado, lo que permite acelerar el proceso de aprendizaje respecto al del BP, utilizado en las redes MLF.

Finalmente, las RBF tienen diversas aplicaciones para el reconocimiento de patrones debido a su simplicidad funcional, generalidad y rapidez de aprendizaje. El éxito de su rápido aprendizaje se debe a que las neuronas intermedias de la capa oculta actúan localmente mientras que las MLP lo hacen globalmente.



## CAPÍTULO 4

# ESQUEMA DE PROTECCIÓN DIFERENCIAL DE TRANSFORMADORES UTILIZANDO RBF



# UANL

### 4.1 INTRODUCCIÓN

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

®

Los esquemas de protección diferencial para transformadores de potencia han sufrido cambios importantes en cuanto a sus algoritmos. La finalidad principal de estos esquemas es operar cuando ocurra una falla dentro de su zona protegida y debe impedir la operación incorrecta en caso de una condición de *inrush* debido a la no linealidad de los núcleos de los transformadores y condiciones de sobreexcitación en el transformador.

Las RNA son capaces de reconocer y almacenar los rasgos distintivos de un grupo de patrones de información que corresponden a distintas condiciones o situaciones de un problema. Con esta información una RNA puede procesar un patrón distinto, que no haya presentado antes, y determinar las características del patrón (clasificación) o identificar el tipo de información (reconocimiento).

Por tanto, la aplicación de RNA de base radial es factible para implementar una protección diferencial de transformadores que tenga como principio de operación caracterizar el comportamiento de la corriente diferencial entre una falla interna o una condición de *inrush*. En este capítulo se describe el planteamiento del problema, la selección de la estructura de la red, la definición de los patrones de entrenamiento, la metodología para el entrenamiento y el análisis del desempeño de la red.

#### 4.2 DISCRIMINACIÓN ENTRE CORRIENTES DE MAGNETIZACIÓN Y DE CORTOCIRCUITO UTILIZANDO RBF

La discriminación entre corrientes de *inrush* y de cortocircuito puede plantearse como un problema de reconocimiento de patrones, siendo factible la utilización de redes neuronales de base radial. En el capítulo 2 se describió el comportamiento de la corriente en un transformador durante la energización del equipo, y ante una condición de cortocircuito; las diferencias en el contorno de la forma de onda de estas dos corrientes son originadas por el nivel de la componente aperiódica de CD y el contenido armónico presente en la corriente [16]. La idea básica para el reconocimiento de patrones, se basa en caracterizar la corriente de cortocircuito con una forma de onda altamente simétrica (Fig. 4.1), con un bajo contenido de armónicas y un nivel variable de la componente aperiódica de CD, y la corriente de *inrush* con una forma de onda asimétrica, con un grado severo de distorsión debido a la presencia armónicas y a un alto nivel de la componente aperiódica de CD (Fig. 4.2).

El comportamiento de la corriente de *inrush* y de cortocircuito puede apreciarse tanto en la corriente primaria como en la corriente secundaria del transformador. No obstante, es conveniente utilizar como base del algoritmo la corriente diferencial definida como,  $I_d = I_1 - I_2$  donde  $I_1$  e  $I_2$  son las corrientes por secundario de los TC's. Esta corriente es la corriente de operación ( $I_{OP}$ ) utilizada en los relevadores de porcentaje diferencial. Al utilizar esta corriente, se está cancelando implícitamente el efecto de la carga, por lo que el algoritmo es sensible a las componentes transitorias de la corriente.




Fig. 4.1 Representación de la corriente de cortocircuito en un transformador de potencia.




Fig. 4.2 Representación de una corriente de inrush en un transformador de potencia.

### 4.3 SELECCIÓN DE LA ESTRUCTURA DE LA RED

La selección de la estructura de la RNA es básicamente heurística y depende del nivel de complejidad del problema. La estructura típica recomendada en la literatura [34,40,49] consiste de una red de tres capas; la primera capa o capa de entrada consiste en los nodos donde la red recibe la información que va a procesar, la segunda capa o

capa oculta es un grupo de neuronas que realizan la función de extraer los rangos distintivos de la información de entrada y la tercera capa o capa de salida, que consiste en otro grupo de neuronas (por lo general menor con respecto a la segunda capa), que realizan las funciones de clasificación y reconocimiento.

Esta estructura ha sido ampliamente utilizada, ya que permite asociar grupos de patrones en regiones de decisión definidas por los pesos de interconexión de la red, lo que facilita las tareas de clasificación y reconocimiento. En caso de que la complejidad de los patrones de información requiera de un mayor número de regiones de decisión para su entrenamiento, solo es necesario incrementar el número de neuronas en la red. Por estas razones se seleccionó una red con una estructura de tres capas para esta aplicación.

Las neuronas de la red fueron implementadas utilizando funciones de activación tipo gaussiana (RBF), ya que su rapidez de aprendizaje para clasificación es mucho mejor que otras funciones. La razón principal de utilizar este tipo de función de activación es que actúan localmente, mientras que otras funciones actúan globalmente, por lo que requieren menos neuronas en la capa oculta.

El número de unidades en la capa oculta está directamente relacionado con la capacidad de almacenamiento de información en la red. Para que el comportamiento de la red sea apropiado (esto es, sea capaz de generalizar), se tiene que determinar el número de neuronas de la capa oculta. Esto se realizó mediante el método de regularización [34].

La solución de problemas reales utilizando redes neuronales usualmente requiere de redes con un alto número de neuronas interconectadas entre sí, lo que provoca que el entrenamiento converja lentamente a una solución. Esto conlleva a tratar de minimizar el tamaño de la red neuronal manteniendo un buen desempeño. Sin embargo, entre más pequeña sea la red, el proceso de entrenamiento se dificulta pudiendo no llegar a una

solución (falta de memoria, asociada al número de interconexiones). El método utilizado para la obtención de la red neuronal óptima para el problema en cuestión es el de reducción de la red (*Network Pruning*) que consiste en formar la red con un gran número de conexiones entre las neuronas (adecuadas para resolver el problema en estudio) y después reducirla basándose en la debilidad o eliminación de ciertos pesos de forma ordenada y selectiva. Para nuestro problema nos enfocamos en la aproximación basada sobre la forma de *regularización*.

Las técnicas de *regularización* abordan el problema introduciendo restricciones que implican que el mapeo que implementa la red neuronal sea más suave, es decir, que a entradas similares haga corresponder resultados próximos. Las restricciones pueden ser incluidas en la función en forma de términos adicionales  $\phi(w_\alpha)$  (siendo  $w_\alpha$  los pesos de interconexión, que miden la desviación de los resultados actuales respecto de la restricción planteada. La representación que es usada para el entrenamiento de redes FFNN se expresa en la siguiente ecuación:

$$E[w_\alpha] = \frac{1}{2} \sum_{\mu} \sum_k [t_k^\mu - F_k^\mu(x)]^2 + \lambda \sum_{\alpha} \phi(w_\alpha) \quad (4.1)$$

siendo  $\lambda$  el parámetro de regularización, que controla el compromiso entre el grado de suavidad de la función frente al nivel de ajuste de los datos de entrenamiento que alcanza. Una de las restricciones que pueda introducirse es que los pesos sean de tamaño reducido, evitando que crezcan indefinidamente; en este caso se elige una función de regularización de la forma  $\phi(w_\alpha) = (w_\alpha)^2$ , lo que conduce a una regla que implementa el decaimiento numérico de los pesos.

#### 4.4 PATRONES DE ENTRENAMIENTO DE LA RBF

Existen dos fases en toda aplicación de las redes neuronales: la fase de aprendizaje o entrenamiento y la fase de prueba. En la fase de entrenamiento, se usa un conjunto de datos o patrones de entrenamiento para determinar los pesos (parámetros de diseño) que

definen el modelo neuronal. Una vez entrenado este modelo, se usará en la llamada fase de prueba o funcionamiento directo, en la que se procesan los patrones de prueba que constituyen la entrada habitual de la red, analizándose de esta manera las prestaciones definitivas de la red.

Los patrones de entrenamiento fueron generados a partir de simulaciones mediante los programas de computadora digital desarrollados en MATLAB® y en ATP. Un enfoque general en esta tesis es utilizar patrones de entrenamiento simples y representativos, con el fin de evaluar la red neuronal de base radial ante señales de entrada con distintos grados de contaminación, con la intención de evaluar la capacidad de generalización de la RNA para esta aplicación.

En la generación de patrones de entrenamiento, se crearon dos grupos de patrones, uno de ellos se generó a través de un modelo matemático de transformador monofásico con capacidad de 35 kVA, desarrollado en MATLAB® con relación de transformación 7620 V/120 V. El otro grupo se generó a través del programa ATP [45] utilizando un modelo de transformador de 5 MVA con una relación de transformación de 115 KV/13.8 KV.

La formulación del modelo matemático se muestra en el apéndice A, y los parámetros eléctricos se muestran en el apéndice B al final de la tesis. En la Fig. 4.3, se muestra el sistema de potencia de prueba.

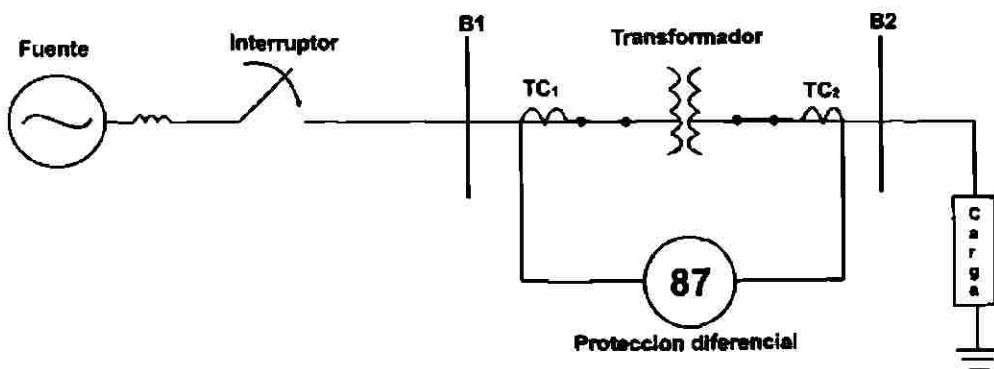


Fig. 4.3 Sistema de potencia de prueba.

Con respecto a la dimensión de los patrones de entrenamiento, se decidió en forma empírica utilizar los dos primeros ciclos al inicio de la simulación de la corriente diferencial de error entre los transformadores de corriente. Esta corriente corresponde a la corriente de operación disponible en un relevador de porcentaje diferencial. Para una frecuencia de muestreo de 1920 Hz, se tienen 32 muestras por ciclo de la corriente diferencial y por tanto, la dimensión de cada patrón es de 64 muestras de corriente; de esta forma, el número de entrada a la RNA (primera capa) es de 64.

Cada grupo de patrones de información se conforma a través de la simulación de cuatro casos de operación del transformador. El primer caso es energizar el transformador con carga, para ello se consideró cargas resistivas conectadas en el secundario del transformador. El segundo caso es energizar el transformador sin carga, donde la corriente diferencial es básicamente la corriente primaria en el transformador. El tercer caso es la ocurrencia de un cortocircuito en el secundario al energizar el transformador. En el último caso se aplica una depresión del voltaje en el lado primario con el transformador operando en estado estable, lo que provoca la aparición transitoria de una corriente de *inrush*.

En los cuatro casos descritos, cada condición (la energización del transformador, la ocurrencia del cortocircuito y la depresión de voltaje) se simuló 16 veces durante un ciclo de voltaje de 60 Hz (cada 22.5°). El total de patrones de entrenamiento para el caso de estudio de los dos grupos fue de 128 patrones, los cuales son los más representativos para los diferentes casos que se presentan en el trabajo.

#### 4.4.1 ETAPAS DE PRE-PROCESAMIENTO

En general, un relevador digital se compone de tres subsistemas:

- Acondicionamiento de las señales de entrada.
- Conversión A/D.
- Procesamiento digital.

Los dos primeros subsistemas son comunes en cualquier tipo de relevadores digitales y el tercero tiene características particulares en dependencia del tipo de relevador. En la Fig. 4.4 se indican los componentes básicos de un relevador digital [30,31].

Cada una de las etapas indicadas en la Fig. 4.4 tienen un efecto en la operación del relevador; en el caso de las etapas de filtrado, se introduce un retardo de tiempo en la operación del relevador en función del tipo y grado de filtrado que se requiere, en dependencia de las funciones del relevador.

El filtrado analógico *anti-aliasing* tiene la función de remover las componentes de alta frecuencia antes de la etapa de conversión analógica/digital a fin de eliminar el problema de *aliasing* en la señal que se va a muestrear [33,50].

