



RESUMEN

Para resolver el problema del diagnóstico y clasificación de fallas se han propuesto algunos algoritmos basados en técnicas de inteligencia artificial tales como redes neuronales, redes neuro-difusas, etc. Estos algoritmos permiten manejar adecuadamente la incertidumbre ante situaciones de datos imprecisos, usar técnicas de aprendizaje para el modelamiento, adaptarse a los cambios en las condiciones de operación del sistema y usar el conocimiento del experto antes situaciones no definidas.

Se propone un diagnóstico automático de fallas en líneas de transmisión usando Algoritmos Adaptivos Neurodifusos (en inglés *Adaptive Neuro-Fuzzy Inference System* – ANFIS).

Se implementa un algoritmo neuro-difuso para la detección y clasificación de fallas en líneas de transmisión eléctricas, usando ANFIS y se aplica a una línea de transmisión de 230 kV típica de un sistema eléctrico de potencia, para mediante simulaciones extraer los datos para entrenamiento y verificación del modelo.

Para validar su desempeño, las entradas al ANFIS son los valores eficaces (*Root Mean Square* - RMS) de las tres corrientes de fase y la corriente de secuencia cero obtenidas, formato COMTRADE, mediante registros de oscilografías de fallas reales en líneas de transmisión de 230 kV del sistema eléctrico ecuatoriano.

De los resultados obtenidos, se observa que los modelos neuro-difusos pueden de manera adecuada y con rapidez detectar y clasificar fallas en líneas de transmisión eléctricas, usando datos de validación tanto simulados como reales. Por esto la metodología utilizada tiene gran potencia para ser aplicada en centros de control, para la toma de decisiones al momento de la ocurrencia de fallas.

PALABRAS CLAVES:

Inteligencia Artificial IA, Red Neural Artificial RNA, Sistema de Inferencia Neurodifuso Adaptivo ANFIS, Sistema de Inferencia Difuso FIS, Detección y clasificación de fallas.



ABSTRACT

In order to solve the automatic classification and detection of a fault, there have been proposed some artificial intelligence approaches based on neural networks, neuro-fuzzy systems, etc. These techniques are very useful to solve that kind of problems due to: i) they can manage uncertainty in data, ii) they can adapt themselves to the particularities of the problem, iii) they use learning techniques to produce adequate models, and iv) they can use expert knowledge to define unclear situations.

In this work, it is proposed an automatic fault diagnosis approach in transmission lines using an Adaptive Neuro-Fuzzy Inference System technique.

It is implemented a neuro-fuzzy algorithm for detection and classification of faults in electrical transmission lines, using ANFIS. Some fault conditions, in a 230 kV transmission line have been simulated to extract data for training and checking in the modeling process.

In order to validate its performance, the ANFIS inputs are the RMS (Root Mean Square) values of the three phase currents and zero sequence current obtained using fault disturbance records of actual 230 kV transmission lines of the electric power Ecuadorian system.

The results obtained show that the neuro-fuzzy models can accurately and rapidly detect and classify different kind of faults in power transmission lines, both simulated and real, so that the methodology could be implemented for decision making in control centers.

PALABRAS CLAVES:

Artificial Intelligence IA, Artificial Neural Network ANN, Adaptive Neuro-Fuzzy Inference System ANFIS, Fuzzy Inference System FIS, Detection and classification of fault.



Contenido

CAPITULO 1.	INTRODUCCIÓN	16
1.1	INTRODUCCIÓN	16
1.2	EXPLORACIÓN DE LA PROBLEMÁTICA.....	17
1.3	ALCANCE Y DEFINICIÓN DEL TRABAJO DE INVESTIGACIÓN	18
1.4	OBJETIVOS	18
1.4.1	Objetivos específicos:.....	18
1.5	ESTRUCTURA DEL TRABAJO.....	19
CAPITULO 2.	ESTADO DEL ARTE	20
2.1	CONCEPTOS BÁSICOS	20
2.1.1	Estudios en los Sistemas Eléctricos de Potencia	20
2.1.2	Análisis de fallas en sistemas eléctricos de potencia	23
2.2	ENFOQUES PARA RESOLVER EL PROBLEMA DE DIAGNÓSTICO DE FALLAS.....	31
2.3	ANÁLISIS DE PRINCIPALES REFERENCIAS BIBLIOGRÁFICAS.....	32
CAPITULO 3.	METODOLOGÍA DE INVESTIGACIÓN	36
3.1	INTRODUCCIÓN	36
3.2	PREPARACIÓN DE DATOS	37
3.2.1	Características Eléctricas	37
3.2.2	Filtrado Analógico y Digital.....	40
3.2.3	Normalización.....	41
3.2.4	Condiciones para el procesamiento de datos	41
3.3	MODELACIÓN Y CONSTRUCCIÓN DEL SEP PARA GENERACIÓN DE PATRONES DE ENTRENAMIENTO Y VERIFICACIÓN.	44
3.3.1	Modelación del Sistema	45
3.3.2	Software de simulación para modelar los casos	46
3.3.3	Construcción del modelo.....	47
3.3.4	Simulaciones.....	48
3.3.5	Generación de datos para entrenamiento y verificación.....	51



3.4	DISEÑO Y CONSTRUCCIÓN DEL MODELO ANFIS	52
3.4.1	Formulación del problema	52
3.4.2	Desarrollo del Algoritmo	54
3.4.3	Metodología para Detección y Clasificación de la Falla:	56
3.4.4	Construcción del Modelo	58
3.5	ENTRENAMIENTO, VERIFICACIÓN Y VALIDACIÓN DEL MODELO.	63
3.5.1	Datos para Entrenamiento, Verificación y Validación.....	63
3.5.2	Evaluación del Error:	64
3.5.3	Entrenamiento, verificación y validación del modelo	64
CAPITULO 4. RESULTADOS		66
4.1	ENTRENAMIENTO, VERIFICACIÓN Y VALIDACIÓN DE LOS MODELOS ANALIZADOS ...	66
4.1.1	Resultados preliminares usando como datos de entrada el valor representativo en la ventana de falla	66
4.1.2	Resultados usando el registro de fallas completo.....	70
4.1.3	Resultados de los 4 ANFIS para las corrientes de las fases A, B y C y corriente de secuencia cero.....	72
4.1.4	Resultados para el ANFIS tomando como datos de entrada las corrientes de las fases A, B, C y corriente de secuencia cero en conjunto.....	77
4.2	ANÁLISIS DEL PROCESO DE ENTRENAMIENTO, VERIFICACIÓN Y VALIDACIÓN	81
4.3	EJEMPLO DE APLICACIÓN DEL MODELO	82
CAPITULO 5. CONCLUSIONES Y TRABAJOS FUTUROS.....		88
5.1	CONCLUSIONES	88
5.2	TRABAJOS FUTUROS.....	89
Bibliografía		91
ANEXOS.....		94
A. REGISTRADORES DE FALLAS Y EVENTOS EN LÍNEAS DE TRANSMISIÓN ELÉCTRICAS.....		95
A.1	ANÁLISIS POST-OPERATIVO	95
A.2	IMPORTANCIA DE LOS REGISTRADORES DE FALLA	96



A.3	FORMATO COMTRADE.....	98
B.	PROCESAMIENTO DE SEÑALES.....	101
C.	PARÁMETROS DEL SISTEMA DE PRUEBA	104
D.	SISTEMAS NEURODIFUSOS.....	108
D.1	REDES NEURONALES	108
D.2	SISTEMAS DIFUSOS	116
D.3	SISTEMAS LÓGICOS DIFUSOS.....	123
D.4	SISTEMAS NEURO-DIFUSOS.....	126
D.5	ANFIS: ADAPTIVE-NETWORK-BASED FUZZY INFERENCE SYSTEM	129
D.6	AGRUPAMIENTO DE DATOS (CLUSTERING)	133
E.	PROCESO DE ENTRENAMIENTO ANFIS.....	135



Índice de Figuras

Figura 2.1 Falla Trifásica: Diagrama equivalente y señal característica	26
Figura 2.2 Falla Fase-Tierra. Diagrama equivalente y señal característica.....	27
Figura 2.3 Falla Fase-Fase. Diagrama equivalente y señal característica.....	29
Figura 2.4 falla Fase-Fase-Tierra. Diagrama equivalente y señal característica.....	30
Figura 3.1 Diagrama de Flujo para la obtención de señales características de los COMTRADE .	39
Figura 3.2 Diagrama de Flujo para la obtención de patrones de entrenamiento y verificación del ANFIS	46
Figura 3.3 Modelo básico para la simulación	47
Figura 3.4 Modelo básico en ATPDraw	48
Figura 3.5 Modelo para simulación de casos.	49
Figura 3.6 Diagrama para el Algoritmo de Detección y Clasificación de Fallas.....	55
Figura 3.7 Diagrama de flujo para la construcción del Modelo ANFIS para detección y clasificación de fallas	59
Figura 3.8 Utilización del ANFIS Editor GUI en MATLAB	62
Figura 4.1 Conjunto de datos de entrenamiento, verificación y validación VS. la salida deseada, para la corriente de la fase C.....	72
Figura 4.2 Funciones de pertenencia del FIS inicial, de la corriente de la fase C.....	73
Figura 4.3 Funciones de pertenencia de la corriente de la fase C posterior al entrenamiento y verificación.	73
Figura 4.4 Evolución del error de entrenamiento y verificación usando un ANFIS para la corriente de la Fase C como entrada	74
Figura 4.5 Salida FIS Vs los datos de entrenamiento de la corriente de la fase C.....	75
Figura 4.6 Salida FIS Vs los datos de verificación de la corriente de la fase C	75
Figura 4.7 Salida FIS Vs el valor de la corriente de la fase C normalizada, que evidencia la evolución de la clasificación.....	76
Figura 4.8 Salida FIS Vs los datos de validación de la corriente de la fase C.....	76
Figura 4.9 Conjunto de datos de entrenamiento, verificación y validación Vs la salida deseada	77
Figura 4.10 Funciones de pertenencia iniciales para las fases A, B, C y secuencia cero	78
Figura 4.11 Funciones de pertenencia optimizadas para las corrientes de fases y secuencia cero.	78
Figura 4.12 Evolución del error de entrenamiento y verificación usando un ANFIS para las corrientes de fase y secuencia cero como entrada	79
Figura 4.13 Salida FIS Vs los datos de entrenamiento	80
Figura 4.14 Salida FIS Vs los datos de verificación	80
Figura 4.15 Salida FIS Vs los datos de validación	81
Figura 4.16 Resultados de los 4 ANFIS para las corrientes de las fases A, B, C y secuencia cero, para el caso de una falla de alta impedancia tipo C-T.....	83
Figura 4.17 Resultados de los 4 ANFIS para las corrientes de las fases A, B, C y secuencia cero, para el caso de una falla de baja impedancia tipo C-T	84
Figura 4.18 Resultados del ANFIS para una falla tipo AB-T. 1) <i>Gráfica superior</i> : Salida ANFIS Vs Salida deseada. 2) <i>Gráfica inferior</i> : Salida ANFIS.....	85
Figura 4.19 Resultados del ANFIS Vs la salida deseada para una falla trifásica A-B-C	86



Figura 4.20 Resultados del ANFIS Vs. salida deseada para una falla tipo AB-T.....	87
Figura C.1 Estructuras Típicas de la red de 230 kV del SNT Ecuatoriano	105
Figura C.2 Resultados para una L/T de 100 Km.....	107
Figura D.1 Neurona Biológica	109
Figura D.2 Red Neuronal Artificial	109
Figura D.3 Componentes de una Neurona Artificial	110
Figura D.4 Red Neuronal Monocapa	112
Figura D.5 Red Neuronal Multicapa	112
Figura D.6 Red Neuronal Realimentada	113
Figura D.7 Red Neuronal Multicapa	115
Figura D.8 Incertezas estocástica y lingüística	117
Figura D.9 Conceptos de Lógica Difusa	119
Figura D.10 Funciones de Pertenencia. (a) Tipo Triangular. (b) Tipo Trapezoidal. (C) Tipo Gaussiana. (d) Tipo Campana Generalizada	120
Figura D.11 Sistema Lógico Difuso	124
Figura D.12 Diagrama de bloques de un sistema neuro-difuso	127
Figura D.13 Estructura de un sistema neuro-difuso.....	128
Figura D.14 (a) Un Fuzzy tipo Sugeno con dos entradas de primer orden modelado con dos reglas. (b) Arquitectura Equivalente ANFIS.....	130
Figura D.15 Clusterización o agrupamiento de datos	134
Figura E.1 Corrientes obtenidas para una falla tipo Fase A-T	135
Figura E.2 COMTRADE del Registro: Falla Fase A-T visto en SIGRA.....	136
Figura E.3 Falla Fase A-T, visto en MATLAB.....	136
Figura E.4 Valores RMS de la corriente de la fase A con falla a Tierra.....	137
Figura E.5 Conjunto de Datos para entrenamiento (+) y verificación (o) del ANFIS	138
Figura E.6 Funciones de pertenencia iniciales creados con genfis1: 3MF, tipo gbell	139
Figura E.7 Funciones de pertenencia iniciales creados con genfis2: 4MF, tipo gbell, ra=0.2 ...	139
Figura E.8 Estructura FIS, para 8MF, tipo gbell, una entrada.....	140
Figura E.9 Estructura FIS para 3MF, tipo gbell, 4 entradas	140
Figura E.10 Estructura FIS para 32MF, ra=0.2 y 4 entradas	141
Figura E.11 Funciones de Pertenencia ajustado a la salida del ANFIS: método GP	142
Figura E.12 Funciones de pertenencia ajustado a la salida del ANFIS: método SC.....	142
Figura E.13 Epochs Vs. Error de entrenamiento: GD. 3MF, gbell.....	143
Figura E.14 Epochs Vs. Error de entrenamiento: SC. 8MF, ra=0.1	144
Figura E.15 Salida ANFIS para los datos de entrenamiento. Método GP.....	145
Figura E.16 Salida ANFIS para los datos de verificación. Método GP.....	145
Figura E.17 Salida ANFIS para los datos de entrenamiento. Método SC	146
Figura E.18 Salida ANFIS para los datos de verificación. Método SC	146
Figura E.19 Conjunto de datos para validación.....	147
Figura E.20 Salida ANFIS para los datos de validación. Método GP.....	148
Figura E.21 Salida ANFIS para los datos de validación. Método SC	148