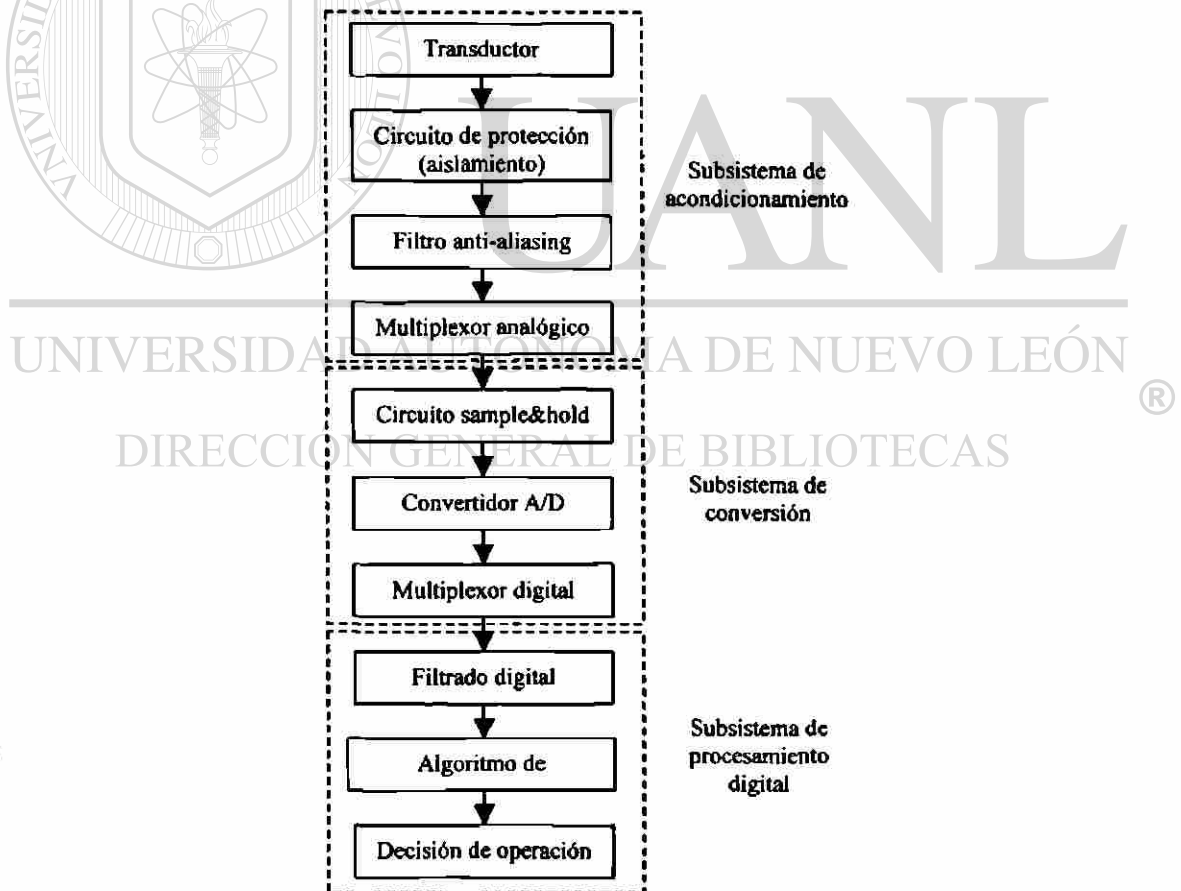


Fig. 4.4. Componentes básicos de un relevador digital.



La Fig. 4.5 muestra el espectro de frecuencias de la señal de corriente primaria de un transformador durante una falla antes y después de la etapa de filtrado *anti-aliasing*, donde se observa la modificación del espectro de frecuencias; en este caso la simulación se realizó con un filtro pasabajo tipo *Butterworth* de 2° orden con una frecuencia de corte de 360 Hz.

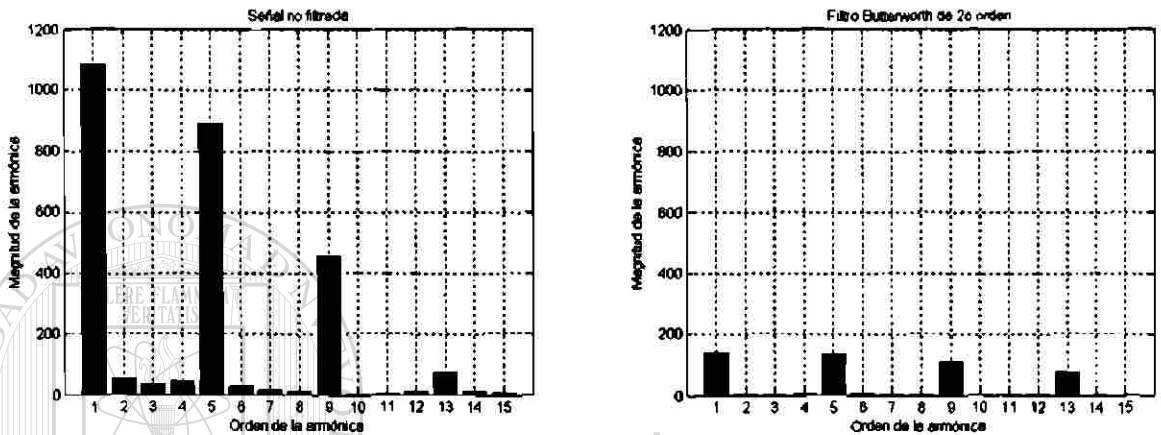


Fig. 4.5 Comparación del espectro de frecuencia de la corriente primaria de un transformador durante una falla.

Para evaluar estos efectos el proceso de generación de patrones incluye las etapas de filtrado analógico *anti-aliasing* y la conversión analógica/digital, antes de calcular la corriente diferencial utilizada como base de operación del algoritmo propuesto (ver Fig. 4.6).




Fig. 4.6 Etapas del procesamiento de la señal antes del entrenamiento de la RBF.

La Fig. 4.7 muestra una sección de corriente diferencial donde se utiliza una ventana de datos de 2 ciclos, para ser procesada a la entrada de la RNA de base radial como se había mencionado en la sección 4.4.




Fig. 4.7 Sección de corriente diferencial utilizada para el entrenamiento de la RBF.

#### 4.4.2 NORMALIZACIÓN

Las señales de corriente diferencial en el transformador se calculan como secuencias de muestras correspondientes a una frecuencia de muestreo de 19.2 KHz, que es suficientemente alta para simular el carácter analógico de las señales. Estas señales analógicas provienen de la corriente primaria y secundaria de los transformadores de corriente. Las señales analógicas ( $I_p$  y  $I_s$ ) son aplicadas al modelo digital de un filtro *anti-aliasing* (*Butterworth* de segundo orden con una frecuencia de corte de 360 Hz). Posteriormente ambas señales son diezmadadas (razón 1/10) para simular el proceso de muestreo a una frecuencia de 1920 Hz; después se obtiene la corriente diferencial expresada como la suma vectorial de ambas corrientes. Por último se escoge una apropiada normalización con el fin de hacer una diferencia significativa de las señales, para facilitar la interpretación de los resultados.

El objetivo de la normalización es restringir los valores máximos de corriente en un rango [-1, +1], a fin de facilitar la operación de la red en el reconocimiento de patrones; esto tiene la ventaja de que la red una vez entrenada, puede ser utilizada en cualquier transformador, siempre y cuando las señales de corriente se normalicen entre [-1 y +1]. Para cada grupo de patrones de entrenamiento, se halla el valor máximo y mínimo de todo el conjunto y cada patrón se normaliza usando la ecuación 4.2. El rango de normalización de las entradas para los patrones de entrenamiento será [-1 y +1].

$$\text{ValorNormalizado} = \frac{(\text{ValorActual}) - (\text{ValorMinimo})}{(\text{ValorMaximo}) - (\text{ValorMinimo})} \quad (4.2)$$

#### 4.5 METODOLOGÍA PARA EL ENTRENAMIENTO DE LA RED

Para que la red neuronal aprenda una cierta relación entrada-salida, debe presentársele patrones bien establecidos y definidos como un conjunto que describen dicha relación. Este conjunto de patrones consta de vectores de entrada y de salida asociados, ya que el conjunto de entrenamiento debe describir plenamente el intervalo de entradas esperadas y de salidas deseadas. El entrenamiento de la RNA de base radial se ejecuta en este trabajo mediante el algoritmo de redes hacia delante (*Feed Forward Neural Network*), con factor de aprendizaje adaptivo, y las redes se implementan mediante el “*Neural Network Toolbox*” de MATLAB®.

Una vez definidas las entradas a la RNA se aplicó el método de reducción de la red *Network Prunning* para determinar la estructura óptima. Se partió de una red con una estructura de 64 neuronas en la primera capa y una neurona en la segunda capa. Esta estructura se debe a que el algoritmo *Network Prunning* establece que la capa oculta debe iniciar con un número de neuronas igual al número de entradas a la red. La información de entrada que se utiliza para reducir la red es la misma que servirá como base para el entrenamiento de la RNA para la discriminación entre cortocircuitos y condiciones de *inrush*, la cual se describe en la siguiente sección.

El algoritmo de *Network Prunning* se puede resumir en los siguientes pasos [34]:

1. Se inicia con una topología de una sola capa oculta con un número  $N$  de neuronas, igual al número de entradas a la red .
2. Se especifica el algoritmo de entrenamiento de la RNA, así como la tolerancia de error deseada ( $1 \times 10^{-7}$ ), el número máximo de iteraciones y la función de activación (gaussiana).
3. Se entrena la RNA utilizando el algoritmo de Levenberg-Marquardt, que asegura convergencia en un mínimo global.
4. Terminado el entrenamiento, se analizan las matrices de pesos; se descartan las interconexiones de valor nulo (no tienen efecto en la salida de la red) y se determina el nuevo número de neuronas de la capa oculta.
5. Se hacen pruebas de desempeño a la RNA resultante, utilizando patrones diferentes a los de entrenamiento para evaluar la capacidad de generalización. Si los resultados son positivos, esta es la estructura adecuada.
6. En caso contrario se debe considerar diferentes entradas de información a la red y repetir el algoritmo de regularización.

La estructura óptima de la red obtenida por este procedimiento se indica en la Fig. 4.8; ésta consiste de dos capas de neuronas, tres neuronas en la capa oculta y una en la capa de salida, debido a que se trata de una decisión binaria (bloqueo, no bloqueo).




Fig. 4.8 Estructura de la RNA de base radial para el entrenamiento y clasificación.

El aprendizaje de la RBF de base radial depende de tres diferentes algoritmos y se basan en como encontrar los centros de la función de base radial. El primer algoritmo consiste en que las muestras en el entrenamiento se seleccionan como los centros de la función, y los pesos de la capa oculta son calculados para minimizar el error entre la salida deseada y la salida actual de la red. El segundo algoritmo consiste en estimar la localización aproximada para los centros de la función de base radial en la capa oculta usando las *k*-means (valores medios) en el algoritmo, por lo tanto se completa la designación para la red por estimación de los pesos lineales de la capa de salida. El tercer algoritmo consiste en un proceso de correlación de error en el aprendizaje, el algoritmo usa el método del gradiente descendiente para minimizar el error de la salida.

En general, las RBF construyen una aproximación local con un mapeo no lineal entre las entradas y salidas deseadas.

#### **4.6 METODOLOGÍA PARA ANALIZAR EL DESEMPEÑO DE LA RED**

Para evaluar y analizar el desempeño de la red, una primera prueba aplicada consiste en presentarle los patrones de entrenamiento como patrones de entrada. El objetivo principal de esta prueba es evaluar la capacidad de reconocimiento y aprendizaje de la red. Posteriormente se le presentan a la red patrones de prueba que no pertenecen al conjunto de patrones con los que se entreno, con el objetivo de evaluar su capacidad de generalización. Los conjuntos de patrones de prueba para cada red son independientes y el número de ellos está en función del aspecto a evaluar y del número de patrones utilizados en el entrenamiento. Esto se describe en el capítulo 5.

#### **4.7 CONCLUSIONES DEL CAPÍTULO**


El uso de la RBF es factible en la protección diferencial de transformadores para discriminar entre una condición de cortocircuito y una de *inrush* utilizando la corriente diferencial.

La estructura de RNA de base radial se definió por tres capas, la primera capa o capa de entrada (información pre-procesada), la segunda capa o capa oculta (extracción de rangos distintivos) y la capa de salida (clasificación y reconocimiento). Se decidió en forma empírica la dimensión de los patrones de entrenamiento (dos ciclos de la corriente diferencial), por lo tanto la estructura de la red es de 64 entradas en la capa de entrada, tres neuronas en la capa oculta y una en la capa de salida, debido a que se trata de un decisión binaria (operación o no operación).

La formación de los patrones de entrenamiento se obtuvieron por simulación digital. Se crearon dos grupos de entrenamiento, el primer grupo se generó en el programa MATLAB® donde se desarrolló un modelo de transformador monofásico y el otro grupo de patrones se generó a través del programa de simulación ATP. Se consideraron cuatro casos de operación del transformador (energización con carga y sin carga, cortocircuito en el secundario y depresión de voltaje en el lado primario). Cada una de las cuales se simuló 16 veces un ciclo de voltaje de 60 Hz, generando 128 patrones de entrenamiento para la RBF.

## CAPÍTULO 5

# RESULTADOS



### 5.1 INTRODUCCIÓN

# UANL

En el capítulo anterior se propuso el esquema de protección diferencial de transformadores utilizando redes neuronales de base radial (RBF), se describió el proceso de formación de patrones de entrenamiento, y la metodología para el entrenamiento de la red.