Índice de Tablas

Tabla 3.1 Fallas según el tipo de generador en los extremos de la línea.....	50
Tabla 3.2 Condiciones de operación para la obtención de datos	51
Tabla 3.3 Salida ANFIS. Método 1	57
Tabla 3.4 Salida ANFIS. Método 2	58
Tabla 4.1 Error MSE para diferentes ANFIS obtenidos mediante el método <i>Grid Partition</i> , para las fases A, B, C y secuencia cero.....	67
Tabla 4.2 Error MSE para diferentes ANFIS obtenidos mediante el método <i>Sustractive Clustering</i> , para las fases A, B, C y secuencia cero	67
Tabla 4.3 Error MSE para diferentes ANFIS obtenidos mediante los métodos <i>Grid Partition</i> y <i>Sustractive Clustering</i> , para las fases A, B, C y secuencia cero consideradas en conjunto	68
Tabla 4.4 Error MSE para diferentes ANFIS obtenidos mediante los métodos <i>Grid Partition</i> y <i>Sustractive Clustering</i> , para las fases A, B, C y secuencia cero consideradas en conjunto y por separado, pero con las muestras completas de cada registro.....	71
Tabla C.1 Datos Equivalentes de la S/E Zhoray	104
Tabla C.2 Datos Equivalentes de la S/E Milagro.....	104
Tabla C.3 Parámetros de los Generadores equivalentes	105
Tabla C.4 Parámetros de los conductores.....	106
Tabla C.5 Parámetros de la Línea Zhoray-Milagro 230 kV	107
Tabla D.1 Tipos de Redes Neuronales	111
Tabla D.2 Sintaxis de la Lógica Proposicional y de la Lógica Difusa	121
Tabla D.3 Semántica de la Lógica Proposicional y de la Lógica Difusa	122
Tabla D.4 Lógica Difusa Y Redes Neuronales.....	126
Tabla D.5 Dos pasos en el procedimiento de aprendizaje híbrido para el ANFIS	133



UNIVERSIDAD DE CUENCA
Fundada en 1867

Yo, Efrén Alvarado G., autor de la tesis "Algoritmo neuro-difuso para la detección y clasificación de fallas en líneas de transmisión eléctrica del sistema ecuatoriano usando simulaciones y datos de registradores de fallas", reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de Magister en Sistemas Eléctricos de Potencia. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor.

Cuenca, 22 de Marzo de 2013

Efrén Alvarado G.
CI. 0102575735

Cuenca Patrimonio Cultural de la Humanidad. Resolución de la UNESCO del 1 de diciembre de 1999

Av. 12 de Abril, Ciudadela Universitaria, Teléfono: 405 1000, Ext.: 1311, 1312, 1316
e-mail cdjbv@ucuenca.edu.ec casilla No. 1103
Cuenca - Ecuador



UNIVERSIDAD DE CUENCA
Fundada en 1867

Yo, Efrén Alvarado G., autor de la tesis "Algoritmo neuro-difuso para la detección y clasificación de fallas en líneas de transmisión eléctrica del sistema ecuatoriano usando simulaciones y datos de registradores de fallas", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor/a.

Cuenca, 22 de Marzo de 2013

Efrén Alvarado G.
CI. 0102575735

Cuenca Patrimonio Cultural de la Humanidad. Resolución de la UNESCO del 1 de diciembre de 1999

Av. 12 de Abril, Ciudadela Universitaria, Teléfono: 405 1000, Ext.: 1311, 1312, 1316
e-mail cdjbv@ucuenca.edu.ec casilla No. 1103
Cuenca - Ecuador



**UNIVERSIDAD DE CUENCA
FACULTAD DE INGENIERÍA
MAESTRÍA EN SISTEMAS ELÉCTRICOS DE POTENCIA**

“ALGORITMO NEURO-DIFUSO PARA LA DETECCIÓN Y CLASIFICACIÓN DE FALLAS EN LÍNEAS DE TRANSMISIÓN ELÉCTRICA DEL SISTEMA ECUATORIANO USANDO SIMULACIONES Y DATOS DE REGISTRADORES DE FALLAS”

**TESIS PREVIA LA OBTENCIÓN
DEL TÍTULO DE MAGISTER EN
SISTEMAS ELÉCTRICOS DE
POTENCIA**

AUTOR:

ING. EFRÉN VINICIO ALVARADO GUICHAY

DIRECTOR:

DR. SANTIAGO TORRES CONTRERAS

CUENCA, DICIEMBRE 2012



DEDICATORIA

Esta tesis va dedicada a mi madre la Sra. Inés Alvarado, porque gracias a ella con su ejemplo, de dedicación, humildad y disciplina, he logrado conseguir las metas propuestas.

A mi esposa Verónica, y mi hijo Danniell, por su apoyo y comprensión en las veces que no he podido estar con ellos, por cumplir con este proyecto.

Efrén Vinicio.



AGRADECIMIENTO

A Dios por darme la fortaleza para no claudicar en momentos difíciles que pudieron haber interrumpido este logro, y avanzar con éxito a culminar esta nueva etapa.

Mi profundo agradecimiento, al Dr. Santiago Torres, director de este trabajo y amigo, quien con su ayuda y experiencia en este tema, a pesar de la distancia, fueron un pilar fundamental, para la terminación de este proyecto.

Un agradecimiento especial, a la institución donde laboro CELEC EP y su Unidad de Negocio TRANSELECTRIC, a través del Ing. José López en su calidad de Subgerente de Operación y Mantenimiento, quien prestó las facilidades, para que parte de este proyecto, pueda plasmarse y concretarse, además que la información y conocimientos, no podían ser alcanzados, sin dicha institución.

Al Msc. Jhon A. Calderón, Coordinador de Estudios de Protecciones en la Dirección de Gestión de la Operación, Interconexión Eléctrica S.A. en Medellín, Colombia, por su ayuda incondicional, ya que gran parte de este proyecto, está basado en su tesis: "MODELO ADAPTATIVO DE INTELIGENCIA ARTIFICIAL PARA EL DIAGNÓSTICO AUTOMÁTICO DE FALLAS A PARTIR DE REGISTROS DE OSCILOPERTURBOGRAFIA".

A todos amigos y familiares, quienes de una u otra forma ayudaron y colaboraron con este proyecto, mis sinceros agradecimientos.

Efrén A.



ABREVIATURAS:

ANN	Artificial Neural Network
ANFIS	Adaptive Neuro-Fuzzy Inference System
ATP-EMTP	Alternative Transients Program – ElectroMagnetic Transients Program
CELEC EP	Corporación Eléctrica del Ecuador. Empresa Pública
CENACE	Centro Nacional de Control de Energía
COMTRADE	IEEE Standard Common Format for Transient data exchange for Power Systems
COT	Centro de Operaciones de Transmisión
DFR	Digital Fault Recorder
DFT	Discrete Fourier Transform
FIS	Fuzzy Inference System
FNN	Fuzzy Neural Network
GP	Grid Partition
HIF	High Impedance Fault
IA	Inteligencia Artificial
IEEE	Institute of Electrical and Electronics Engineers
IED	Intelligent Electronic Devices
LIF	Low Impedance Fault
L/T	Línea de Transmisión
MATLAB	Lenguaje de programación científico (Matrix Laboratory)
RMSE	Root Mean Squared Error
RMS	Root Mean Square
RNA	Redes Neuronales Artificiales
SC	Sustractive Clustering
SCADA	Sistema de control, supervisión y adquisición de datos
S/E	Subestación
SEP	Sistemas Eléctricos de Potencia
SIGRA	Powerful Analysis of all Protection Fault Records - Siemens
SLD	Sistemas Lógicos Difusos
SNT	Sistema Nacional de Transmisión
SOE	Sequence of Event
TRNDATA	Conjunto de datos para entrenamiento
CHKDATA	Conjunto de datos para verificación
VALDATA	Conjunto de datos para validación



SIMBOLOGIA

ω	Velocidad angular [rad/s]
V	Tensión [V]
I	Corriente [A]
Z	Impedancia [Ohms]
Z _f	Impedancia de Falla
t	Tiempo [s]
ϕ	Angulo de la tensión/corriente
I ₀	Corriente de secuencia cero
I ₁ , I _p	Corriente de secuencia positiva
I ₂ , I _n	Corriente de secuencia negativa
I _a , I _b , I _c	Corriente de fases a, b, c
R, L, C	Resistencia, inductancia, capacitancia
f	Frecuencia del sistema
F _s	Frecuencia de muestreo
N	Número de muestras del Registro
N _c	Número de muestras por ciclo
[X _n]	Matriz de datos de entrada normalizados
[X _r]	Matriz de datos reales
[X _s]	Matriz de datos simulados
[X _d]	Matriz de datos depurados
[Y]	Matriz de salida calculada
[D]	Matriz de salida estimada
[E]	Matriz de Error
[W]	Matriz de pesos sinópticos
u _A (x)	Función de Pertenencia del conjunto difuso A



CAPITULO 1. INTRODUCCIÓN

1.1 INTRODUCCIÓN

La importancia en garantizar la continuidad del servicio y el correcto funcionamiento de las redes eléctricas, ha hecho que las empresas encargadas de la transmisión y distribución deban cumplir con exigentes estándares de calidad en sus servicios. Uno de ellos es el análisis de fallas en líneas de transmisión con el fin de detectar y clasificar dichas eventualidades, establecer su causa y origen y dar pautas adecuadas para el restablecimiento del sistema; evitando así demoras en la normalización del servicio, disminuyendo en costos incurridos y aumentando la seguridad del sistema usando estrategias operativas adecuadas.

El diagnóstico automático de fallas en sistemas eléctricos así como la extracción de sus características son unas tareas complejas, por la cantidad de información involucrada que puede provenir de diversas fuentes tales como: i) SOE (*Sequence of Event*) - bitácora de señales producidas por los sistemas de protección, ii) SCADA (*Supervisory Control and Data Acquisition*) – adquisición de datos para control y supervisión del sistema en tiempo real e histórico, iii) DFR (*Digital Faul Recorder*) – dispositivos que producen los registros de oscilografías en los que se reportan corrientes y tensiones. Además la variabilidad presente en las fallas y la complejidad de sus características hacen de éste, un problema complejo de ser resuelto.

El diagnóstico de eventos en líneas de transmisión se basa en disponer de toda la información producto de un evento que ha causado la indisponibilidad de la línea. Los datos recolectados proporcionan información para cumplir dos objetivos: i) Identificación de eventos, y ii) detección y clasificación de fallas. En el proceso de identificación de eventos se pretende conocer la causa y evolución del evento, así como la operación del sistema de protección. En el proceso de detección y clasificación de la falla es necesario para la determinación de la dirección de la falla, la localización de la falla, la causa y tipo de la falla y la Impedancia de la falla.

Dicha información impacta en la oportunidad y certeza del diagnóstico, factores particularmente importantes para el análisis en tiempo real donde rápidamente deben tomarse medidas adecuadas para el restablecimiento del sistema eléctrico de potencia (SEP).

El uso de técnicas de inteligencia artificial tales como redes neuronales y lógica difusa para la detección y clasificación de fallas a partir de registros SOE y DFR provenientes de registradores de falla, ha probado ser efectivo para una amplia variedad de escenarios, según la literatura estudiada [1], [2], [3].

En este sentido es posible obtener modelos neuro-difusos, que nos proporcionen como salida información de la falla en una línea de transmisión, de manera de detectar y clasificar la falla adecuada y oportunamente con el



propósito de apoyar a la toma de decisiones en tiempo real durante el despeje de la falla o restablecimiento del sistema.

1.2 EXPLORACIÓN DE LA PROBLEMÁTICA

Luego de un evento de falla es necesario realizar el análisis de la falla para determinar aspectos relevantes del evento y reducir al mínimo el impacto causado; esta información permite un mayor soporte en la toma de decisiones al momento del restablecimiento del servicio eléctrico, minimizando el tiempo de indisponibilidad de la línea. Además la información obtenida del diagnóstico de fallas sirve para que el operador del sistema sea capaz de establecer las estrategias operativas adecuadas en el caso de presentarse un evento de falla.