En el presente capítulo se muestran los resultados de validación realizadas al algoritmo de protección diferencial basado en redes neuronales de base radial. Con el objetivo de evaluar la capacidad de generalización de la RNA para esta aplicación, se mostrarán los resultados de los 2 grupos de patrones de entrenamiento de acuerdo al análisis del desempeño de la red.

Así mismo, se analiza un caso real de la operación incorrecta de la protección diferencial de un transformador de 60MVA debido a la corriente de *inrush*, el cual ocurrió en Colombia en el 2003.

## 5.2 METODOLOGÍA DE EVALUACIÓN

El proceso para evaluar la RNA de base radial propuesta en este trabajo como algoritmo de protección diferencial de transformadores, se puede ver en el diagrama de flujo que se muestra en la Fig. 5.1. Para la preparación de los patrones de entrenamiento se simularon señales analógicas de corriente, para ello se utilizó un paso de integración de  $52.08333 \mu s$ , que representa una frecuencia de muestreo de 19.2 KHz y da lugar a 320 muestras por ciclo.

Las señales de corriente primaria y secundaria ( $I_p$  e  $I_s$ ) pasan por un filtro analógico *anti-aliasing* pasabajos con la finalidad de eliminar el problema de *aliasing* durante el proceso de muestreo [46]. El filtro analógico utilizado es el filtro de *Butterworth* de segundo orden con una frecuencia de corte de 360 Hz.

La siguiente etapa es simular un diezmado de razón 1/10 como conversión analógica/digital, lo que da lugar a un muestreo de 32 muestras por ciclo, correspondientes a una frecuencia de muestreo de 1920 Hz.

Posteriormente se calcula la corriente de operación del relevador para cada muestra de la corriente primaria y secundaria previamente diezmada. Después de obtener la corriente de operación de todos los patrones de entrenamiento, se prosiguió a normalizar las señales, esto con el fin de restringir los valores máximos y mínimos de la corriente diferencial a un rango  $[-1 +1]$ , con la ventaja de que una vez entrenada la red pueda ser utilizada en cualquier otro transformador siempre y cuando las señales de corriente se normalicen con el mismo rango.



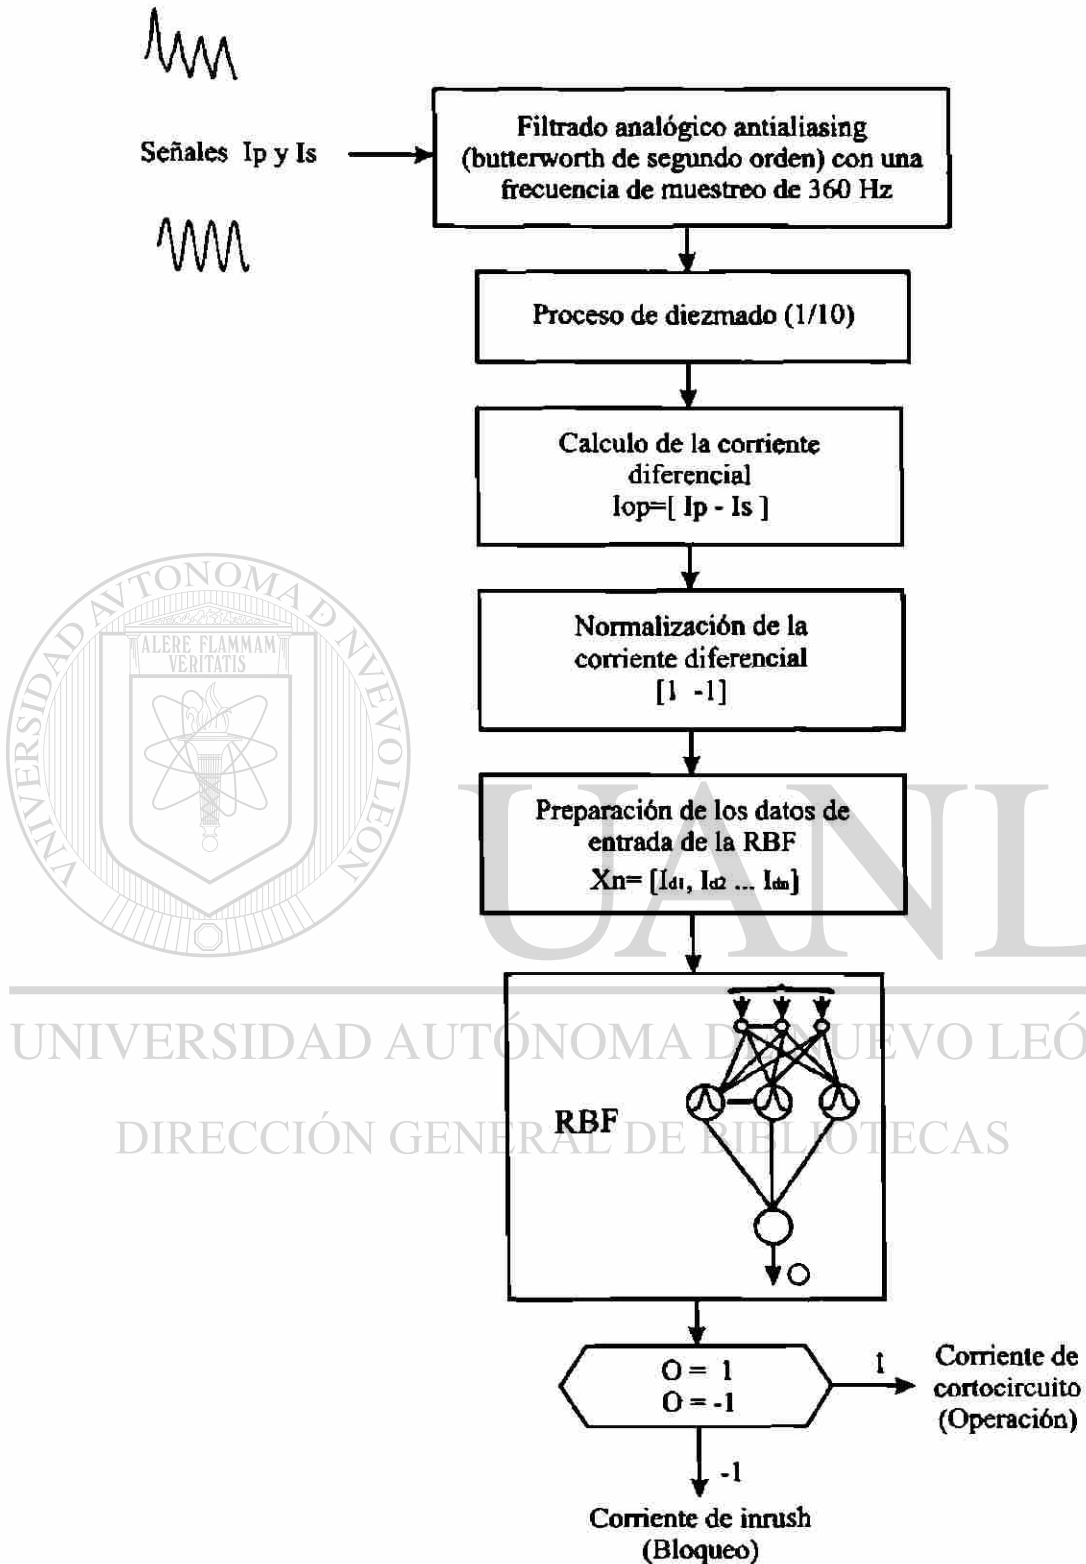


Fig. 5.1 Diagrama de flujo del algoritmo de protección diferencial utilizando RBF.

La representación de las entradas a la red  $p_j$ , ( $j=1,2,\dots,n_e$ ) y las salidas deseadas  $d_j$ , [20], se representan en forma matricial como:

$$P = \begin{bmatrix} p_{11} & p_{12} & p_{13} & \bullet & p_{1n_e} \\ p_{21} & p_{22} & p_{23} & \bullet & p_{2n_e} \\ \bullet & \bullet & \bullet & \bullet & \bullet \\ p_{n_e1} & p_{n_e2} & p_{n_e3} & \bullet & p_{n_en_e} \end{bmatrix} \quad (5.1)$$

$$D = \begin{bmatrix} d_{11} & d_{12} & d_{13} & \bullet & d_{1n_e} \\ d_{21} & d_{22} & d_{23} & \bullet & d_{2n_e} \\ \bullet & \bullet & \bullet & \bullet & \bullet \\ d_{n_e1} & d_{n_e2} & d_{n_e3} & \bullet & d_{n_en_e} \end{bmatrix} \quad (5.2)$$

donde  $n_e$  es el número de entradas a la red,  $n_o$  son las salidas deseadas y  $n_e$  son los patrones de entrenamiento.

El número total de patrones utilizados es de 168, de los cuales 128 son los patrones utilizados en la etapa de entrenamiento y 40 patrones de prueba que no habían sido analizados por la red previamente. De esta forma, la matriz de datos de entrada que describe el comportamiento de la corriente diferencial tienen dimensiones de (64x128), en la etapa de entrenamiento con un vector de salidas deseadas de (1x128). Las 2 matrices correspondientes a los patrones de prueba utilizados para evaluar y analizar el desempeño de la red tienen dimensiones de (64x20), cada una con un vector de salidas deseadas de (1x20).

### 5.3 ANÁLISIS DEL DESEMPEÑO DE LA RBF

Para evaluar y analizar el desempeño de la red se presentaron los patrones de entrenamiento como patrones de entrada. En la Tabla 5.1 se muestra la descripción de cada caso, así como el número de patrones de entrenamiento de la RBF.

Tabla 5.1 Descripción de los casos de operación simulados.

Caso	Descripción de la operación del transformador	Patrones
A	Energización con carga	16
B	Energización sin carga	16
C	Energización con cortocircuito en el lado secundario	16
D	Estado estable con depresión de voltaje en el lado primario	16

Los 16 patrones de cada caso, corresponden a la simulación del transitorio en 16 instantes de tiempo, uniformemente espaciados, en la onda de voltaje.

Adicionalmente, los 40 patrones de prueba adicionales, que no pertenecían al conjunto de patrones con los que se entreno la RNA, se simularon con los mismos modelos de transformadores y los mismos casos de operación del transformador, pero con diferente instante de simulación con respecto al ciclo de voltaje de 60 Hz; el objetivo es analizar el comportamiento de la red ante patrones diferentes a los del entrenamiento y evaluar así la capacidad de generalización de la RBF. La tabla 5.2 describe estos 40 patrones de prueba.

Tabla 5.2 Descripción de los patrones de prueba.

Casos	MATLAB	ATP	Ángulos de simulación
	Patrones de prueba		
A	5	5	56.25°, 191.25°, 258.75°, 281.25°
B	5	5	56.25°, 191.25°, 258.75°, 281.25°
C	5	5	56.25°, 191.25°, 258.75°, 281.25°
D	5	5	56.25°, 191.25°, 258.75°, 281.25°

### 5.3.1 PRIMER GRUPO DE PATRONES DE ENTRENAMIENTO Y PRUEBA

#### a) Origen de los patrones de entrenamiento y prueba

El primer grupo de patrones de entrenamiento y prueba son generados por simulación, con el modelo de transformador desarrollado en MATLAB (ver apéndice A). El transformador tiene una capacidad de 35 KVA y su relación de transformación es de 7620 V/120 V, los parámetros se encuentran en el apéndice B.

#### b) Primer grupo de patrones de entrenamiento

La Fig. 5.2 muestra las señales de corriente de operación normalizadas, correspondientes a los cuatro casos de operación del transformador obtenidos por simulación, con distintos instantes de tiempo de simulación de la onda de voltaje para cada uno de los casos.

En la Fig. 5.2 se puede apreciar la complejidad de las formas de onda de la corriente de operación para los 4 casos descritos en la tabla 5.1. Los casos A y B tienen formas de ondas mis parecidas, sin embargo se observa una diferencia significativa en la parte superior e inferior de las gráficas, debido a la carga considerada para el caso A. Las formas de onda para el caso C se aprecian altamente simétricas, debido a las condiciones de cortocircuito en el secundario del transformador, mismas que se caracterizan de esta forma. Finalmente, para el caso D se observa que las formas de onda son asimétricas, debido a la corriente de *inrush* originada por la depresión de voltaje en el lado primario.