Ciertas técnicas de inteligencia artificial han sido utilizadas para el diagnóstico de eventos, particularmente los sistemas expertos y las redes neuronales en combinación con otras técnicas, en algunos casos, como lógica difusa o computación evolutiva.

Hay varios ejemplos de aplicación para el diagnóstico de eventos, usando sistemas expertos que han probado ser eficientes; sin embargo los trabajos de investigación en los últimos años han estado enmarcados a mejorar el desempeño de los sistemas planteados, especialmente en el manejo de incertidumbre por falsa información o información incompleta (Métodos Difusos), su desempeño en tiempo real, y el mecanismo de aprendizaje (Redes Neuronales).

Las redes neuro-difusas, son sistemas que incorporan aspectos de las Redes Neuronales Artificiales (en inglés *Artificial Neural Networks-ANN*) en el sentido que son sistemas con la capacidad de aprender y generalizar conocimiento inherente en un conjunto de datos. Además incorporan aspectos de la lógica difusa ya que trabajan con razonamientos lógicos basados en reglas de inferencia, incorporan la posibilidad de trabajar con variables lingüísticas y, además, cambian el tratamiento del problema que hacen las ANNs por un tratamiento difuso. Esto a su vez permite trabajar con información obtenida de un conjunto de datos o del conocimiento experto específico.

La teoría de los sistemas difusos permite trabajar con información lingüística, pudiéndose interpretar la computación numérica usando etiquetas lingüísticas estipuladas por las funciones de pertenencia. Además una selección adecuada de reglas *If-Then* es el componente primordial de un sistema de inferencia difuso (*Fuzzy Inference System - FIS*) que permite modelar el conocimiento experto humano para una aplicación específica. Aunque un FIS tiene la representación del conocimiento estructurada en forma de reglas *If-Then*, carece de adaptabilidad necesaria para cambiar cuando se modifiquen las condiciones externas. Por esta razón se incorporan conceptos del aprendizaje de las ANNs a los FIS, cuyo resultado es un nuevo tipo de topologías conocidas como redes neuro-difusas.

Uno de los modelos neuro-difusos más conocidos son los algoritmos Adaptivos Neurodifusos (en inglés *Adaptive Neuro-Fuzzy Inference System –*



ANFIS) el cual fue desarrollado por Jang y Sun en 1993 y es funcionalmente equivalente a los sistemas de inferencia difusos. Las capacidades adaptativas de las redes ANFIS las hacen directamente aplicables a una gran cantidad de áreas como control adaptativo, procesamiento y filtrado de señales, clasificación de datos y extracción de características a partir de ejemplos, etc.

ANFIS usa un algoritmo de aprendizaje híbrido para identificar los parámetros de las funciones de pertenencia de los conjuntos de salidas de valores puntuales difusos, el tipo de inferencia difuso es del tipo Sugeno. La red adaptativa es una estructura de varias capas con nodos y enlaces direccionales a través de los cuales esos nodos son conectados, estas redes adaptativas están fundamentadas en principios de aprendizaje híbrido, es decir, que usa diferentes métodos de aprendizaje básico para el entrenamiento de la red [4].

1.3 ALCANCE Y DEFINICIÓN DEL TRABAJO DE INVESTIGACIÓN

Este trabajo de investigación proporcionará una fase inicial para el desarrollo de una herramienta computacional para la detección y clasificación de fallas en líneas de transmisión.

Se realizará la detección y clasificación de fallas, el cual será validado con registros reales de fallas, obtenidas del Sistema Nacional de Transmisión (SNT) de la empresa CELEC EP-TRANSELECTRIC y de esta manera proporcionar información que deberá ser procesada por los encargados de las maniobras de restablecimiento de líneas falladas, permitiendo operar con criterios de seguridad, oportunidad y confiabilidad.

La adaptación a los cambios topológicos que tiene una red de transmisión real, debido a las variaciones de las características eléctricas del SEP, son sin duda la motivación de la presente investigación. Se busca un modelo adaptivo de inteligencia artificial que considere diversas condiciones críticas extremas esperadas en un SEP cualquiera y que logre adaptarse a la variabilidad exigida por cualquier registro de falla nuevo, de tal manera que proporcione un diagnóstico automático acertado aún en situaciones de alto nivel de dificultad.

El problema del diagnóstico automático de fallas, involucra tópicos como la determinación de la causa de la falla, la localización de la falla y la identificación del componente fallado, sin embargo la presente investigación se centrará únicamente en la detección y clasificación de la falla, dejando como trabajo de investigación futuro otros temas del diagnóstico de fallas.

1.4 OBJETIVOS

El propósito de este trabajo es proponer un modelo de inteligencia artificial adaptivo para el diagnóstico automático de fallas en líneas de transmisión del sistema eléctrico Ecuatoriano a partir de registros de fallas obtenidos de eventos reales.

1.4.1 Objetivos específicos:



- a) Realizar el procesamiento de señales analógicas y digitales provenientes de los registros de fallas del SNT a 230 kV.
- b) Obtener un modelo para la simulación de la red para la generación de los patrones de entrenamiento y verificación del algoritmo ANFIS.
- c) Analizar, diseñar y construir un modelo de inteligencia artificial adaptivo neuro-difuso para la detección y clasificación de fallas en líneas de transmisión
- d) Entrenar, y verificar el modelo de inteligencia artificial para los diferentes casos de estudio simulados de una línea típica del sistema eléctrico ecuatoriano
- e) Analizar y validar el problema de detección y clasificación de fallas para el caso de la red del SNT utilizando los registros de fallas reales.
- f) Proponer el modelo para ser utilizado en tiempo real por la operadora del Centro de Control de Transmisión de CELEC EP-TRANSELECTRIC en el restablecimiento de líneas de transmisión falladas.

1.5 ESTRUCTURA DEL TRABAJO

Este trabajo en el capítulo 1, expone la justificación, la exploración de la problemática y los objetivos de la investigación. En el capítulo 2, se presenta una introducción teórica y el estado del arte, referente a investigaciones desarrolladas sobre el tema, la cual sirven de pauta, para la metodología propuesta.

En el siguiente capítulo, se inicia con el desarrollo del trabajo. Primero con la preparación de datos obtenidos desde un registro de fallas reales de una línea de transmisión del sistema eléctrico ecuatoriano. Luego con la generación de patrones para entrenamiento y verificación del modelo, mediante la simulación de un SEP que describe a una línea de transmisión típica ante diversos escenarios de fallas. Después con el diseño y construcción del modelo ANFIS para la detección y clasificación de fallas. Finalmente con el entrenamiento y verificación del modelo a partir de datos simulados y su validación mediante datos reales del SNT Ecuatoriano.

En el capítulo 4, se expone los resultados del algoritmo para el proceso de entrenamiento, verificación y validación y ejemplos de aplicación con el análisis de algunas fallas ocurridas en líneas de transmisión del sistema eléctrico ecuatoriano. Las conclusiones y trabajos futuros, se exponen en el capítulo 5.

En los Anexos se presentan las herramientas y el desarrollo de temas específicos que fueron utilizados para el desarrollo del trabajo.



CAPITULO 2. ESTADO DEL ARTE

2.1 CONCEPTOS BÁSICOS

Con el propósito de definir algunos conceptos utilizados en este trabajo, se hace referencia a la literatura expuesta en las referencias [5] [6] [7].

2.1.1 Estudios en los Sistemas Eléctricos de Potencia

El diseño, construcción y operación del sistema de generación, transporte y distribución de energía eléctrica se realiza con el objetivo de proporcionar el suministro eléctrico con una adecuada calidad y seguridad, de la manera más económica posible. Para conseguir estos objetivos es necesario comprender y cuantificar, con la mayor exactitud posible, los fenómenos que afectan a los sistemas eléctricos: descargas atmosféricas, conexión y desconexión por maniobra, transitorio electromecánico, transitorio lento, etc [5].

El tipo de estudio o análisis del sistema de energía eléctrica y los elementos a considerar en el modelo, están relacionados con la duración del fenómeno a analizar. De esta forma, los estudios analizan el sistema eléctrico en diferentes condiciones de funcionamiento:

- Condiciones de régimen permanente, bajo las cuales todas las variables y parámetros se consideran constantes durante el periodo de estudio.
- Condiciones transitorias lentas, que se deben a los patrones normales de cambios de topología y las acciones de los controles automáticos (voltaje y frecuencia).
- Condiciones transitorias electromecánicas, que pertenecen a las oscilaciones electromecánicas de las maquinas y las acciones de los sistemas de control primario de tensión y frecuencia.
- Condiciones transitorias electromagnéticas, que corresponden a los fenómenos electromagnéticos rápidos, en los cuales es importante considerar la velocidad de propagación del fenómeno y se puede despreciar los fenómenos electromecánicos.

Estudios en régimen permanente [5].

Es el análisis del sistema eléctrico para conocer su funcionamiento en estado estacionario y son: El cálculo de flujo de cargas, el cálculo de cortocircuitos y propagación de armónicos.

Flujos de Cargas

Consiste en obtener las condiciones de operación del sistema de energía eléctrica en régimen permanente. Dadas las potencias de entrega y consumo (conocidas) se trata de encontrar las tensiones, en modulo y ángulo, en cada nodo de la red. A partir de estos valores, se determina el flujo de potencia activa y reactiva en cada elemento del sistema, las pérdidas en dichos elementos, la potencia reactiva generada o demandada en cada nodo de control de tensión, etc. Este análisis es empleado en la operación y planificación del sistema. En la operación diaria, es la base del análisis de



seguridad del sistema (identificación de sobrecargas, tensiones fuera de límites, etc.). En la planificación, permite simular el estado en el que se encontraría el sistema ante los distintos escenarios.

Cálculo de cortocircuitos

El problema del cálculo de cortocircuitos consiste en obtener el estado del sistema cuando se produce una situación de falla. Se trata también de una herramienta básica, para la operación y planificación del sistema eléctrico, ya que permite conocer la máxima corriente de cortocircuito en un punto cualquiera del sistema. Esto resulta imprescindible para el correcto dimensionamiento de los equipos que irán conectados en dicho punto y el diseño de los sistemas de detección y protección, así como para el estudio del sistema en situaciones de estabilidad transitoria.

Propagación de armónicos

El estudio de la propagación de armónicos se basa en la determinación de las impedancias del sistema a las frecuencias armónicas y la propagación de las ondas de tensión e intensidad desde los elementos generadores de armónicos al resto del sistema. En teoría se supone que en el punto de conexión de un usuario con el sistema eléctrico la tensión es una onda sinusoidal pura de frecuencia fundamental, pero en la realidad este objetivo nunca se alcanza, debido a que la onda se deteriora durante su propagación, dando lugar a una deformación conocida como distorsión armónica. Esta distorsión se debe fundamentalmente a cargas alimentadas por dispositivos que no tienen una característica tensión-corriente lineal, lo que provoca la aparición de tensiones y corrientes armónicas que se propagan por el sistema y que pueden incidir en otros usuarios.

Estudios en régimen transitorio

En este tipo de estudios se simula el comportamiento del SEP según va evolucionando en el tiempo, de un estado a otro posterior. Dependiendo del tipo de fenómeno que se quiera estudiar, el tiempo de transición entre estados (horizonte de estudio) puede comprender desde unos pocos microsegundos hasta varias horas.

Transitorios lentos

Se analiza la evolución del sistema de energía eléctrica en periodos de tiempo que van desde minutos hasta varias horas. Su objetivo consiste en estudiar la dinámica del sistema asociada con el control de la tensión y de la frecuencia. El método de trabajo se basa en discretizar el intervalo de estudio y efectuar flujos de carga consecutivos pero teniendo en cuenta: el control primario de la frecuencia, el control secundario de la frecuencia, los cambiadores de tomas de los transformadores, el control secundario de la tensión y la respuesta de los elementos del sistema (disparo por sobrecarga de elementos, deslastre de cargas o funcionamiento en isla, disparo de generadores, etc).

Transitorios electromecánicos

Se analizan fenómenos transitorios rápidos provocados por las oscilaciones electromecánicas de los rotores de los generadores y las interacciones con



los dispositivos de control. El periodo de tiempo en el que se trabaja es del orden de unos milisegundos a unos pocos segundos (0.1s / 10s). Estas oscilaciones pueden dar lugar a una pérdida de estabilidad del sistema. Por una parte, se puede perder el sincronismo de los generadores y por otra parte puede producirse el colapso de tensión. Los estudios de estabilidad analizan tanto la estabilidad de ángulo como la estabilidad de tensión.

Estabilidad de ángulo. Analiza la dinámica de los movimientos del rotor alrededor del punto de sincronismo. Dependiendo de la amplitud de dichos movimientos (perturbaciones) se distingue entre:

- Estabilidad transitoria: analiza los movimientos de elevada amplitud durante perturbaciones fortuitas (cortocircuitos, etc).
- Estabilidad estática o de pequeña señal: tiene en cuenta las fluctuaciones de pequeña amplitud que se producen durante la operación normal del sistema, por la interacción de los controles ante pequeñas perturbaciones alrededor del punto de equilibrio.

El objetivo de estos estudios consiste en analizar si, tras una perturbación, el sistema se vuelve inestable o vuelve a un estado de operación estable.

Estabilidad de tensión. Analiza la capacidad de un sistema eléctrico para alcanzar niveles de tensión fijos, mayores que cero, en todos sus nodos. Cuando un sistema sufre inestabilidad de tensión, se produce un colapso de las tensiones que lleva a una pérdida parcial o total del sistema. Junto con la estabilidad de tensión, también se presentan problemas de inestabilidad de ángulo, aunque el colapso de tensión se produce antes que la separación de ángulos.

Transitorios electromagnéticos

Estos estudios analizan fenómenos muy rápidos (microsegundos), de forma que las ondas de tensión e intensidad ya no se pueden suponer como sinusoides que varían a 60 Hz. Este tipo de estudios requieren una representación diferente, que puede ser muy detallada, de la dinámica de alguno de los elementos del sistema que intervienen en el estudio. Los fenómenos que se incluyen en el ámbito de los transitorios electromagnéticos son: sobretensiones provocados por ondas tipo rayo, sobretensiones provocadas por maniobras de interruptores y seccionadores, fenómenos de ferresonancia, resonancia subsíncrona, respuesta de sistemas de protección de alta velocidad, etc.

Modelos de elementos del sistema de energía eléctrica

El estudio realizado sobre los sistemas de energía eléctrica se basa en la simulación de fenómenos reales, usando modelos que presentan el mismo comportamiento que el sistema real. En la práctica, en el sistema eléctrico se presentan todo tipo de fenómenos, algunas veces simultáneamente. Dadas las diferentes características entre dichos fenómenos (por ejemplo entre estabilidad y transitorios electromagnéticos) no es posible definir un único modelo capaz de dar una imagen real para todo el rango de constantes de tiempo.



La tarea de desarrollar un modelo de un sistema se puede dividir en dos grupos: la determinación de la estructura del modelo y el hecho de proporcionar los datos a dicho modelo. La determinación de la estructura fija las características que se deben considerar del sistema eléctrico, mientras que los datos suministran los valores de dichas características.

Simulación de los sistemas eléctricos de potencia

La simulación consiste en una serie de técnicas que imitan o simulan las operaciones de diferentes procesos de la vida real. Para analizar estos procesos desde el punto de vista científico, a menudo hay que realizar un conjunto de suposiciones acerca de cómo se desarrollan dichos procesos. Estas suposiciones, que normalmente adoptan la forma de ecuaciones matemáticas o relaciones lógicas, constituyen los modelos.

La simulación incluye tanto la construcción del modelo como el proceso de experimentación para estudiar un sistema. La simulación permite experimentar con el modelo antes que con el sistema real, permitiendo examinar el sistema y realizar cambios y nuevos diseños sin necesidad de cambios físicos o instalaciones adicionales.

Si las relaciones que componen el modelo son suficientemente simples pueden utilizarse métodos matemáticos sencillos para obtener información exacta acerca del comportamiento del sistema a analizar. Sin embargo, la mayoría de los sistemas reales son demasiado complejos para ser analizados mediante modelos que sean resolubles por métodos analíticos sencillos. Por lo tanto, estos modelos se deben analizar mediante técnicas más complejas. Estas técnicas utilizan ordenadores para evaluar numéricamente los modelos desarrollados durante un determinado periodo de tiempo.

Para el análisis de la red es necesario recurrir a un proceso de cálculo o de simulación que reproduzca el comportamiento y los fenómenos que se producen en un sistema eléctrico y que permita conocer tanto la respuesta del sistema ante condiciones de funcionamiento normal y de fallas, como las consecuencias sobre los parámetros fundamentales del sistema ante dichas situaciones [5].

2.1.2 Análisis de fallas en sistemas eléctricos de potencia

***Cortocircuitos* [6]**

De forma general, se denomina falla o cortocircuito a la conexión accidental, a través de una impedancia relativamente baja, de dos o más puntos del sistema que tienen potenciales diferentes. Los cortocircuitos en general se producen al fallar el aislamiento, debido a diferentes causas como: pérdida de las propiedades aislantes del medio (envejecimiento, calentamiento, contaminación, etc), sobretensiones (tanto de origen externo como interno) o efectos mecánicos diversos (roturas, deformaciones, desplazamientos, etc).

Los efectos perjudiciales que las fallas provocan son numerosos y están asociadas, fundamentalmente a las corrientes elevadas que se pueden



establecer en el sistema. Los efectos pueden ser: Calentamiento de conductores por efecto Joule, que en función del valor y la duración de la corriente de cortocircuito puede provocar deterioros irreversibles. Esfuerzos electrodinámicos, con la posibilidad de roturas y desplazamientos bruscos que pueden dar lugar a nuevas faltas. Variaciones de tensión, con caídas en las fases involucradas en el cortocircuito y eventuales elevaciones en las otras fases.

Los cortocircuitos se clasifican en varias categorías, según el número de fases implicadas en la falla y según la existencia o no de una conexión a tierra. De esta manera, se pueden distinguir entre fallas serie, simultáneas y paralelas. Las fallas paralelo que son las más usuales, pueden ser: Trifásicas, bifásicas sin contacto a tierra, bifásicas con contacto a tierra y monofásicas.

Las fallas trifásicas se denominan también faltas simétricas, ya que al afectar a las tres fases por igual, el sistema de tensiones e intensidades continúa siendo equilibrado tras la falla. Por el contrario, las fallas monofásicas y bifásicas, con o sin contacto a tierra, afectan de distinta manera a las diferentes fases, por lo que dan lugar a sistemas de tensiones e intensidades desequilibrados, denominándose por este motivo fallas asimétricas.

En un sistema eléctrico, las fallas monofásicas son las más frecuentes (80%), seguidas de las fallas bifásicas (15%) y por último las trifásicas (5%). La falla trifásica, a pesar de ser el tipo de falla menos habitual, es la que generalmente se considera al realizar los estudios de cortocircuito, pues suele ser la situación más desfavorable por presentar, por lo general, la mayor intensidad de falla.

Los cálculos de cortocircuito consisten en determinar las corrientes que van a aparecer en un sistema eléctrico cuando se producen distintos tipos de falla, en diferentes puntos del sistema. El conocimiento de las intensidades que pueden presentarse en caso de un cortocircuito permite:

- Seleccionar y coordinar los equipos de protección con el objeto de detectar la zona donde se produce el fallo y así separarla del sistema para que no afecte al funcionamiento del resto de la red.
- Seleccionar las características de los equipos destinados a aislar la zona de la red con falta, con el objeto de que los interruptores y seccionadores aguanten las sollicitaciones térmicas y electromecánicas que se producen durante el cortocircuito.
- Seleccionar y diseñar los equipos que forman la red, para que aguanten las sollicitaciones provocadas por una situación de falla durante el tiempo que transcurre entre su aparición y su eliminación por parte de los sistemas de protección.

El cálculo de las corrientes de falla puede dividirse en dos tipos principales:

- Averías por cortocircuito de las tres fases, cuando la red esta equilibrada eléctricamente. Para estos cálculos pueden utilizarse



circuitos equivalentes normales monofásicos, como en el caso de los cálculos de flujos ordinarios de carga.

- Averías distintas de los cortocircuitos trifásicos cuando la red esta eléctricamente no equilibrada. Para facilitar estos cálculos se utiliza un método especial para tratar redes no equilibradas, conocidas como método de las *componentes simétricas*.

Fallas en sistemas eléctricos de potencia [6] [7]

Las técnicas de modelado y estudio habituales de las redes eléctricas se puede dividir en tres regímenes: Estacionario, electromecánico y electromagnético. En el caso del análisis de fallas, se tiene un proceso claramente electromagnético donde la red en una situación estacionaria sufre una modificación brusca de su topología. De este modo para el análisis de una determinada falla, la red debe modelarse por las ecuaciones diferenciales de sus elementos. Esto en ciertos casos no es práctico cuando se requiere el cálculo de redes con cientos de nodos y ramas. Por ello, las normas existentes y el cálculo habitual de cortocircuitos admiten como suficiente aproximación el modelo estacionario de la red [6].

Los tipos de falla que se analizan en los SEP entre fases de un mismo equipo son:

Falla Trifásica
Falla Fase – Tierra
Falla Fase – Fase
Falla Dos Fases – Tierra

Asumiendo que las corrientes de carga son despreciables de manera que los generadores estén en vacío y con voltaje 1 pu, y “F” es el nodo o barra donde se produce la falla, se tiene [7]:

a) Falla Trifásica

Se presenta cuando las tres fases entran en contacto, con caídas de voltaje y aumento de corriente similar para las tres fases. En la Figura se aprecia un ejemplo de las variaciones de corriente ante la presencia de una falla trifásica aislada.

En el punto de la falla:

$$[V_a^F \quad V_b^F \quad V_c^F] = [0 \quad 0 \quad 0]$$

$$I_a^F + I_b^F + I_c^F = 0$$

(2.1)

Transformando a componentes simétricas se tiene:

$$[V_1^F \quad V_2^F \quad V_0^F] = [0 \quad 0 \quad 0]$$

$$[I_1^F \quad I_2^F \quad I_0^F] = [I_a^F \quad 0 \quad 0]$$

(2.2)

El circuito equivalente está formado por la componente de secuencia positiva.

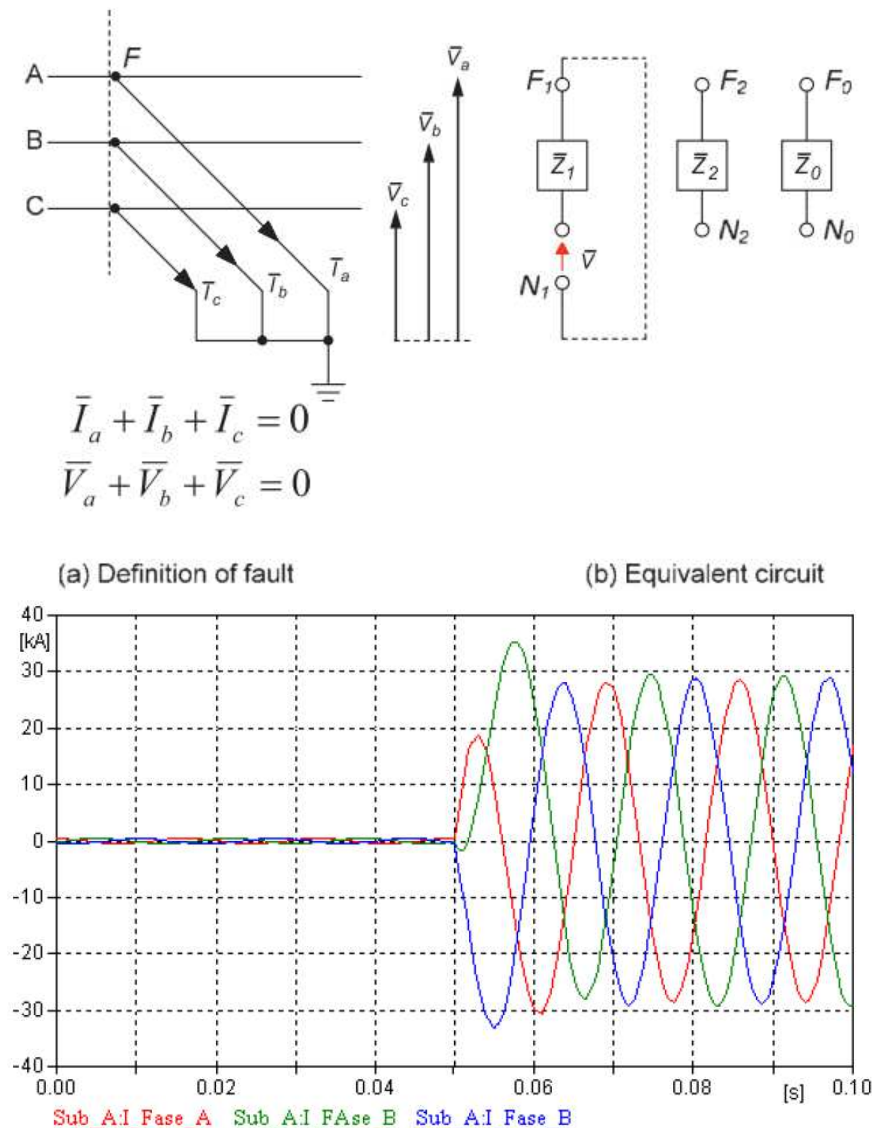


Figura 2.1 Falla Trifásica: Diagrama equivalente y señal característica

b) Falla Fase – Tierra

Este tipo de falla únicamente afecta una sola fase del SEP, presentándose un aumento de corriente y caída de voltaje en la fase que presenta el problema. La falla puede ser de baja impedancia (falla franca) con valores cercanos a 0 ohmios, de media-alta ó de alta impedancia con valores mayores a 30 y 60 ohmios, respectivamente. Las fallas de alta impedancia no presentan gran variación en la variable corriente de la fase fallada por lo que a veces no se detecta fácilmente ya que pueden ser vistas como un aumento en la demanda de energía del SEP. En contraste las fallas francas presentan un importante aumento de la corriente, lo cual facilita su detección.

Las fallas de alta impedancia, son producidas normalmente por árboles, cometas, fuego bajo la línea, flámeos de aisladores, entre otros. En la Figura 2.2 se aprecian las curvas de corriente y voltaje de la fase A, ante una falla franca en esta fase.