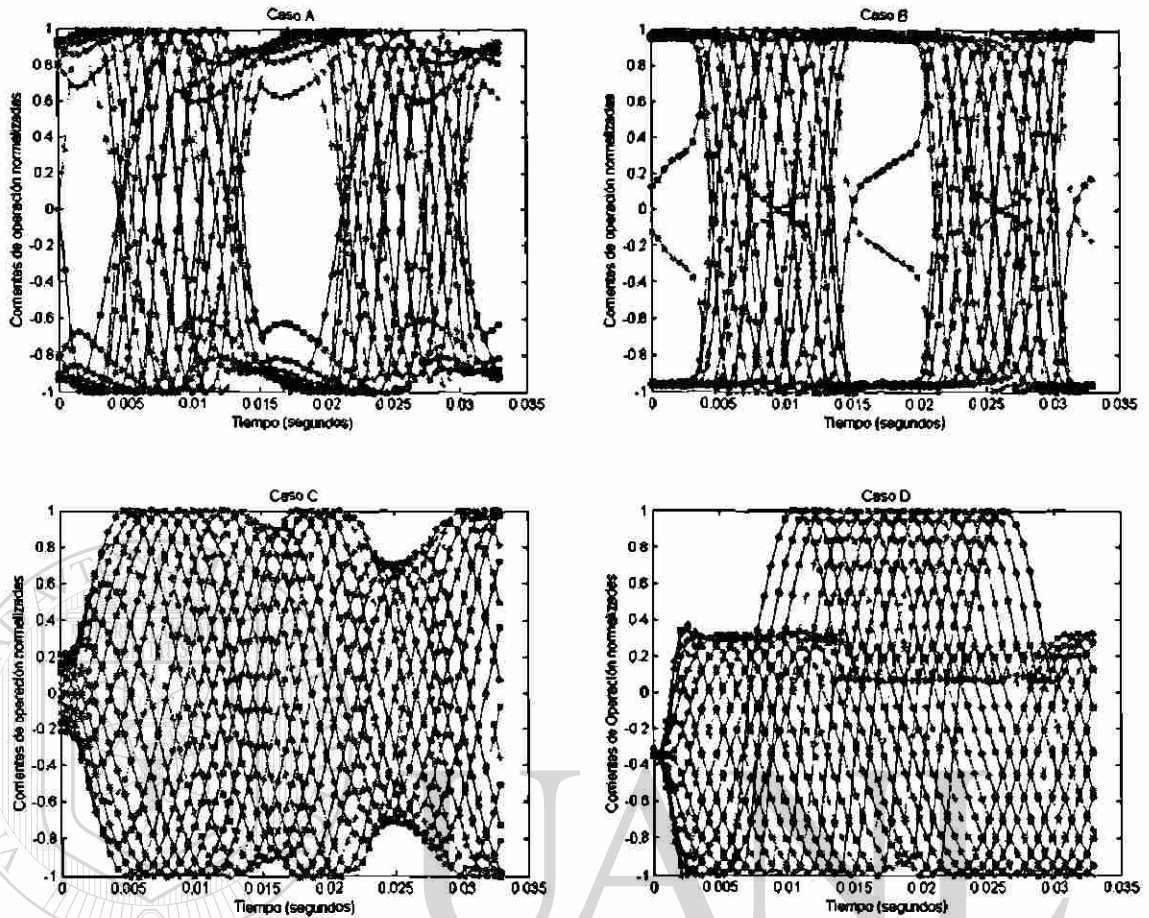


Figura 5.2 Primer grupo de patrones de entrenamiento correspondiente a los casos A,B,C y D.

### c) Salida de la red con los patrones de entrenamiento

La matriz de entrada del primer grupo de entrenamiento es de dimensión  $(64 \times 64)$ , donde las filas son las entradas a la red (64) y las columnas son los patrones de entrenamiento (64). Los primeros 32 patrones de entrenamiento que se muestran a la salida de la red (caso A y B), corresponden a formas de onda de la corriente de operación ocasionadas por energizaciones, los patrones del 33 al 48 (caso C) corresponden a formas de onda debido a cortocircuitos en el secundario del transformador y los patrones del 49 al 64 (caso D) corresponden a los casos de depresión del voltaje en el lado primario del transformador.

La Fig 5.3 muestra la salida de la RBF para el primer grupo de patrones de entrenamiento, donde la salida  $-1$  corresponde a la condición de no operación (*inrush*) y la salida  $+1$  corresponde a la condición de operación (cortocircuito).

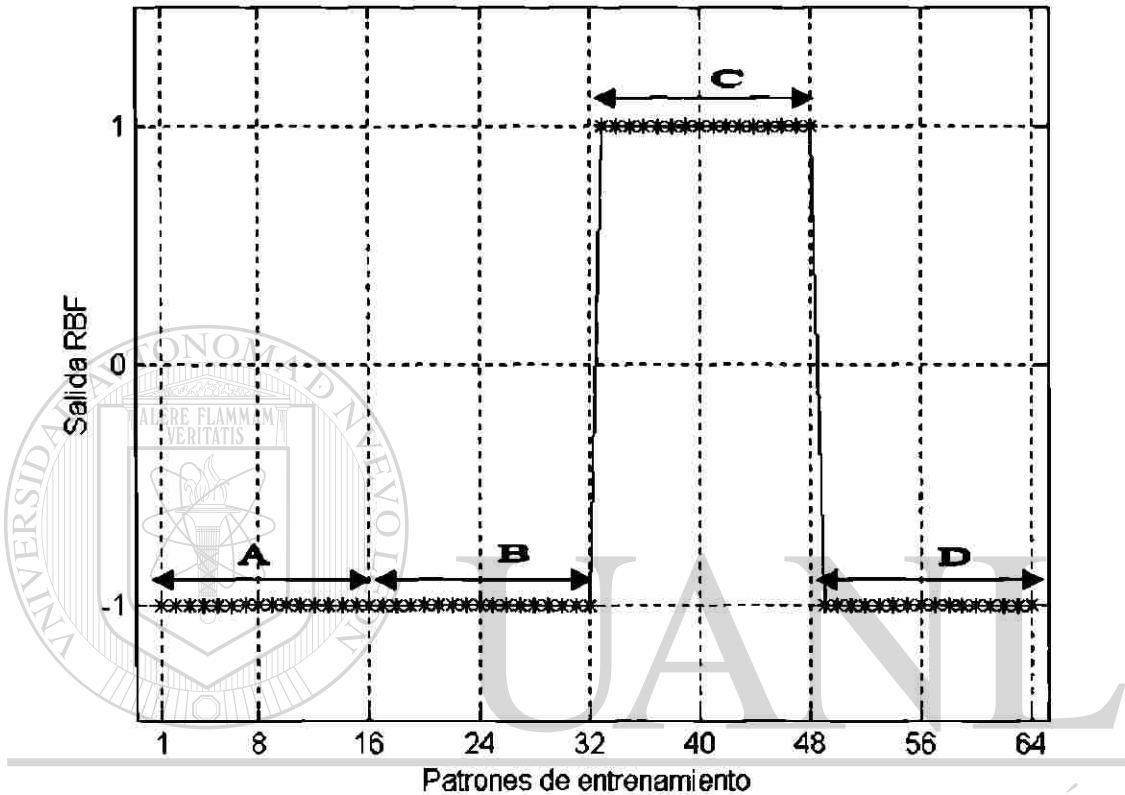


Fig. 5.3 Respuesta de la RBF con el primer grupo de patrones de entrenamiento.

DIRECCIÓN GENERAL DE BIBLIOTECAS

#### d) Primer grupo de patrones de prueba

Los patrones de prueba son generados con el modelo de transformador desarrollado en MATLAB, se generaron 5 patrones de prueba para cada caso, utilizando los 2 primeros ciclos de la corriente de operación al igual que en los patrones de entrenamiento. La Fig. 5.4 muestra los patrones de prueba normalizados, que fueron simulados considerando los casos de operación del transformador descritos en la tabla 5.1. Los instantes de simulación se indican en la tabla 5.2.




Figura 5.4 Primer grupo de patrones de prueba correspondiente a los casos A,B,C y D.

### e) Salida de la red con los patrones de prueba

La matriz de entrada de los patrones de prueba es de dimension  $(64 \times 20)$ . Donde las filas son el número de entradas a la red (64) y las columnas son los patrones de prueba (20). Los primeros 10 patrones de prueba mostrados en la salida de la red (caso A y B), corresponden a formas de onda de la corriente de operación ocasionadas por energizaciones, los patrones del 11 al 15 (caso C) corresponden a formas de onda debido a cortocircuitos en el secundario del transformador y los patrones del 16 al 20 (caso D) corresponden a los casos de depresión de voltaje en el lado primario del transformador.

La Fig 5.5 muestra la salida de la RBF de los patrones de prueba. Se puede apreciar que el resultado obtenido exhibe una excelente respuesta de la red.

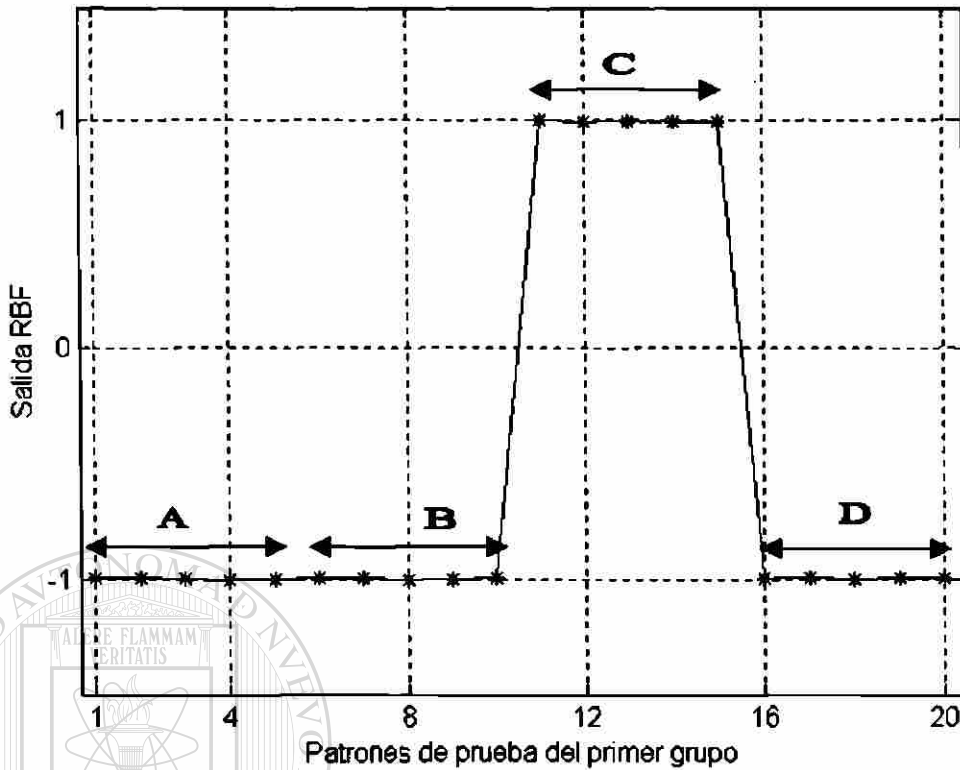


Fig. 5.5 Respuesta de la RBF del primer grupo de patrones de prueba.

### 5.3.2 SEGUNDO GRUPO DE PATRONES DE ENTRENAMIENTO Y PRUEBA

#### a) Origen de los patrones de entrenamiento y prueba

El origen del segundo grupo de patrones de entrenamiento y prueba son generados por simulación con el modelo de transformador desarrollado en ATP. El transformador tiene una capacidad de 5 MVA y su relación de transformación es de 115 KV/13.8 KV, los parámetros se muestran en el apéndice B.

#### b) Patrones de entrenamiento del segundo grupo

La Fig. 5.6 muestra las señales de corriente de operación normalizadas, correspondientes a los cuatro casos de operación del transformador A, B, C y D.



En la Fig. 5.6 se puede apreciar la complejidad de las formas de onda de la corriente de operación. Para los casos A, B que corresponden a condiciones de energización, se observa que son muy parecidas, esto es debido a que el factor carga es la diferencia entre ellas. Para los casos C y D se aprecian las formas de onda de corriente muy diferentes debido a que las condiciones de operación simuladas no son iguales (cortocircuito en el secundario y depresión de voltaje en el primario). Sin embargo, comparados con los casos de operación simulados con el modelo de transformador en MATLAB, se aprecia que las señales en conjunto son más robustas debido a que el sistema de potencia que se simuló es de mayor capacidad.