En el punto de falla se tiene:

$$[V_a^F \quad V_b^F \quad V_c^F] = [0 \quad V_b^F \quad V_c^F]$$

$$[I_a^F \quad I_b^F \quad I_c^F] = [I_a^F \quad 0 \quad 0]$$

(2.3)

Pasando a componente simétricas:

$$[I_1^F \quad I_2^F \quad I_0^F] = [I_a \quad I_a \quad I_a]/3$$

$$V_1^F + V_2^F + V_0^F = 0$$

(2.4)

El circuito equivalente se forma con las tres redes de secuencia conectadas en serie.





Figura 2.2 Falla Fase-Tierra. Diagrama equivalente y señal característica



c) Falla Fase – Fase

Se presenta entre dos fases de forma aislada de la tierra. Este tipo de falla es frecuente cuando se realizan quemas debajo de la línea, lo que ocasiona cambios en la rigidez dieléctrica del aire y en sus propiedades de conducción. En la Figura 2.3 se observa un ejemplo del comportamiento de la corriente en las tres fases cuando se presenta esta falla.

Si se produce una falla entre las fases b y c en el punto F, se tiene:

$$\begin{aligned} [V_a^F \quad V_b^F \quad V_c^F] &= [V_a^F \quad V_b^F \quad V_b^F] \\ [I_a^F \quad I_b^F \quad I_c^F] &= [0 \quad I_b^F \quad -I_b^F] \end{aligned} \tag{2.5}$$

Descomponiendo en componentes simétricas se tiene:

$$\begin{aligned} V_1^F &= V_2^F \\ I_1^F &= -I_2^F \end{aligned} \tag{2.6}$$

El circuito equivalente del sistema para este tipo de falla, es con las redes de secuencia positiva y negativa en paralelo.


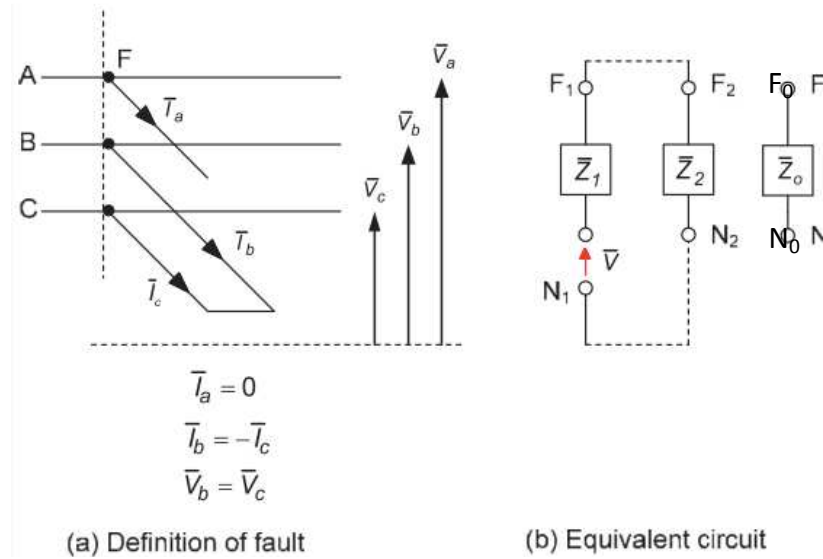


Figura 2.3 Falla Fase-Fase. Diagrama equivalente y señal característica

d) Falla Dos Fases – Tierra

En esta falla se afectan dos fases del SEP, generalmente por la caída de una de las fases, haciendo contacto con otro cable y con elemento externo que conduce a tierra. Cuando se presenta esta falla aumenta la corriente en ambas fases y disminuye el voltaje. En la Figura 2.4 se puede apreciar el comportamiento de la corriente frente a este tipo de falla.

Si las fases b y c se ponen a tierra, se tiene:

$$[V_a^F \quad V_b^F \quad V_c^F] = [V_a^F \quad 0 \quad 0]$$

$$[I_a^F \quad I_b^F \quad I_c^F] = [0 \quad I_b^F \quad I_c^F]$$

(2.7)

Cambiando a componentes de secuencia:

$$I_1 = -(I_2 + I_0)$$

$$V_1 = V_2 = V_0$$

(2.8)

Lo que significa que las tres redes de secuencia están conectadas en paralelo.





Figura 2.4 falla Fase-Fase-Tierra. Diagrama equivalente y señal característica



2.2 ENFOQUES PARA RESOLVER EL PROBLEMA DE DIAGNÓSTICO DE FALLAS

Muchos son los métodos empleados para resolver el problema del diagnóstico de fallas, sin embargo en los últimos tiempos se han desarrollado nuevas técnicas que complementan o suplementan los métodos tradicionales desde el punto de vista matemático y son las llamadas métodos de inteligencia artificial

Los sistemas de inteligencia artificial son herramientas atractivas e interesantes para resolver en tiempos de cálculo razonables, problemas complejos no lineales, como es el caso del problema del análisis de fallas en los SEP.

La modelación de sistemas basados en herramientas matemáticas convencionales (por ejemplo, ecuaciones diferenciales) no es el adecuado para trabajar con sistemas mal definidos o inciertos. Por el contrario, un sistema de inferencia difusa empleando reglas difusas *if-then* puede modelar los aspectos cualitativos del conocimiento humano y los procesos de razonamiento, sin el empleo de los análisis cuantitativos.

Los sistemas neuro-difusos tienen su origen en la teoría de la inteligencia artificial y han estado en continuo desarrollo desde mediados de los años 70 y su aplicación esta en campos como control automático, clasificación de datos, análisis de decisión, sistemas expertos entre otros. Estas técnicas son conceptualmente fáciles de entender, flexibles a los cambios de topología de la red, tolerantes a datos imprecisos, y sobre todo pueden modelar funciones no lineales, y ser construidos sobre la base de la experiencia del experto.

La metodología difusa más comúnmente usada para modelos lineales, es el método de inferencia difusa de Mamdani, desarrollado por Ebrahim Mamdani en 1975, mientras que el método de inferencia difuso tipo Sugeno, desarrollado en 1985 por Takagi-Sugeno-Kang modela elementos lineales como constantes [8].

Por otro lado, la introducción de técnicas de aprendizaje en las redes neuronales estudiado por Rosenblatt en 1961 y las muchas investigaciones en este campo para finales de los años 90 muestran diferentes aplicaciones como son el ajuste de funciones, reconocimiento de patrones, agrupamiento de datos entre otros [9].

En este sentido, muchas investigaciones se han desarrollado desde los años 90 relacionadas con el diagnóstico de fallas, las mismas que principalmente se dirigen para determinar:

- Direccionalidad de la falla.
- Clasificación de la falla.
- Localización de la falla.
- Causa de la falla.



2.3 ANÁLISIS DE PRINCIPALES REFERENCIAS BIBLIOGRÁFICAS

En la referencia [10], se usa las primeras y segundas derivadas de la señal de entrada para crear los fasores de los valores muestreados. Para detectar el instante de la falla este método se basa en comparaciones, dentro de un umbral establecido, entre valores obtenidos para una ventana de tiempo o de muestra y la ventana inmediatamente anterior a esta. Este algoritmo, presenta un gran inconveniente para muchos de los eventos al intentar determinar un umbral que sirviera para todos los casos; es decir se necesitaría un umbral adaptativo pues los valores varían mucho de acuerdo a las condiciones de la falla.

En la investigación realizada en la referencia [11], se utiliza para el diagnóstico, señales de corriente superimpuestas de las componentes de secuencia, obtenidas mediante la diferencia existente entre la muestra de corriente actual y la muestra del ciclo anterior. Las magnitudes de cada componente de secuencia son comparadas con la magnitud de la misma componente de secuencia, tomando un ciclo antes, si existe una diferencia considerada fuera de un rango establecido, entonces, se presume la existencia de una anomalía. En ese trabajo se emplea ANFIS como técnica matemática para solucionar el problema. El estudio muestra que esta propuesta es capaz de clasificar correctamente diferentes tipos de fallas y es evaluado usando varias características de fallas, mostrando resultados satisfactorios para diferentes combinaciones de condiciones de fallas, como: tipo de falla, resistencia de falla, ángulo de comienzo de falla, localización de falla, dirección de flujo de potencia pre-falla y nivel de cortocircuito del sistema.

El trabajo expuesto en [12], indica que para la clasificación de la falla, los rasgos característicos de diferentes tipos de fallo se encuentran en términos de una variable delta obtenida de las relaciones normalizadas existentes entre el máximo absoluto de las muestras post-falla de corrientes de las tres fases. Las diferencias de esos valores normalizados corresponden a los valores deltas requeridos. Las características de los diferentes tipos de falla están clasificados mediante rangos establecidos entre valores deltas especificados entre alto, medio y bajo. Los resultados obtenidos, mediante este procedimiento, para sistemas de 200-400 kV, concluyen que el método es bastante robusto.

En la metodología descrita por [13], se utiliza ANFIS para localización de fallas en un sistema de distribución, en términos de sus coordenadas geométricas y su determinación del tipo de falla. Utiliza valores RMS de corrientes trifásicas post-falla, mediante varios ANFIS en serie y paralelo; las salidas representan las coordenadas de la red del punto de falla y un número entre 0 y 10 representa el tipo de falla. De los resultados se observa que el nivel de errores de localización es bajo, demostrando que la metodología empleada es satisfactoria para la clasificación de fallas, además de tener beneficios como bajo costo, aplicación simple y fácil reconfiguración del sistema.



La propuesta de [14] aplica ANFIS para la clasificación de fallas en líneas de transmisión a partir de la componente fundamental de las mediciones de voltajes y corrientes. Los datos de entrada de la unidad de detección de falla FNN (*Fuzzy Neural Networks*) son las impedancias de las tres fases divididas por sus valores sin falla y de acuerdo a un umbral de decisión, se establece la condición de falla o no falla. Para la unidad de clasificación, los datos de entrada del ANFIS son las impedancias de las tres fases y la componente de secuencia cero de las corrientes divididas para sus valores sin falla, la salida del FNN clasifica de acuerdo a un umbral fallas de una fase a tierra, fallas fase-fase, fallas doble fase a tierra, y fallas trifásicas. Los resultados, aparentemente satisfactorios, no ofrecen un análisis del error incurrido.

La propuesta en [15] presenta una técnica neuro-difusa para clasificación de fallas en sistemas de transmisión. Se basa en el estudio de la relación entre las componentes simétricas de la corriente y la corriente nominal para obtener valores que determinen la existencia o no de la falla y la clasificación de la falla. La investigación muestra que la técnica utilizada es rápida, precisa y robusta, es decir, en principio es adaptable a varias condiciones del sistema. Esto significa que realizando un refinamiento adicional a este modelo puede ser implementado en un sistema de potencia real y en tiempo real para monitorear ocurrencias de falla y tomar las acciones que sean necesarias.

En la referencia [16], se utiliza ANFIS para la localización de fallas en líneas de transmisión de Extra Alta Tensión. Utiliza formas de onda de voltajes y corrientes de los localizadores de falla como entradas a 11 FIS para clasificar y localizar la falla, con el siguiente criterio: 1 existencia de falla y 0 no existencia de falla. De los resultados obtenidos, se aprecia niveles de error bajos en la mayoría de casos, que demuestran su alta confiabilidad

La investigación realizada en [17] utiliza FIS y ANN para la localización de fallas basados en técnicas sobre el uso de wavelet (coeficientes MRA-*Multi resolution analysis*), demostrando la superioridad del FIS sobre un ANN para esta aplicación

La referencia [18] propone un relé de distancia basado sobre FNN (*Fuzzy Neural Networks*), en donde la clasificación y la localización son llevados a cabo por diferentes FNN's. El clasificador FNN usa los picos de las formas de onda de corrientes y voltaje normalizados como entradas, mientras que los FNN's para la localización de la falla en adición a la normalización requiere una relación derivada de la componente DC de una de las formas de onda de las corrientes considerada como entrada. Los resultados indican que la red entrenada es capaz de proveer una rápida y precisa clasificación y localización de la falla para una variedad de condiciones del sistema.

Otras investigaciones encontradas en [19] [20] [21] hacen uso de las redes neuronales artificiales para la clasificación y localización de fallas en líneas de doble circuito.

El presente trabajo de investigación ha considerado los trabajos desarrollados por ISA Colombia, donde se ha puesto en marcha una herramienta



computacional, utilizando técnicas de inteligencia artificial para el análisis y diagnóstico de fallas en el Sistema de Transmisión Eléctrico Colombiano, obteniendo resultados razonables.

La referencia [1] presenta el Diagnóstico Automático de Fallas (DAF) a partir de registros de fallas que se presentan en un Sistema Eléctrico de Potencia, mediante modelos inteligentes y adaptativos, que aprenden de las experiencias para mejorar su desempeño en el tiempo y se adaptan a las condiciones exigidas por un SEP real. Esta investigación propone un Modelo Adaptativo de Inteligencia Artificial (MAIA), una Metodología de Entrenamiento y Validación Adaptativa (MEVA) y un Sistema Basado en Conocimiento (SBC) para integrar el DAF. La propuesta se inspira en dos aspectos del cerebro humano: el hardware ó conocimiento almacenado en sistemas conexionistas (redes neuronales y Teoría de Resonancia Adaptativa: entrenadas y validadas con MEVA) para reproducir capacidades asociadas a la inteligencia de bajo nivel, para reconocimiento de patrones (MAIA) y el software ó conocimiento intuitivo de más alto nivel, como el razonamiento aproximado (SBC). Finalmente, todo este conjunto MAIA + SBC se entrena y valida mediante MEVA con casos simulados y registros reales de la red de Interconexión Eléctrica S.A.

Otra propuesta estudiada en [2] presenta un algoritmo para la detección y clasificación de fallas, para tipos de fallas de alta impedancia (HIF) y de baja impedancia (LIF) mediante ANFIS. Las entradas al ANFIS se basan en valores RMS de las tres corrientes de fase y la corriente de secuencia cero. Los resultados muestran que un modelo ANFIS puede de manera precisa detectar y clasificar fallas dentro de un tiempo de medio ciclo.

La investigación presentada en [3] muestra dos nuevos modelos para la localización del punto de falla monofásica en Sistemas Eléctricos de Potencia (SEP), a través de dos técnicas de inteligencia artificial (ANN y ANFIS) que permiten estimar la localización del punto de falla en la línea de transmisión, para baja, media-alta y alta impedancia. Para la determinación de las variables de interés, realiza un análisis del comportamiento mediante el análisis adimensional, que permite determinar relaciones entre grupos de variables. Como señales de interés se tuvieron en cuenta los fasores superimpuestos de corriente y voltaje, los cuales se calculan mediante la diferencia de un ciclo completo de corriente y voltaje en pre-falla y post-falla. Posteriormente a través de un filtro de Fourier se obtiene la magnitud y ángulo para los fasores superimpuestos de primer y tercer armónico de la corriente y voltaje.

En el trabajo de investigación [22], realiza el procesamiento de las señales obtenidas de registradores de fallas, y analiza, las ventajas de la utilización de filtros para el tratamiento digital de la señal.

Finalmente [23] presenta el modelamiento y validación de un sistema de inferencia difuso (FIS) para identificar eventos por falla eléctrica, en tiempo real, del STE (Sistema de Transporte de Energía) con registros SOE. Detecta el inicio del evento y selecciona la información útil del mismo. El modelo FIS



es del tipo Mamdani en el que el conjunto de reglas se construye a partir del conocimiento del experto quien define la relación que se esperaría de la combinación de los posibles estados de las variables lingüísticas de entrada, tales como: Cantidad de señales SOE, tiempo promedio entre señales, tipo de señal SOE, etc.



CAPITULO 3. METODOLOGÍA DE INVESTIGACIÓN

3.1 INTRODUCCIÓN

Se propone la metodología para establecer el modelo para detectar y clasificar fallas en líneas de transmisión eléctricas empleando un sistema adaptivo de inferencia neuro-difusa, ANFIS en combinación con el algoritmo de agrupamiento substractivo y la técnica de partición en grilla.

Cualquier técnica de inteligencia artificial, tal como la herramienta ANFIS que se emplea en este trabajo y que involucra técnicas de aprendizaje para la creación del modelo matemático, exige que se disponga de una base de datos. Esta base de datos, conformada por datos de entrada (el conjunto de datos de las variables de entradas) y datos de salida (la variable calculada, que en este trabajo es un valor que representa la detección y clasificación de la falla), se divide usualmente en tres conjuntos [24]:

- i) Base de datos de entrenamiento;
- ii) Base de datos de verificación;
- iii) Base de datos de validación.

Si bien cada conjunto de datos tiene el mismo formato (esto es, cada conjunto contiene información sobre las mismas variables del problema), cada uno posee un uso diferente.

Los datos de entrenamiento sirven justamente para todas las tareas de entrenamiento que permiten que el modelo adquiera conocimientos (aprendizaje del modelo).

Los datos de verificación se utilizan para verificar en cada paso de entrenamiento la capacidad de generalización o aprendizaje que va adquiriendo el modelo.

Los datos de validación se utilizan para evaluar la capacidad del modelo en la estimación de la salida deseada y establecer qué se puede esperar en la práctica.

En la metodología propuesta, la base de datos está formada por información sobre variables de operación del sistema (en este caso corrientes de fase y neutro) que se genera en base a simulaciones para diferentes estados de falla y diferentes topologías del sistema y datos de fallas reales del SNT ecuatoriano.

Este conjunto de entradas, son aplicados a los modelos neuro-difusos, para dar como respuesta un valor que interpreta una estimación para la detección y clasificación de fallas, con un margen de error mínimo con respecto al valor verdadero existente. El modelo inicial FIS, para la agrupación de datos, son obtenidos por medio del algoritmo de agrupamiento substractivo de datos (*Sustractive Clustering-SC*) o la partición de datos en grilla (*Grid Partition-GP*).



El modelo finalmente entrega salidas identificadas como falla o no falla y clasificadas por el tipo de falla, según las fases involucradas.

La metodología propuesta requiere para su implementación de varias tareas y simulaciones en modo de estudio para obtener los modelos difusos adecuados. Luego con estos modelos difusos ya validados se podrá implementar en tiempo real el análisis de fallas en el SNT Ecuatoriano.

De las consideraciones anteriores el trabajo de investigación se desarrolló en cuatro fases:

- 1) Preparación de datos obtenidos desde los registradores de fallas
- 2) Modelación del SEP para la simulación y generación de patrones de entrenamiento y verificación
- 3) Construcción del modelo de inteligencia artificial (ANFIS)
- 4) Entrenamiento, verificación y validación del modelo

3.2 PREPARACIÓN DE DATOS

El modelo identifica y clasifica la falla de datos reales del sistema eléctrico ecuatoriano, obtenidos desde los registradores de falla instalados en diferentes subestaciones del SNT. Los registros en formato COMTRADE (*IEEE standard common format for transient data exchange for power systems*) provenientes de los registradores, se procesan de una manera adecuada para su utilización en el modelo propuesto.

3.2.1 Características Eléctricas

El procesamiento de señales de un registro COMTRADE y la extracción de sus características eléctricas en un rango de falla establecido constituye probablemente el paso más importante con miras al desarrollo final del proyecto. Los archivos de COMTRADE fueron exportados a MATLAB con el objeto de manejar la información en ese ambiente de manera más sencilla.

Una vez que los datos se encuentran en MATLAB, es necesario extraer la información necesaria que contiene características eléctricas de la/s falla/s analizadas, tales como:

- I = Valores instantáneos de corrientes por fase y neutro
- N = Numero de muestras
- f = Frecuencia del sistema
- F_s = Frecuencia de muestreo

Toda esta información está contenida en los archivos con extensiones *.CFG* y *.DAT* que contiene un COMTRADE, visto en el ANEXO A.

La obtención de datos y el procesamiento señales obtenidos de los registros de fallas para la extracción de las características eléctricas del registro se realiza mediante la siguiente metodología:



- 1) Inicialmente se dispone del archivo COMTRADE, y sus respectivas extensiones, de donde se obtiene la información del registro de falla y las señales de corrientes análogas en el tiempo, mediante la herramienta de programación MATLAB.
- 2) Posteriormente se realiza el procesamiento digital de la señal. Esto es el filtrado analógico y digital de la señal, que consiste en pasar estas señales de corrientes, a través de filtros analógicos y digitales, con el objeto de eliminar el efecto "ALIASING" y adecuarlas para el modelo ANFIS. Como salida se obtienen las señales RMS de las corrientes que son los datos de entrada para el modelo propuesto.
- 3) Finalmente, se normaliza la señal de entrada entre intervalos [0,1] que son los intervalos que maneja el modelo ANFIS propuesto. La figura 3.1, muestra el diagrama de flujo para la obtención de señales del COMTRADE.

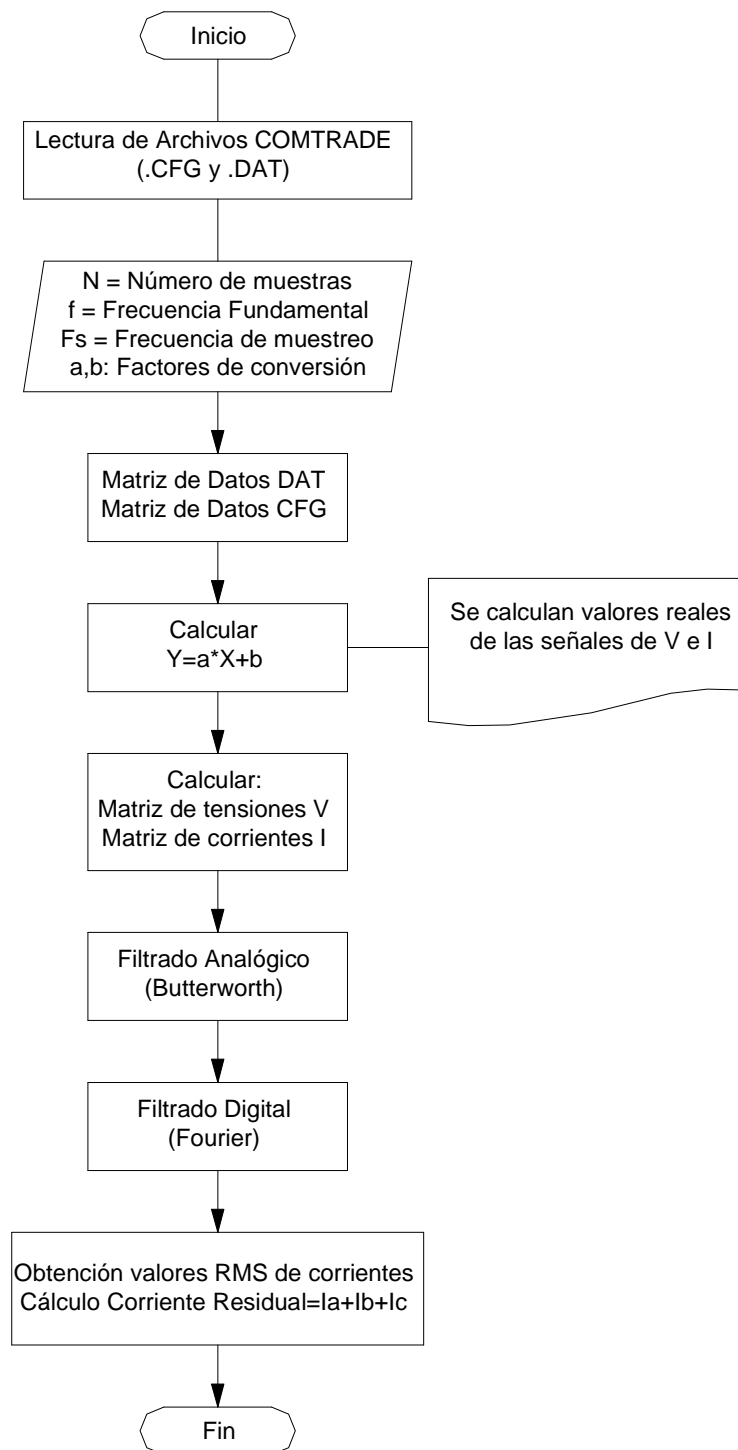


Figura 3.1 Diagrama de Flujo para la obtención de señales características de los COMTRADE



3.2.2 Filtrado Analógico y Digital

El procesamiento de señales digitales, requiere de un filtrado analógico *anti-aliasing*, que limita el contenido de frecuencias de la señal de entrada a un intervalo que pueda manejar el filtro digital.

Aliasing, es el efecto que causa que señales continuas distintas se tornen indistinguibles cuando se les muestrea digitalmente. Cuando esto sucede, la señal original no puede ser reconstruida de forma unívoca a partir de la señal digital. El teorema de muestreo o Nyquist, establece que la frecuencia de muestreo de una señal analógica, debe ser al menos el doble de la frecuencia fundamental de la señal, para que las réplicas del espectro original que aparecen en el muestreo no se traslapen y puedan ser reconstruidas a partir de su espectro de frecuencia.

Las réplicas se eliminan mediante un filtro pasabajos. Para este requerimiento existe varios métodos entre ellos: Filtro Butterworth, Chebyshev I, Chebyshev II y Elíptico. Mediante comparaciones y análisis realizados en varios trabajos, se concluyó que el mejor filtro análogo para nuestro caso de estudio, corresponde a un tipo Butterworth pasabajos de orden 2 con frecuencia de corte de 360 Hz, ya que presenta las menores oscilaciones y sobreimpulsos, lo que implica un menor tiempo de retardo en la respuesta final del filtro.

Las señales resultantes deben ser pasadas a través de un filtro digital y los métodos más utilizados en relés digitales de protección son: Algoritmo de Fourier, Algoritmo Coseno y Algoritmo Seno. En base a investigaciones sobre el tema [1], el filtro de Fourier es el más apropiado para determinar las componentes de 60 Hz debido a que utiliza un ciclo completo para muestreo y por lo tanto es más preciso. En aplicaciones de tiempo real los algoritmos de seno y coseno sacan provecho del muestreo de medio ciclo para propósitos de aumentar velocidad de respuesta. Sin embargo en aplicaciones Off-line, como las utilizadas en análisis post-operativos, la velocidad no es el factor preponderante y en cambio sí resulta más importante la precisión en el cálculo.