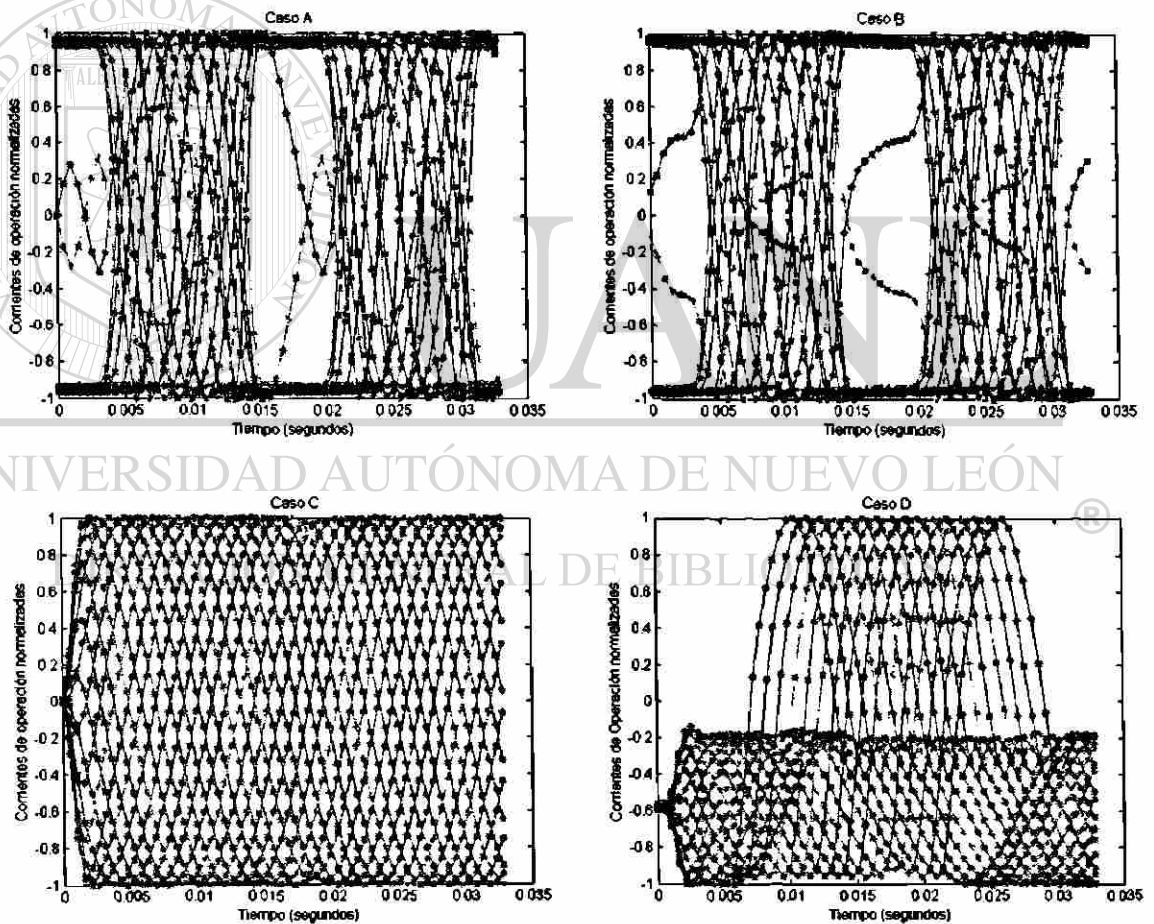


Figura 5.6 Segundo grupo de patrones de entrenamiento correspondiente a los casos A,B,C y D.

## b) Salida de la red con los patrones de entrenamiento

La matriz de entrada del segundo grupo de patrones de entrenamiento quedo conformada en forma similar que el primer grupo de patrones de entrenamiento siendo de dimensión (64x64). La Fig 5.7 muestra la salida RBF obtenida para este grupo de patrones de entrenamiento.

Los primeros 32 patrones de entrenamiento mostrados en la salida de la red (caso A y B), corresponden a formas de onda de la corriente de operación ocasionadas por energizaciones, los patrones del 33 al 48 (caso C) corresponden a formas de onda debido a cortocircuitos en el secundario del transformador y los patrones del 49 al 64 (caso D) corresponden a los casos de depresión de voltaje en el lado primario del transformador.

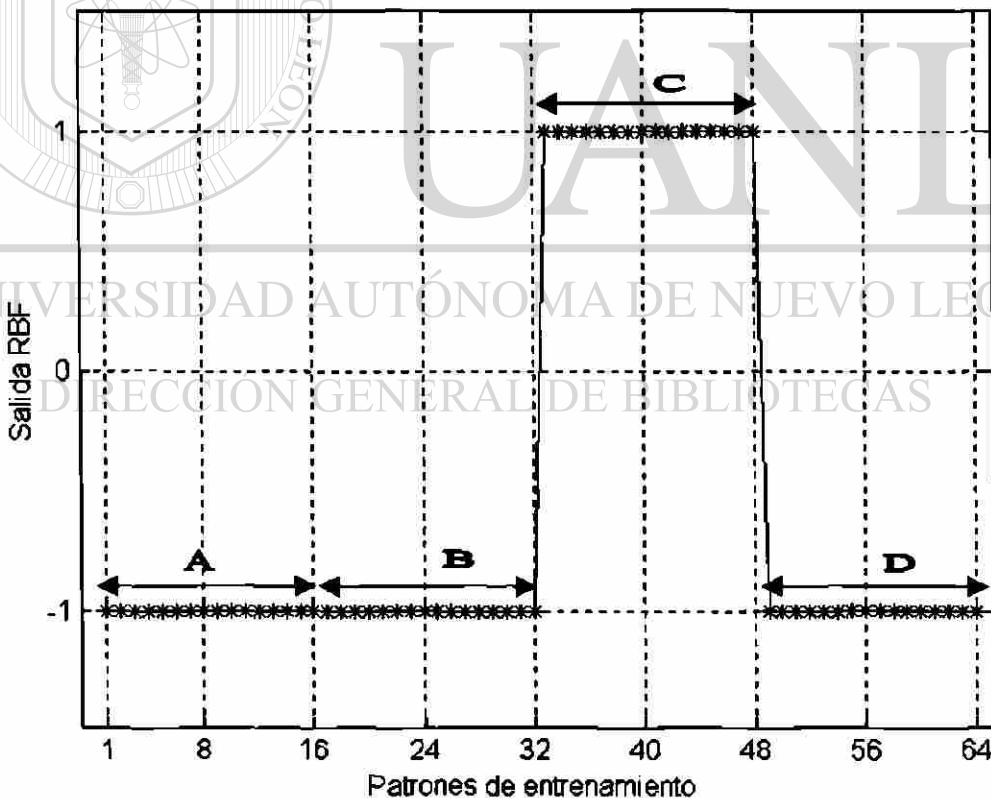


Fig. 5.7 Respuesta de la RNA de base radial para el segundo grupo de patrones de entrenamiento.

#### d) Segundo grupo de patrones de prueba

El segundo grupo de patrones de prueba son generados con el mismo modelo de transformador disponible en el programa ATP. Se simularon 20 condiciones transitorias y la matriz de entrada se formó utilizando 2 ciclos de la corriente de operación. La Fig. 5.8 muestra los patrones de prueba normalizados.

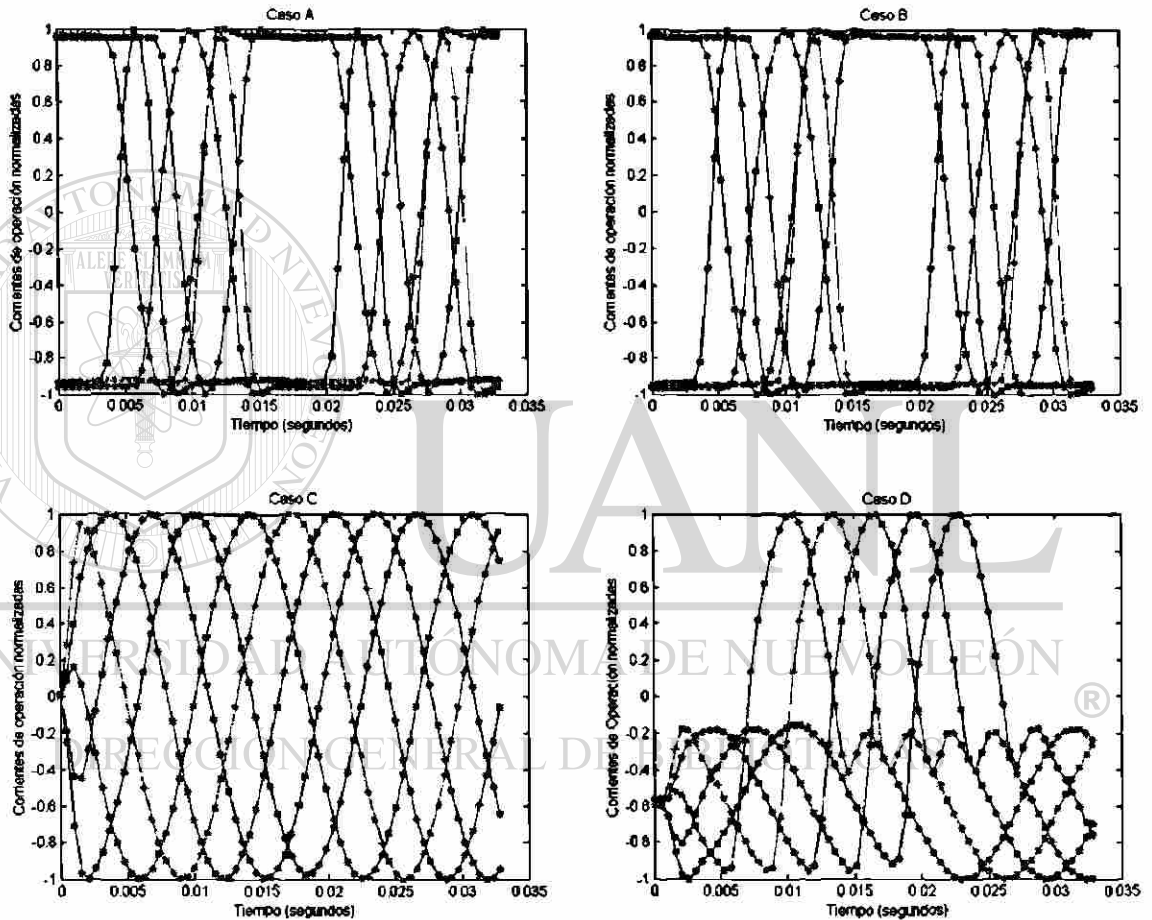


Figura 5.8 Segundo grupo de patrones de prueba correspondiente a los casos A,B,C y D.

#### e) Salida de la red con los patrones de prueba

La Fig 5.9 muestra la salida de la RBF del segundo grupo de patrones de prueba. En este caso la matriz de entrada es de dimensión (64x20).

Los resultados obtenidos demuestran el buen desempeño de la RBF para discriminar entre corrientes de *inrush* y de cortocircuito que es la base de una protección diferencial de transformador. La salida de la red es similar al primer grupo de patrones de prueba, donde los primeros 10 patrones de prueba (caso A y B) son condiciones de energizaciones, los patrones del 11 al 15 (caso C) son la condición de cortocircuito en el secundario del transformador y los patrones del 16 al 20 (caso D) son señales correspondiente a una situación de depresión del voltaje en el lado primario del transformador.

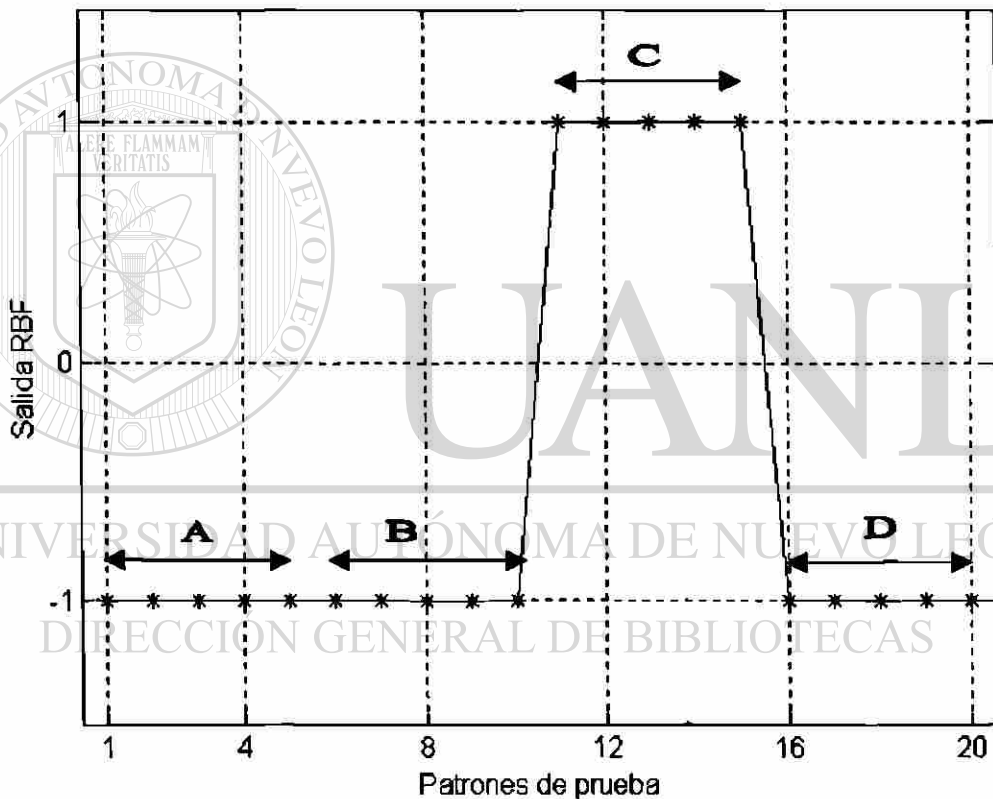


Fig. 5.9 Respuesta de la RBF del segundo grupo de patrones de prueba.

#### 5.4 ANÁLISIS DE UN CASO REAL

El objetivo de la generalización de la RNA de base radial es evaluar la capacidad de reconocimiento y aprendizaje de la red. Además de las pruebas descritas anteriormente, se analizó el caso real de un evento ocurrido el 28 de mayo del 2003 en Colombia en un

transformador de 60 MVA con relación de transformación de 115 KV /13.8 KV, donde la protección diferencial operó incorrectamente por una condición de *inrush*. La información fue obtenida de un oscilograma almacenado en formato COMTRADE.