Consideraciones para el Filtrado

Los filtros analógicos y digitales son de importancia para el procesamiento de señales, sin embargo en este trabajo, el filtro analógico, no se realiza, ya que las señales obtenidas de los COMTRADE son con frecuencias de muestreo de 3840 Hz superiores a la fundamental (60 HZ), los cuales satisfacen el Teorema del Muestreo.

El filtro Fourier, como se menciona, utiliza un ciclo completo para efectuar el muestreo, por lo tanto para lograr aplicarlo con éxito en los módulos computacionales que se van a trabajar, es necesario dejar transcurrir un ciclo de la señal registrada que se quiere filtrar y a partir de este instante de tiempo, implementar el algoritmo del filtro de Fourier. La ventana de desplazamiento de este filtro siempre va a comprender un número de muestras igual a un ciclo, y el desplazamiento entre ventanas corresponde a una muestra. Esto quiere decir que una vez calculado el fasor y la magnitud correspondiente para un ciclo se desecha la primera muestra y se toma la



inmediatamente posterior para calcular un nuevo fasor. Este proceso se repite hasta que se recorren todas las muestras del registro.

Como resultado de este filtrado se obtienen las magnitudes RMS y ángulos de las señales punto a punto, es decir muestra a muestra. En el ANEXO B, se describe en detalle los filtros anteriores.

3.2.3 Normalización

La normalización consiste en procesar los valores de los patrones de entrada de tal manera que sean comparativamente similares. Esto implica que se deben tomar en cuenta las unidades de las corrientes (Amperios). Para que no existan errores de normalización, es necesario determinar las unidades en las que vienen las señales desde los registros de falla para que en caso de que se encontraran en factores de kiloamperios (kA), se hagan los ajustes del caso.

Para la utilización y correcta aplicación del algoritmo, tanto los datos de entrenamiento y verificación como los de validación fueron normalizados de acuerdo al siguiente procedimiento:

Sea $X = [x_1, x_2, \dots, x_i, \dots, x_n]^T$ un vector de datos con n elementos, en donde su valor máximo y mínimo es

$$x_{max} = \max\{x_1, x_2, \dots, x_i, \dots, x_n\} \quad ; \quad x_{min} = \min\{x_1, x_2, \dots, x_i, \dots, x_n\}$$

Entonces las componentes del vector normalizado $x^{nor} = [x_1^{nor}, x_2^{nor}, \dots, x_i^{nor}, \dots, x_n^{nor}]^T$ en el intervalo $[0, 1]$, se calculan con la siguiente expresión:

$$x_i^{nor} = \left[\frac{x_i - x_{min}}{x_{max} - x_{min}} \right] \tag{3.1}$$

Donde: x_i corresponde al valor de la muestra i

3.2.4 Condiciones para el procesamiento de datos

Se exponen algunas condiciones y restricciones que deben tenerse en cuenta para obtener resultados verdaderamente significativos y válidos para los métodos de detección y clasificación de falla.

Las siguientes condiciones tomadas de la referencia [22] son suficientes, para definir los datos de entrada.

1) Tiempo de duración de la falla detectada

Entre las restricciones a tener en cuenta se establece que para validar la existencia de una perturbación en un registro de falla analizado, una vez que el algoritmo detecte alguna de las condiciones de falla establecidas, esta condición debe permanecer al menos por un ciclo completo de muestras sucesivas a partir del instante en que se ha detectado la falla. Es decir, si en



la muestra N se encuentra una falla monofásica a tierra, las siguientes N_c muestras deben corresponder también con este estado de falla, siendo N_c el número de muestras en un ciclo completo. Si la condición anterior se cumple, entonces se establece que en el instante N se inicia una falla.

Para determinar el instante de finalización de la falla se procede de manera igual, es decir cuando se presenta el cambio de falla a estado normal del sistema, este nuevo estado de condición estable debe poseer al menos un ciclo completo de muestras en dicha condición para que sea válido y se pueda reconocer como el instante de finalización del rango de falla.

Es necesario tener en cuenta que si en la muestra N se detecta una falla monofásica a tierra de la fase A y en la muestra $N+1$, cambia a cualquier otro tipo de falla, esta muestra no contaría como la muestra siguiente sucesiva para establecer un inicio de falla, sino que por el contrario, esta muestra $N+1$, pasaría a ser la primera muestra N para validar la falla encontrada en este instante. Es decir que para que un inicio de falla detectado sea validado como tal, todas las muestras del primer ciclo completo deben pertenecer al mismo tipo de falla.

2) Condición de falla inicial

Cuando el evento analizado contiene fallas evolutivas o algún otro tipo de fallas posteriores a la falla inicial, el algoritmo no podrá detectarlas adecuadamente, razón por la cual es necesario encontrar la forma de procesar únicamente el primer rango de falla encontrado, pues para fallas posteriores, los resultados son poco satisfactorios y alejados de la realidad, es decir detecta fallas cuando no las hay o viceversa.

Por lo mencionado anteriormente, una de las principales restricciones a tener en cuenta es considerar solo fallas iniciales del registro y no una vez que las protecciones han actuado. Lo anterior se refleja en el hecho de que una vez que el registro evidencia la apertura de un polo o fase, las fallas posteriores a esa apertura no pueden ser detectadas por medio del módulo de detección de falla, ni por ningún otro método al que se tuviera acceso.

3) Condición de polo abierto

Por las razones explicadas anteriormente, la información del registro que resulta útil para el análisis es la relacionada con la primera falla antes del disparo o acción de los equipos de interrupción. Debido a esto es necesario establecer para los registros, el momento en que se presenta una apertura del interruptor y establecer bajo qué circunstancias se puede considerar condición real de polo abierto en el registro de oscilografía analizado, para procesar únicamente la información existente hasta este instante de tiempo.

En los casos reales de análisis de fallas se establece que el umbral para determinar si existe realmente una condición de polo abierto se debe fijar en 5 Amperios, es decir que cualquier corriente debajo de este umbral permite considerar condición de polo abierto en el evento.



Para evitar la generación de un error al momento de determinar la condición de polo abierto, se opta por acoger la misma condición utilizada para validar la detección del inicio o final de una falla: por lo menos un ciclo completo de muestras consecutivas debe permanecer bajo la misma condición establecida.

4) Restricción de la información procesada

Hace referencia al análisis que se lleva a cabo para determinar cuáles de los registros de falla a procesar poseen datos realmente válidos que aporten a la finalidad del trabajo.

La primera característica que deben poseer los registros para ser válidos para el posterior procesamiento, es que deben poseer canales análogos para ser analizados.

Teniendo presente las observaciones realizadas referentes a la condición de polo abierto, es necesario mencionar que algunos registros de perturbaciones son continuación de uno anterior en el cual se presenta la condición de polo abierto, es decir son registros donde desde las primeras muestras se presentan magnitudes de corrientes por debajo del umbral establecido. En otras palabras, todos los registros que posean de entrada un polo abierto en alguna de sus líneas son descartados.

Existen casos donde no se presenta falla antes del disparo, por lo cual no existe un rango de falla que pueda ser procesado. Esta condición particular se puede presentar entre otras razones, porque no alcanza a existir un ciclo completo en la condición de falla antes de que el polo abra, impidiendo así que se pueda determinar un instante de inicio de la falla a la vez que hace imposible el procesamiento de la información. Todos los registros que presenten esta característica son descartados.

5) Direccionalidad de la falla

El registro debe poseer información sólo de las subestaciones y bahías de línea en las que realmente ocurra una falla. Para esto es necesario determinar mediante la información del registro que la anomalía detectada en una de las líneas de éste corresponda justamente a una falla en la bahía asociada y no a un efecto causado por una perturbación externa que alcanza a tener impacto sobre la línea analizada.

Para validar entonces la detección de una falla correspondiente a una bahía en un registro de perturbaciones, dos condiciones deben satisfacerse:

1. Debe existir condición de polo abierto en el registro asociado a la bahía que presenta la supuesta falla. La condición de polo abierto implica el disparo de un equipo de interrupción asociado a la bahía, si no se presenta esta condición, implica que la falla ocurrió sobre otra línea o bahía.
2. La direccionalidad de la falla detectada debe ser "hacia adelante". Para esto es necesario utilizar el concepto que rige a muchos tipos de relés para determinar si una falla es para adelante o para atrás. Esto se hace de



acuerdo al ángulo de la impedancia que para estos casos en específico corresponde a la diferencia entre los ángulos de la tensión promedio RMS y la corriente promedio RMS.

6) Campo de bahía de línea en el archivo de configuración

Otra forma en la que se acotó la información a utilizar, tiene que ver con las etiquetas de las bahías presentes en los registros COMTRADE específicamente en los archivos CFG. Debido a que en este proyecto se utiliza únicamente información correspondiente a las bahías de línea, toda etiqueta que no cumpla con esta característica, no es tomada en cuenta.

En los archivos CFG procesados existen muchos registros cuyas etiquetas de bahías no poseen ni una sola que corresponda a líneas de transmisión sino que el archivo hace referencia a otros campos (transformadores, bancos de compensación, entre otros). Este tipo de información no resulta útil y por lo tanto estos registros no son analizados o procesados en los análisis de fallas de líneas.

7) Campos faltantes del archivo de configuración

Los registros utilizados en los análisis de fallas de líneas de transmisión deben poseer información validada completamente útil para el objetivo del trabajo, es decir que aquellos registros de los cuales se van a extraer las características eléctricas establecidas previamente, deben cumplir con las siguientes condiciones:

- Presentar condición de polo abierto en alguna de sus bahías.
- La falla o fallas analizadas deben corresponder a la primera contenida en el registro oscilográfico, es decir antes de que operen los equipos de interrupción asociados.
- El módulo de detección de falla debe encontrar al menos un rango de análisis antes de la apertura del polo.
- Se determina que la direccionalidad de la falla detectada es “hacia delante” de acuerdo a los criterios mencionados.
- Deben tener al menos una bahía de línea para analizar.
- No deben presentar condición de polo abierto en el inicio del registro (disparos de equipos de interrupción en las primeras muestras).

Cualquier registro que no cumpla con alguna de las condiciones mencionadas debe ser inmediatamente descartado.

3.3 MODELACIÓN Y CONSTRUCCIÓN DEL SEP PARA GENERACIÓN DE PATRONES DE ENTRENAMIENTO Y VERIFICACIÓN.

El modelo requiere del entrenamiento y verificación del sistema, antes de su validación con datos reales, por lo que en la metodología propuesta, la base de datos de entrada para su entrenamiento y verificación, está formada por información sobre corrientes de falla de una línea de transmisión que se genera en base a simulaciones para diferentes tipos de falla y diferentes condiciones eléctricas. Se realiza el modelo que represente la variabilidad asociada con las condiciones eléctricas de un sistema de potencia durante



eventos, la construcción del modelo y el análisis de sensibilidad de los diferentes casos.

3.3.1 Modelación del Sistema

Se lleva a cabo la modelación de un sistema para la generación de muestras de entrenamiento y verificación. El sistema debe cumplir con los siguientes requerimientos:

- Reproducir las formas de ondas de tensiones y corrientes resultantes en los dos extremos de una línea de transmisión, para un número exhaustivo de condiciones eléctricas esperadas en cualquier SEP.
- Establecer un conjunto representativo de muestras del universo de fallas que se pueden producir en cualquier SEP.
- Delimitar el dominio de entrada del problema de diagnóstico de fallas a partir de registros de oscilografía.

El diagrama siguiente, muestra el proceso para la obtención de dichos patrones.

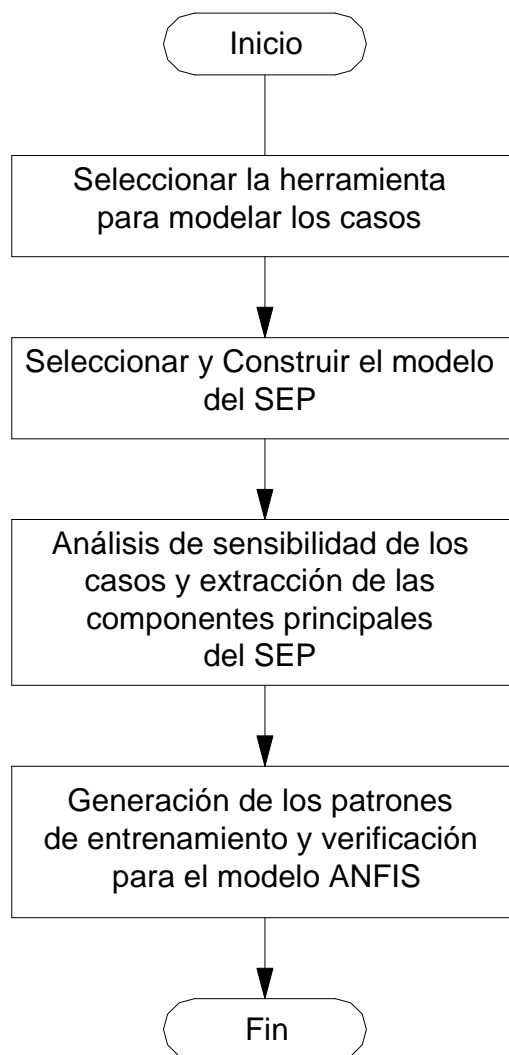


Figura 3.2 Diagrama de Flujo para la obtención de patrones de entrenamiento y verificación del ANFIS

3.3.2 Software de simulación para modelar los casos

Existen numerosas herramientas informáticas, para realizar diversos tipos de estudios de los sistemas eléctricos, entre los más destacados están: *SimPowerSystem* (Simulink), *PowerWorld*, PSS/E, ATP-EMTP, PSCAD/EMTDC, POWER FACTORY DIGSILENT. Además también existen herramientas de análisis matemático, que permiten, mediante la programación por el usuario, simular los sistemas de energía eléctrica como Mathcad y el MATLAB.