En la Fig. 5.10 se muestran la corriente primaria y secundaria del evento ocurrido, con una frecuencia de muestreo igual a los casos de prueba analizados anteriormente (1920 Hz). Es importante notar que las ondas de corriente son diferentes a los patrones de entrenamiento obtenidos por simulación por lo que es una buena referencia para evaluar el desempeño de la RBF.

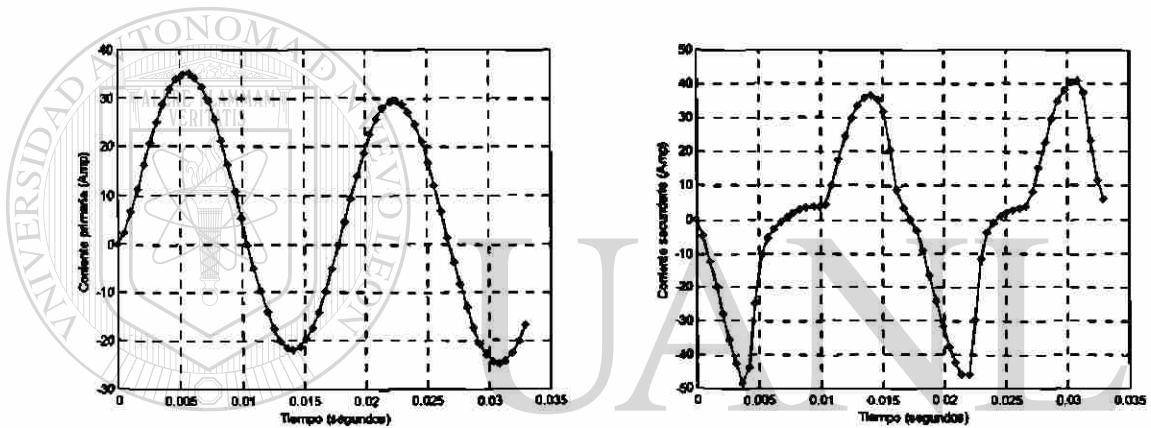


Fig. 5.10 Corriente primaria y secundaria de un evento real de la operación incorrecta de una protección diferencial.

La Fig. 5.11(a) muestra la corriente de operación normalizada previa a la entrada de la RBF. La salida esperada de la red para este caso debe corresponder a una condición de bloqueo es decir  $O = -1$  (Fig. 5.11(b)).

Se observa que la salida no es  $-1$  como se esperaba, sin embargo es muy cercana a la condición de no operación (salida  $-1$ ). Esto significa que puede ser necesario aumentar el número de patrones de entrenamiento considerando diferentes parámetros de transformadores y otras condiciones de operación. De esta forma se mejoraría la capacidad de reconocimiento de la RBF.

No obstante, esto puede provocar un incremento muy grande en el número de patrones de entrenamiento, dificultando el ajuste de los pesos de la red. Una forma de utilizar la capacidad de generalización de la red es definir un nivel de umbral en la salida de la red, de tal forma que no sea necesario incrementar en forma sustancial el número de patrones de entrenamiento. Una posibilidad sería:

$$O > 0.5 \quad \text{Condición de operación} \quad (5.3)$$

$$O < -0.5 \quad \text{Condición de no operación} \quad (5.4)$$

De esta forma, las condiciones de falla o energización que no hayan sido consideradas en el entrenamiento de la red, pero que den lugar a formas de onda de la corriente diferencial similares a las presentes en la matriz de patrones de entrenamiento, generarán salidas numéricamente cercanas a +1 (operación) y -1 (bloqueo), y la condición de umbral permitirá identificarlas correctamente. Este es el caso del evento real descrito anteriormente. Con esto se demuestra la factibilidad de implementar una protección diferencial de transformador basada en RBF.

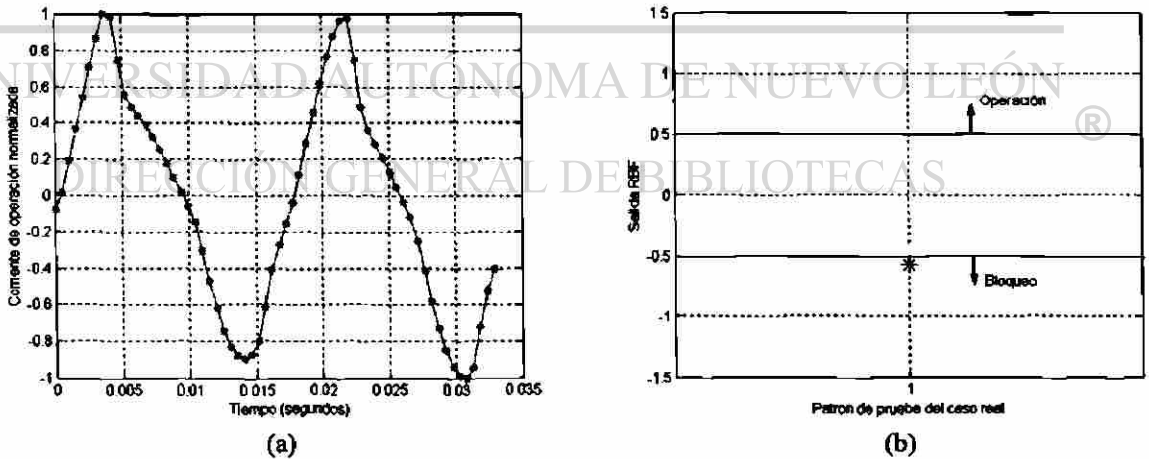


Fig. 5.11 Corriente de operación normalizada (a) y salida de la RBF para un caso real de operación incorrecta de transformador por corriente de inrush (b).

## 5.5 CONCLUSIONES DEL CAPÍTULO

La discriminación entre una condición de *inrush* y una de falla es primordial debido a la importancia de mantener la continuidad del servicio eléctrico a los consumidores durante condiciones transitorias, así como el asegurar la desconexión del transformador en caso de ocurrir un cortocircuito, que puede dañar el transformador debido a los grandes esfuerzos internos originados a corrientes excesivas de cortocircuito.

El método propuesto se basa en la identificación de diferentes condiciones operativas internas en el transformador mediante una RBF. La información de entrada de la RNA esta formada por corrientes de operación normalizadas que corresponden a diferentes eventos de falla y energización en el transformador. Una característica del método a diferencia de otros, es que no requiere de ningún ajuste para un buen desempeño.


La utilización de un umbral de salida de la RBF mejora la generalización de la red, sin incrementar sustancialmente el número de patrones de entrenamiento.

Se evaluó y analizó el desempeño de la red con diferentes patrones de prueba, con buenos resultados, lo que demuestra el buen desempeño de la RBF para detectar condiciones de *inrush*, y permitir la operación del relevador si una falla ocurre internamente en el transformador.

Finalmente, se analizo el desempeño de la red utilizando la información de un caso real de la operación incorrecta de un transformador debido a la corriente de *inrush*, ocurrido en Colombia en el 2003. El resultado de esta prueba fue satisfactoria, ya que la red reconoció que se trataba de una condición de *inrush*, obteniéndose una señal de salida -1 (bloqueo), utilizando una condición de umbral.

## CAPÍTULO 6

# CONCLUSIONES Y RECOMENDACIONES



### 6.1 CONCLUSIONES

# UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

De los estudios y análisis desarrollados en el presente trabajo, se concluye lo siguiente:

- Las corrientes transitorias originadas por las características no lineales del núcleo de transformadores pueden provocar la operación incorrecta de los relevadores diferenciales, especialmente cuando las corrientes son altamente simétricas.
- Actualmente existen distintos métodos de bloqueo para impedir la operación incorrecta de los relevadores diferenciales durante condiciones de *inrush*. Los métodos más empleados utilizan el contenido armónico de la corriente diferencial para bloquear o restringir el relevador, con el fin de realzar la diferencia entre una corriente de cortocircuito y una corriente de *inrush*.



- Los algoritmos de protección actuales tienen problemas para discriminar entre las corrientes de cortocircuito y las corrientes de *inrush*, en especial cuando esta última tiende a ser altamente simétrica. Esto es debido a que los materiales que se utilizan en la construcción de núcleos de transformadores reducen el nivel de distorsión de la corriente y el contenido de armónico en las corrientes de magnetización es menor.
- La discriminación entre una condición de *inrush* y una falla puede concebirse como un problema de reconocimiento de patrones. El método propuesto en esta tesis consiste en diseñar y entrenar una RNA de base radial para diferenciar entre una corriente altamente simétrica (cortocircuito) de una corriente con un alto nivel de distorsión (*inrush*) utilizando la información de la corriente diferencial.
- La estructura de la RNA propuesta en este trabajo consiste de 3 capas de neuronas, la primera capa que corresponden a las entrada de la red (64), 3 neuronas en la capa oculta, y una en la capa de salida, ya que se trata de una decisión binaria (bloqueo o no bloqueo), utilizando funciones de activación tipo campana de gauss. El número de entradas a la red se selecciono heurísticamente, siendo de 64, lo que corresponde a una ventana de datos de dos ciclos; la capa oculta se obtuvo por el método de regularización. La diferencia fundamental entra la arquitectura del modelo de RNA de base radial (RBF) con otros modelos, es en la operación de las neuronas ocultas, ya que en vez de calcular la suma ponderada de las entradas y aplicar una de función de activación para realizar el mapeo no-lineal, operan en base a la distancia espacial que separa el vector de entradas del vector sináptico almacenado en los pesos de la red.
- Una ventaja del modelo RBF es que su aprendizaje es en dos etapas, primero se calculan los parámetros de la capa oculta y después se calculan los de la capa de salida. La primera etapa hace uso de un algoritmo no supervisado, que puede ser del tipo *Kohonen* o el de *k-medias*, mientras que en la segunda etapa se emplea un algoritmo supervisado (*Adaline*). Por consiguiente es más rápido el proceso

de aprendizaje respecto a otros modelos de redes. Otra ventaja principal del modelo RBF es su rapidez de aprendizaje para su clasificación. La razón principal es que las neuronas intermedias actúan localmente, ya que requiere menos nodos para cubrir el espacio de entradas, mientras que las del perceptrón multicapa (MLP) actúan localmente.

- Se simularon 4 condiciones diferentes de operación del transformador (energización con carga y sin carga, cortocircuito en el secundario, depresión de voltaje en el lado primario) cada una de las cuales se simuló 16 veces durante un ciclo de voltaje de 60 Hz. El número total de patrones de entrenamiento fueron 128. Se normalizaron las señales con el objetivo de restringir los valores máximos de corriente en un rango  $[-1, +1]$ , con el fin de facilitar la operación de la red en el reconocimiento de patrones, con la ventaja de que la red, una vez entrenada, pueda ser utilizada en cualquier otro transformador.
- Se generaron 40 patrones para prueba adicionales con ángulos distintos a los utilizados para formar los patrones de entrenamiento, con el objetivo de evaluar la capacidad de generalización de la RBF. Los resultados obtenidos por simulación demuestran el buen desempeño de la red para detectar condiciones de *inrush* y de fallas para impedir la operación incorrecta de los relevadores diferenciales. Las pruebas realizadas con los cuatro grupos de patrones de entrenamiento y prueba (168 patrones) fueron exitosas.
- Se definió un nivel de umbral en la salida de la red para analizar la capacidad de generalización, esto con el fin de no incrementar el número de patrones de entrenamiento. Para condiciones de bloqueo (*inrush*) el umbral propuesto es  $O < -0.5$  y para condiciones de operación (cortocircuito) el umbral propuesto es  $O > 0.5$ . De esta forma la condición de umbral permite identificar correctamente formas de onda de condiciones de falla o de *inrush* que no se considerarán en el entrenamiento de la red.

- Se analizó un caso real de la operación incorrecta de una protección diferencial para una condición de *inrush* en un transformador de 60 MVA durante su energización. El evento ocurrió en Colombia en el 2003. El resultado obtenido por la red no fue ideal (salida -1, bloqueo). Sin embargo, cumple la condición de umbral propuesta ( $O < -0.5$ ) para reconocer el evento como condición de *inrush*.
- Los resultados obtenidos demuestran la factibilidad de implementar una protección diferencial de transformador en base a una RBF, que reconozca las características de la corriente diferencial en condiciones de *inrush* y de cortocircuito.

## 6.2 APORTACIONES DEL TRABAJO

Las principales aportaciones de este trabajo de investigación son las siguientes:

- Se realizó un análisis bibliográfico para identificar los problemas de operación de los actuales algoritmos de protección diferencial de transformadores de potencia.
- Se desarrollo un nuevo algoritmo de protección diferencial de transformadores basado en técnicas de reconocimiento de patrones, utilizando una RBF. La red lleva a cabo la función de discriminar entre una corriente de *inrush* y una de cortocircuito mediante el reconocimiento de la forma de onda de la corriente diferencial, que es sensible al nivel de la corriente aperiódica exponencial de CD y el contenido de armónicas.
- Se propone el uso de un umbral de operación de la RBF, que permita explotar la capacidad de generalización de la red sin la necesidad de aumentar en forma sustancial el número de patrones de entrenamiento.

### 6.3 RECOMENDACIONES PARA TRABAJOS FUTUROS

- Considerar la saturación de los transformadores de corriente como fuente de error en las mediciones de señales de corriente, y analizar en detalle las aportaciones de las componentes transitorias apériodicas (exponenciales) y oscilatorias, así como armónicas de alto orden en la corriente diferencial.
- Considerar el efecto de las condiciones de sobreexcitación y ferresonancia, con el fin de considerar sus efectos en la corriente diferencial. Así mismo, se debe considerar el efecto del FP de la carga.
- Extender los resultados obtenidos en un transformador trifásico, donde los ángulos de energización sean controlados para observar el efecto de las corrientes de magnetización en cada fase y analizar diferentes condiciones operativas internas y externas en el transformador de potencia.
- Ampliar los resultados obtenidos, mediante la aplicación de técnicas de pre-procesamiento de información para mejorar el desempeño del reconocimiento de patrones.

## REFERENCIAS

- [1] R. Van Warrington, *Protective Relays, Their Theory and Practice*, vol. 2, Chapman and Hall: London, 1977.
- [2] Westinghouse, *Applied Protective Relaying*, Westinghouse Electric Co. Newark.
- [3] M.A. Rahman, B. Jeyasurya, "A State-of-art Review of Transformer Protection Algorithms," *IEEE transactions on power Delivery*, vol. 3, no. 2, April 1988, pp. 534-544.
- [4] M.A. Sykes, I.F. Morrison, "A. Proposed Method of Harmonic Restraint Differential Protection of Transformers by Digital Computer," *IEEE Transactions*.
- [5] O.P. Malik, P. K. Dash, G.S. hope, "Digital Protection of a Power Transformer," *IEEE Publication 76CH1075-1 PWR*, Paper no. A76 191-7, IEEE PES Winter Meeting, New York, January 1976.
- [6] E.O. Schweitzer, R.R, Larson, A. J. Flechsig, "An Efficient Inrush Current-Detection Algorithm for Digital Computer Relay Protection of Transformers," Paper A77 510-1, IEEE PES Summer Meeting, Mexico City, 1977.
- [7] A. J. Degens, "Algorithm for a Digital Transformers Differential Protection Based on a Least-squares Curve Fitting," *proceedings IEE*, vol. 128, part C, no. 3, May 1981, pp.155-161.
- [8] M.A. Rahman, P. K. Dash, E. R. Downton , "Digital Protection of Power Transformer Based on Weighted Least Square Algorithm," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-101, no. 11, November 1982, pp. 4202-4209.
- [9] M.A. Rahman, P. K. Dash, "Fast Algorithm for Digital Protection of Power Transformers," *Proceedings IEE* vol. 129, Part C, no. 2, March 1982, pp. 79-85.
- [10] B. Fakruddin, K. Parthasarathy, L. Jenkins, B. W. Hogg, "Application of Haar Functions for Transmission Lines and Transformers Differential Protection," *Electrical Power & Energy Systems*, vol. 6, no. 3, July 1984, pp. 169-180.

- [11] M. A. Rahman, B. Jeyasurya, A. Gangopadhyay, "Digital Differential Protection of Power Transformers Based on Walsh Functions," Transactions of CEA Engineering & Operating Division, vol. 24, part 3, Paper 85-SP-149, 1985.
- [12] Jeyasurya, M. A. Rahman, "Application of Walsh Functions for Microprocessor based Transformer Protection," IEEE transactions on Electromagnetic Compatibility, vol. EMC-27, no. 4, November 1985, pp. 221-225.
- [13] P. Liu, O.P. Malink, D. Chen, G.S. Hope, Y Guo, "Improved Operation of Differential Protection of Power Transformers for Internal Faults," IEEE Transaction on Power Delivery, vol. 7, no. 4, 1992, pp. 1912-1919.
- [14] T.S. Sidhu, M.S. Sachdev, H. C. Wood, M. Nagpal, "Design, Implementation and Testing of a Micro-processor-based High-speed Relay for Detecting Transformer Winding Faults," IEEE Transaction on Power Delivery, vol. 7, no. 1, 1992, pp. 108-117.
- [15] T.S. Sidhu, M.S. Sachdev, "On-line Identification of Magnetizing Inrush and Internal Faults in Three-phase Transformers," IEEE Transaction on Power Delivery, vol. 7, no. 4, 1992, 1885-1891.
- [16] A. Guzmán, S. Zocholl, G. Benmouyal, H. Altuve, "Performance Analysis of Traditional and Improved Transformer Differential Protective Relays," Memoria técnica del V Simposio Iberoamericano sobre Protección de Sistemas Eléctricos de Potencia, Monterrey, N.L, México, Noviembre 2000, pp. 123-142.
- [17] K. Warwick, A. Ekwue, R. Aggarwal, Artificial Intelligence Techniques in Power Systems, IEE: London, 1997.
- [18] H. Haykin, Neural Networks: A comprehensive Foundation, IEEE Press, MacMillan College Publishing Co., Inc., 1994.
- [19] M.R. Zaman, M. A. Rahman, "Experimental Testing of the Artificial Neural Network Based Protection of Power Transformers," IEEE Transaction on Power Delivery, vol. 13, no. 2, April 1998, pp. 510-517.
- [20] L.G. Pérez, A. J. Flechsig, J.L. Meador, Z. Obradovic, "Training an ANN to Discriminate Between Magnetizing Inrush and Internal Faults," IEEE Transaction on power Delivery, vol. 9, no. 1, January 1994, pp. 434-441.


- [21] B. Kasztenny, E. Rosolowski, M.M. Saha, B. Hillstrom, "A. Self-organizing Fuzzy Logic Based Protective Relay, Application to Power Transformer Protection," *IEEE transaction on Power Delivery*, vol. 12, no. 3, July 1997, pp. 1119-1127.
- [22] D. C. Robertson, O. I. Camps, J. S. Mayer, W. B. Gish, "Wavelets and Electromagnetic Power System Transients," *IEEE Transactions on Power Delivery*, vol. 11, no. 2, April 1996, pp. 1050-1058.
- [23] P.L. Mao, R.K. Aggarwal, "A Wavelet Transform Based Decision Making Logic Transformers," *Electrical Power & Energy Systems*, 22, 2000, pp. 389-395.
- [24] M. Gómez, D. W. Nicoletti, "A Wavelet-based Differential Transformer Protection," *IEEE Transaction on power Delivery*, vol. 14, no. 4, October 1999, pp. 1351-1358.
- [25] Z. Bo, G. Weller, T. Lomas, "A New Technique for Transformer Protection Based on Transient Detection," *IEEE Transactions on Power Delivery*, vol. 15, no. 3, July 2000, pp. 870-875.
- [26] J. H. Brunke, K. J. Fröhlinch, "Elimination of Transformers Inrush Currents by Controlled Switching – Part I: Theoretical Considerations," *IEEE Transactions on Power Delivery*, Vol. 16, No. 2, April 2001, pp 276-280.
- [27] C.H. Einval and J.R. Linders," A Three-Phase Differential Relay for Transformer Protection," *IEEE Transactions PAS*, Vol. PAS-94, No.6, Nov/dec 1975, pp. 1971-1980.
- [28] R.L. Sharp, and W. E. Glassburn, "A Transformer Differential Relay With Second-harmonic Restraint," *AIEE Transactions*, Vol. 77, Part III, Dec. 1958, pp. 913-918.
- [29] G.D. Rockefeller, "Fault Protection With a Digital Computer," *IEEE Transactions PAS*, Vol. PAS-98, April 1969, pp. 438-464.
- [30] S.B. Wilkinson, *Transformer Differential Relay*, U.S. Patent No 5627712, May 6, 1997.
- [31] M. El-Sharkawi, *A Tutorial Course On Artificial Neural Networks with Applications to Power Systems*, Piscataway: IEEE Press, 1996.



- [32] C. G. Looney, *Pattern Recognition Using Neural Networks*, New York: Oxford University Press, Inc, 1997.
- [33] The Power Engineering Education Committee and The Power System Relaying Committee, *Advancements in Microprocessor Based Protection and Communication*, Piscataway: IEEE Press, 1997.
- [34] S. Haykin, *Neural Networks*, New Jersey: Prentice-Hall, Inc, 1999.
- [35] Simpson, P.K. *Artificial Neural System*, Pergamon Press, 1989.
- [36] Warwick, K. *An overview of neural networks in control applications*. An Neural networks for Robotic Control, M. Zalzal, Prentice-Hall, pp. 1-25, 1.995.
- [37] Wasserman, P.D. *Neural Computing. Theory and Practice*. Van Nostrand Reinhold, 1.989.
- [38] Hrycej. T., *Modular Learning in Neural Networks*. John Wiley and Sons, 1992.
- [39] Kohonen, T. *The Self- Organization and Associative Memory*. 3th edition, Springer. Verlag, 1989.
- [40] J. M. Zurada, *Introduction to Artificial Neural System*, USA: West Publishing Co., 1992.
- [41] Jan, J. S.R. Sun, C.T. "Functional Equivalence Between Radial Basic Function Networks and Fuzzy Inference System," IEEE Trans. Neural Networks, vol. 4, número 1, enero 1993.
- [42] P. Bornard J.C. Bastide, "A. Prototype of Multiprocessor Based Distance Relay," IEEE. Trans. On Power Apparatus ans System, Vol. PAS-101, No. 2, Feb. 1982, pp 491-498.
- [43] Poggio, T., Girosi, F. Networks For Approximation and Learning, Proc. Of the IEEE, sep., 1481-1497, 1990.
- [44] Thorp, J.S., and Phadke, A. G.: "A Microprocessor Based Three Phase Transformers Differential Relay, IEE Trans. 1982, PAS-94, pp 426-432.
- [45] "Alternative Transients Program," Rule Book, Last Revision: July 1987.
- [46] H. J. Altuve, H. V. Martínez, I. D. Verduzco, "Estudio Comparativo de Filtros Analógicos Pasabajos para Relevadores Digitales de Distancia".



- [47] H. J. Altuve, *Protección de Sistemas Eléctricos de Potencia: DIE- UANL*, 1996.
- [48] J. R. Hilera, V. J. Martínez, *Redes Neuronales Artificiales*, Editorial RA-MA, Madrid, España, 1995.
- [49] B. M. del Brío, A. S. Molina, *Redes Neuronales y Sistemas Difusos*, Segunda Edición, Editorial RA-MA, Madrid, España, 2002.
- [50] E. O. Schweitzer, D. Huo, "Filtering for Protective Relays", "47<sup>th</sup> Annual, Georgia Tech Protective Relay Conference, Atlanta, GA, April 1993, pp. 24.
- [51] C. G. Looney, *Pattern Recognition Using Neural Networks*, New York: Oxford University Press, Inc, 1997.
- [52] C. Pérez. "Fitting Saturation and Hysteresis via Arctangent Functions", *IEEE Power Engineering Review*, November 2000, pp. 55-57.
- [53] W. Hayt Jr., *Teoría Electromagnética*, Quinta Edición, McGraw-Hill, México 1991.



# UANL

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN



DIRECCIÓN GENERAL DE BIBLIOTECAS



# APÉNDICE A

**FORMULACIÓN DEL MODELO DEL TRANSFORMADOR  
PARA LA GENERACIÓN DE PATRONES DE  
ENTRENAMIENTO**

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS



En la Figura A.1. se presenta la estructura de un transformador monofásico para estudios transitorios, donde  $V_1$  es el voltaje primario,  $I_1$  es la corriente primaria,  $V_2$  es el voltaje secundario,  $I_2$  es la corriente secundaria,  $\phi_{11}$  flujo magnético del lado primario,  $\phi_{12}$  flujo magnético del lado secundario y  $\phi_m$  es el flujo magnético mutuo.




Fig. A.1. Representación de un transformador monofásico.

El flujo generado por cada devanado puede separarse en dos componentes, una es el flujo propio de cada devanado y la otra es el flujo mutuo entre ambos [53]. El flujo total que enlaza cada devanado es entonces;

$$\phi_1 = \phi_{L1} + \phi_m \quad (A.1)$$

$$\phi_2 = \phi_{L2} + \phi_m \quad (A.2)$$

Si se define  $N_1$  como el número de vueltas del primer devanado, se puede expresar los enlaces de flujo para el primer devanado, por medio de;

$$\lambda_1 = N_1 \phi_1 = N_1 (\phi_{L1} + \phi_m) \quad (A.3)$$

El flujo de dispersión  $\phi_{L1}$  resulta de la fuerza magnetomotriz (fmm) del primer devanado, es decir  $N_1 i_1$ . A su vez, el flujo  $\phi_m$  resulta por la fmm de  $N_1 i_1 + N_2 i_2$ .

Rescribiendo de nuevo (A.3) se tiene:

$$\lambda_1 = N_1 \left[ \frac{N_1 i_1}{\mathfrak{R}_{L1}} + \frac{(N_1 i_1 + N_2 i_2)}{\mathfrak{R}_m} \right] = \left( \frac{N_1^2}{\mathfrak{R}_{L1}} + \frac{N_1^2}{\mathfrak{R}_m} \right) i_1 + \frac{N_1 N_2}{\mathfrak{R}_m} i_2 \quad (\text{A.4})$$

donde  $\mathfrak{R}$  es la trayectoria del flujo. De igual manera para el segundo devanado.

$$\lambda_2 = N_2 \left[ \frac{N_2 i_2}{\mathfrak{R}_{L2}} + \frac{(N_1 i_1 + N_2 i_2)}{\mathfrak{R}_m} \right] = \left( \frac{N_2^2}{\mathfrak{R}_{L2}} + \frac{N_2^2}{\mathfrak{R}_m} \right) i_2 + \frac{N_1 N_2}{\mathfrak{R}_m} i_1 \quad (\text{A.5})$$

Quando el sistema magnético es lineal, los enlaces de flujo se puede expresar en términos de inductancias y corrientes, con lo que se llega a la forma siguiente.

$$\lambda_1 = L_{11} i_1 + L_{12} i_2 \quad (\text{A.6})$$

$$\lambda_2 = L_{21} i_1 + L_{22} i_2 \quad (\text{A.7})$$

De (A.4) y (A.5) se obtienen  $L_{11}$  y  $L_{22}$  que son las inductancias propias de ambos devanados y también las expresiones para  $L_{12}$  y  $L_{21}$  que son las inductancias mutuas entre ellos.  $L_{L1}$  es la inductancia en el primario del transformador y  $L_{L2}$  es la inductancia en el secundario del transformador.

$$L_{11} = \frac{N_1^2}{\mathfrak{R}_{L1}} + \frac{N_1^2}{\mathfrak{R}_m} = L_{L1} + L_{m1} \quad (\text{A.8})$$

$$L_{22} = \frac{N_2^2}{\mathfrak{R}_{L2}} + \frac{N_2^2}{\mathfrak{R}_m} = L_{L2} + L_{m2} \quad (\text{A.9})$$

$$L_{12} = L_{21} = \frac{N_1 N_2}{\mathfrak{R}_m} \quad (\text{A.10})$$

Con la cual se obtienen las expresiones para los enlaces de flujo  $\lambda_1$  y  $\lambda_2$ .

$$\lambda_1 = L_{L1}i_1 + L_{m1} \left[ i_1 + \frac{N_2}{N_1} i_2 \right] \quad (\text{A.12})$$

$$\lambda_2 = L_{L2}i_2 + L_{m2} \left[ i_2 + \frac{N_1}{N_2} i_1 \right] \quad (\text{A.13})$$

Así las ecuaciones de voltaje inducido en cada devanado expresadas como la razón de cambio de los enlaces de flujo por unidad de tiempo.

$$e_1 = \frac{d\lambda_1}{dt} = L_{L1} \frac{di_1}{dt} + L_{m1} \frac{d}{dt} \left( i_1 + \frac{N_2}{N_1} i_2 \right) \quad (\text{A.14})$$

$$e_2 = \frac{d\lambda_2}{dt} = L_{L2} \frac{di_2}{dt} + L_{m2} \frac{d}{dt} \left( i_2 + \frac{N_1}{N_2} i_1 \right) \quad (\text{A.15})$$

La relación de vueltas entre ambos devanados ( $N_1 / N_2$ ), también se conoce como relación de transformación, y se emplea para referir las variables a un solo devanado. En ese caso las variables con apostrofe indican que la variable está referida a uno de los devanados, por ejemplo:

$$i_2' = \frac{N_2}{N_1} i_2 \quad (\text{A.16})$$

Tomando en cuenta esta relación de transformación, se puede multiplicar (A.15) por ( $N_1 / N_2$ ), y escribir nuevamente (A.14) y (A.15) como:

$$e_1 = \frac{d\lambda_1}{dt} = L_{L1} \frac{di_1}{dt} + L_{m1} \frac{d}{dt} (i_1 + i_2') \quad (\text{A.17})$$

$$e_2' = \frac{d\lambda_2}{dt} = L_{L2} \frac{di_2'}{dt} + L_{m1} \frac{d}{dt} (i_1 + i_2') \quad (\text{A.18})$$

Estas ecuaciones de voltaje representan un circuito eléctrico ideal, equivalente en su comportamiento estático y dinámico al circuito magnético, según se muestra en la Fig. A.2. En este caso se ha despreciado las resistencias de los devanados, así como las pérdidas del núcleo.

Para incluir los fenómenos de saturación y pérdidas en el núcleo en las ecuaciones (A.12) y (A.13), éstas se escriben como:

$$\lambda_1 = L_{L1}i_1 + \lambda_m \quad (\text{A.19})$$

$$\lambda_2 = L'_{L2}i'_2 + \lambda_m \quad (\text{A.20})$$

Para considerar las pérdidas en los devanados por efecto Joule, se agrega una resistencia en serie con la inductancia y para considerar las pérdidas por corrientes de Eddy e histéresis en el núcleo, se inserta una conductancia en paralelo con la inductancia de magnetización. De esta forma las ecuaciones de voltaje se describen como (A.21) y (A.22) y de ellas se deduce el modelo que representa al transformador monofásico, incluyendo saturación y pérdidas, mostrado en la figura A.2.

$$v_1 = R_1i_1 + L_{L1} \frac{di_1}{dt} + \frac{d\lambda_m}{dt} \quad (\text{A.21})$$

$$v_2 = R_2i'_2 + L'_{L2} \frac{di'_2}{dt} + \frac{d\lambda_m}{dt} \quad (\text{A.22})$$




Fig. A.2. Representación del modelo del transformador monofásico saturable.

Además, se obtiene una ecuación que determina la corriente que circula por la rama de magnetización, y se emplea para determinar las pérdidas en el núcleo.

$$\frac{d\lambda_m}{dt} = \frac{N^2 A}{\ell} \left[ \mu + i_m \frac{d\mu}{di_m} \right] \frac{di_m}{dt} \quad (\text{A.23})$$

Así mismo, también se cumplen las siguientes relaciones:

$$\frac{d\lambda_m}{dt} = R_c i_c \quad (\text{A.24})$$

$$i_c = i_1 + i_2 - i_m \quad (\text{A.25})$$

En caso de tener una carga en el secundario del transformador, por ejemplo una carga puramente resistiva, el voltaje en el secundario esta dado por:

$$v_2 = -R_L' i_2' \quad (\text{A.26})$$

Sustituyendo (A.26) en (A.22), y resolviendo para la corriente del devanado secundario, así como en (A.21), y resolviendo para la corriente primario, se obtienen las expresiones (A.27) y (A.28) con las corrientes como variables de estado. La tercera variable de estado, la corriente de magnetización se igualan (A.23) y (A.24) y se resuelven para la corriente de magnetización (A.29). Estas tres ecuaciones describen el comportamiento transitorio en el dominio del tiempo.

$$\frac{di_1}{dt} = \frac{1}{L_{L1}} [v_1 - R_1 i_1 - R_c i_c] \quad (\text{A.27})$$

$$\frac{di_2}{dt} = \frac{1}{L_{L2}} [-(R_2' + R_L') i_2' - R_c i_c] \quad (\text{A.28})$$

$$\frac{di_m}{dt} = R_c i_c \frac{\ell}{N^2 A} \left[ \mu + i_m \frac{d\mu}{di_m} \right]^{-1} \quad (\text{A.29})$$

El comportamiento no lineal de la corriente de magnetización, que depende de las características del núcleo magnético se simula utilizando la función tangente hiperbólica [52]. Esta función en particular se ajusta a la forma de saturación de los materiales magnéticos y puede presentar con exactitud y sencillez los datos que se proporcionan del transformador. La expresión es la siguiente:

$$\lambda_1 = \alpha \tanh(\beta i_m) + \gamma i_m \quad (\text{A.30})$$

donde  $\alpha$  representa el ajuste a la rodilla de saturación,  $\beta$  ajusta la pendiente de la curva en la parte lineal y  $\gamma$  ajusta la pendiente de la zona saturada.

Los coeficientes  $\alpha$ ,  $\beta$  y  $\gamma$  permiten tener control sobre la forma de la función tangente hiperbólica. Por lo tanto de la curva experimental normalmente se conocen algunos puntos, por lo tanto los coeficientes de la curva de saturación se calculan basándose en tales puntos; se requiere de al menos 3 mediciones y se sustituye en (A.30), formando un conjunto de ecuaciones con tres incógnitas. En caso de tener un mayor número de puntos se puede aplicar una estimación de parámetros por mínimos cuadrados.

La expresión (A.31) es un sistema de ecuaciones no lineales y con el método de Newton se resuelve iterativamente el sistema de ecuaciones. Por lo tanto se obtienen coeficientes adecuados para representar la curva de saturación.

$$\begin{aligned} \lambda_1 &= \alpha \tanh(\beta i_{m1}) + \gamma i_{m1} \\ \lambda_2 &= \alpha \tanh(\beta i_{m2}) + \gamma i_{m2} \\ \lambda_3 &= \alpha \tanh(\beta i_{m3}) + \gamma i_{m3} \end{aligned} \quad (\text{A.31})$$

Una vez que se conoce la característica de saturación  $\lambda$  se sustituye en (A.32), y se obtiene la permeabilidad en función de la corriente de magnetización.




$$\mu = \frac{l \lambda}{N^2 A i_m} \quad (\text{A.32})$$

donde  $l$  es la longitud promedio del núcleo y  $A$  es la sección transversal del núcleo.

Una vez obtenida la permeabilidad se calcula la derivada en la expresión (A.33), la cual representa la razón de cambio de los enlaces de flujo respecto al tiempo en el núcleo magnético.


$$e = \frac{N^2 A}{l} \left[ \mu + i_m \frac{d\mu}{di_m} \right] \frac{di_m}{dt} \quad (\text{A.33})$$



# UANL

---

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN<sup>®</sup>  
DIRECCIÓN GENERAL DE BIBLIOTECAS



# **APÉNDICE B**

## **PARÁMETROS ELÉCTRICOS DE LOS TRANSFORMADORES**

---

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

DIRECCIÓN GENERAL DE BIBLIOTECAS

®

En este apéndice se presentan los parámetros eléctricos de los dos transformadores que se utilizaron para la simulación de condiciones de cortocircuito y energización. A partir de estas simulaciones se definieron los patrones de entrenamiento y prueba para la RBF.

## B.1 TRANSFORMADOR 1

Los datos del transformador desarrollado en MATLAB, cuyo modelo matemático se describe en el apéndice 1, son:

Tabla B.1 Parámetros del transformador 1 desarrollado en MATLAB.

<i>Tensión Nominal H:</i>	115 KV	<i>Eficiencia:</i>	99.25 %
<i>Tensión Nominal X:</i>	13.8 KV	<i>Impedancia:</i>	7.50 %
<i>Capacidad:</i>	5 MVA	<i>Corriente en vacío:</i>	0.35 %
<i>Frecuencia Nominal:</i>	60 Hz	<i>Rmag:</i>	1410666.67 ohms
<i>Corriente Nominal en H:</i>	43.478 A	<i>Rp:</i>	4.95937 ohms
<i>Corriente Nominal en X:</i>	362.319 A	<i>Rs:</i>	0.142830 ohms
<i>Z base en H:</i>	2645 ohms	<i>Xp:</i>	99.1875 ohms
<i>Z base en X:</i>	38.088 ohms	<i>Xs:</i>	1.4283 ohms

La característica y los datos de saturación del transformador de potencia se muestran a continuación:

Tabla B.2. Datos de la curva de saturación del transformador 1.

Corriente (A)	Flujo (Wb)
0	0
0.014210425	97.7295
0.030423505	192.4933
0.059765264	312.3784
0.092361555	360.7019
0.143130478	383.6138
0.265411063	411.2233
0.489330459	431.4940
0.942804558	450.8241
1.96033205	469.3812
3.099888587	479.2914
8.004704628	496.5811




Fig. B.1 Representación de la curva de magnetización del transformador 1.

## B.2 TRANSFORMADOR 2

La Figura B.2 presenta el modelo de transformador monofásico desarrollado en ATP.




Fig. B.2 Modelo del transformador saturable monofásico del ATP.

Los parámetros del transformador son los siguientes:

Tabla B.3 Parámetros del transformador desarrollado en ATP.

<i>Tensión Nominal H:</i>	7620 V	<i>Eficiencia:</i>	98.75 %
<i>Tensión Nominal X:</i>	120 V	<i>Impedancia:</i>	2.75 %
<i>Capacidad:</i>	35 KVA	<i>Corriente en vacío:</i>	1.25 %
<i>Frecuencia Nominal:</i>	60 Hz	<i>Rmag:</i>	530874.514 ohms
<i>Corriente Nominal en H:</i>	4.593 A	<i>Rp:</i>	5.18432 ohms
<i>Corriente Nominal en X:</i>	291.667 A	<i>Rs:</i>	0.002571 ohms
<i>Z base en H:</i>	1658.98 ohms	<i>Xp:</i>	22.811014 ohms
<i>Z base en X:</i>	0.4114 ohms	<i>Xs:</i>	0.00565714 ohms

La característica y los datos de saturación del transformador de potencia se muestran a continuación:

Tabla B.4. Datos de la curva de saturación del transformador 2.

Corriente (A)	Flujo (Wb)
0	0
0.00614791	6.4756
0.01316224	12.7548
0.02585648	20.6985
0.03995875	23.9004
0.06192311	25.4186
0.11482585	27.2480
0.21170099	28.5912
0.4078893	29.8720
0.84810629	31.1016
1.34111719	31.7583
3.46310735	32.9039




Fig. B.3 Representación de la curva de magnetización del transformador 2.