Para realizar la exploración de la variabilidad de las condiciones eléctricas de un SEP, se seleccionó como herramienta de simulación el programa ATP (*Alternative Transient Program*) catalogado como una de las herramientas más versátiles para el análisis de transitorios electromagnéticos.

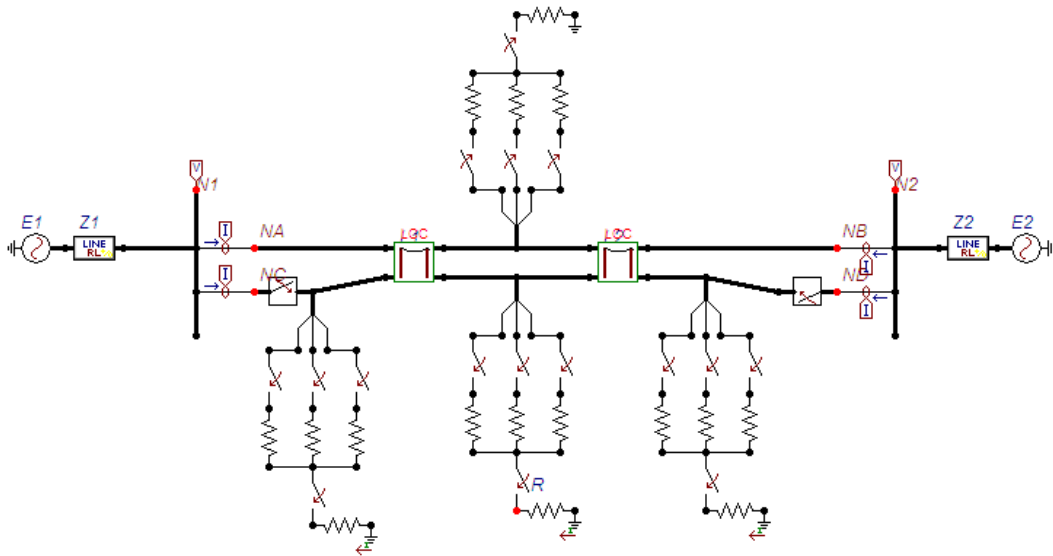


Figura 3.4 Modelo básico en ATPDraw

La obtención de los parámetros eléctricos del caso de estudio se expone en el ANEXO C.

3.3.4 Simulaciones

Se aplica el paquete software ATP-EMTP en la simulación del sistema eléctrico cuyo esquema unifilar se presenta en la figura 3.5 cuando se presenta una falla en la línea de interconexión entre los nodos N1 y N2, a diferentes tramos de la longitud de la línea (25%, 50% y 75%). En cada tramo se ha colocado resistencias e interruptores conectados entre ellos y hacia tierra, de manera de simular distintos tipos de fallas (AT, BT, CT, AB, CB, CA, etc), con distintos valores de impedancia.

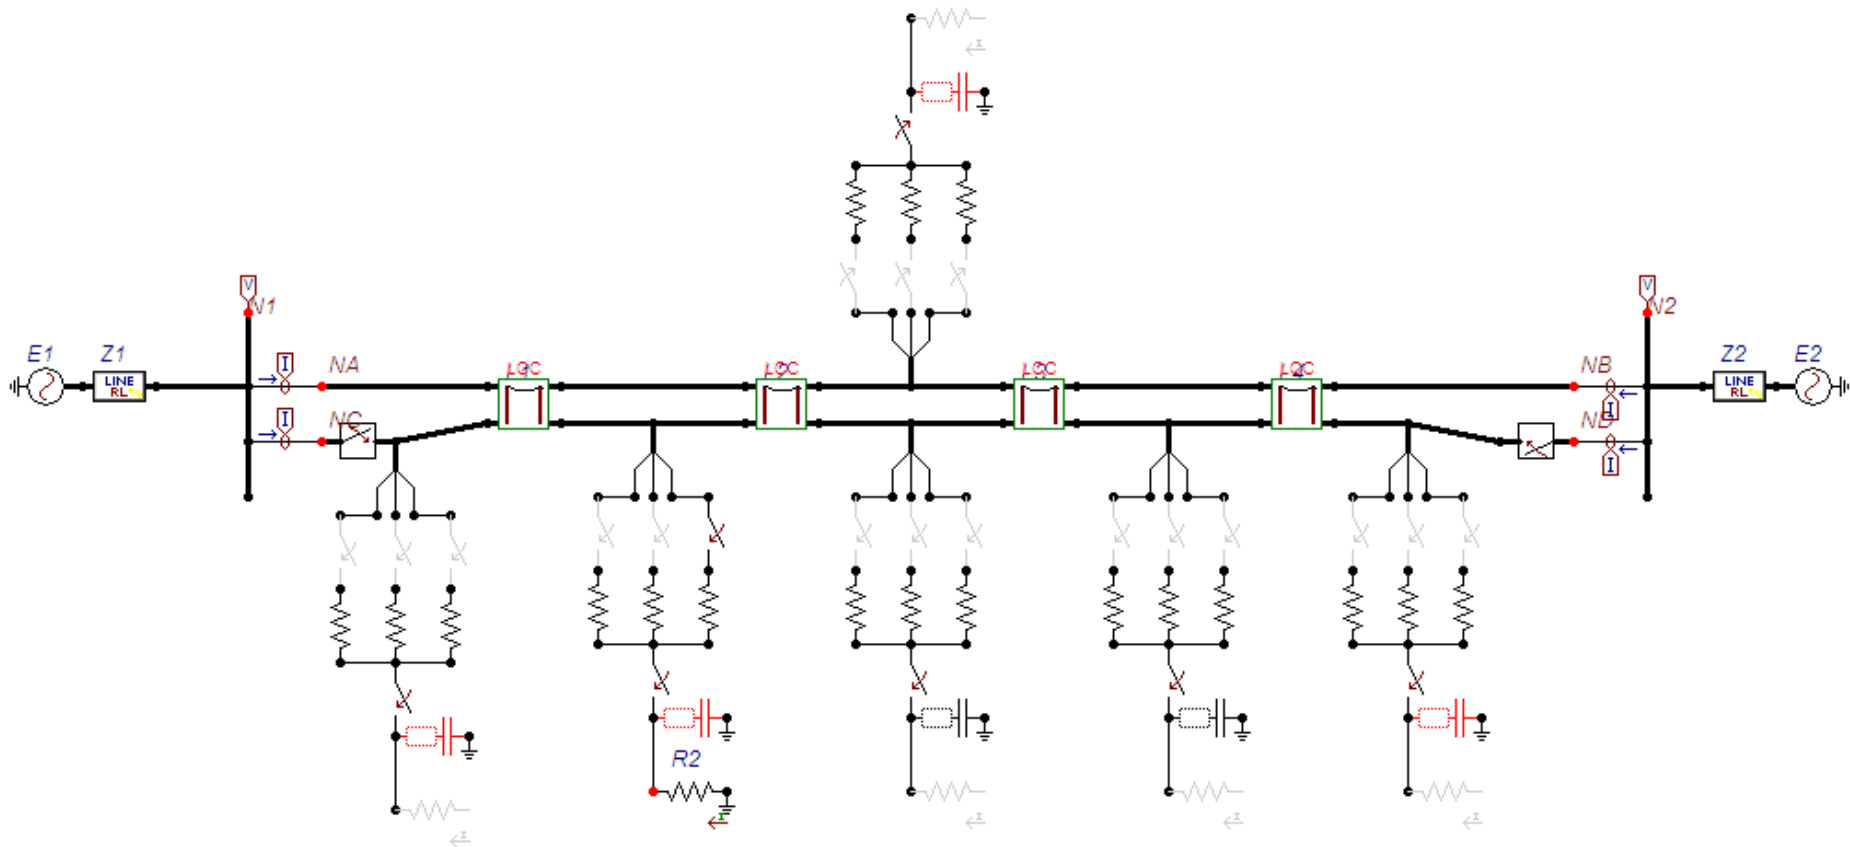


Figura 3.5 Modelo para simulación de casos.

Ejemplo: Falla Fase A-Tierra al 25% de la línea, con una resistencia de falla R2



Variabilidad de parámetros de estudio

Con el fin de generar las muestras de entrenamiento y verificación para ser usados en el algoritmo propuesto, acorde con la variabilidad esperada de condiciones eléctricas de cualquier SEP real, se realiza una exploración exhaustiva de una diversidad de fallas simuladas en ATP. Para ello, se llevó a cabo la siguiente exploración sistemática de posibilidades, variando los siguientes parámetros, según la referencia [1]:

A) Impedancia fuente tanto del extremo emisor como del extremo receptor.

En este punto, se consideraron condiciones de impedancia fuente con diferentes grados de fortaleza y aterrizamiento cubriendo condiciones extremas entre un nivel de corto cercano los 20 kA y un nivel de cortocircuito inferior a 1 kA. Para ello se varía el tipo de generador equivalente en los extremos de la línea. Se obtienen los siguientes casos:

Tabla 3.1 Fallas según el tipo de generador en los extremos de la línea

SIMULACIONES	GENERADORES
CASO 1	$G1=G2$
CASO 2	$G2=G1/2$
CASO 3	$G2=0$
CASO 4	$G1=G2/2$
G1, G2: Generadores equivalentes en los nodos N1 y N2	

B) Condiciones de carga de una línea de transmisión en estado estacionario.

La variabilidad de las condiciones de carga de una línea de transmisión se encuentra relacionada con la diferencia angular entre el ángulo de carga del extremo emisor y el ángulo de carga del extremo receptor.

Para variaciones angulares positivas el flujo de potencia resultante va desde el extremo emisor hacia el extremo receptor (exportación) y para las variaciones angulares negativas desde el extremo receptor al extremo emisor (importación).

Para este caso se consideró una condición de carga promedio de las líneas de transmisión de TRANSELECTRIC correspondiente con un ángulo de 6, 10 y 15 grados entre fuentes, considerando siempre que la barra de la S/E Zhoray es fuente y la barra de la S/E Milagro es carga, como caso real del SNT Ecuatoriano, ya que desde la C. Paute se evacua la mayor potencia generada del país, y fluye a través de la S/E Zhoray hacia Milagro y resto de subestaciones costeras.

C) Longitud de las líneas de transmisión.



Para este trabajo se consideró una longitud de línea típica de 100 km que representa un valor medio para diferentes longitudes a considerarse en el SNT Ecuatoriano. La longitud real de la L/T Zhoray-Milagro es de 121.07 Km.

D) Localización de la falla.

Se considera la ubicación de la falla al 25%, 50% y 75% de la longitud de la línea, con la finalidad de interpretar fallas de ubicaciones cercanas, medianamente cercanas y lejanas del extremo emisor.

E) Impedancia de la falla.

Las fallas en una L/T pueden ser francas o a través de una impedancia de falla; mientras más alto es este valor, la corriente de falla se acercara más a la corriente de carga, llegándose a confundir con ésta y por tanto causando falsas interpretaciones.

Se consideraron valores típicos del SNT Ecuatoriano, para representar la impedancia de falla: muy baja impedancia (inferior a 1 ohm), baja impedancia (entre 5 y 10 ohm), impedancia medio-baja (entre 10 y 20 ohm), impedancia medio-alta (entre 20 y 30 ohmios).

F) Tipo de falla.

Se consideraron los siguientes tipos de falla en los sistemas de transmisión: Falla monofásica (A,B,C), Falla bifásica aislada (AB, BC y CA), Falla bifásica a tierra (AB-g, BC-g, CA-g) y Falla trifásica (ABC).

La siguiente tabla muestra en resumen las condiciones de operación mencionadas anteriormente

Tabla 3.2 Condiciones de operación para la obtención de datos

ITEM	VARIABILIDAD DE PARAMETROS					
	ANG	LONG	GEN	LOCL. FALLA	Zfalla	TIPO F.
A	6	100	G1=G2	25%,50%, 75%	1, 5, 10, 30	A, B, C, T
B	6	100	G2=G1/2	25%,50%, 75%	1, 5, 10, 30	A, B, C, T
C	6	100	G2=0	25%,50%, 75%	1, 5, 10, 30	A, B, C, T
D	6	100	G1=G2/2	25%,50%, 75%	1, 5, 10, 30	A, B, C, T
E	15	100	G1=G2	25%,50%, 75%	1, 5, 10, 30	A, B, C, T
F	15	100	G1=G2	25%,50%, 75%	20	A
			G2=G1/2			
			G2=0			
			G1=G2/2			

3.3.5 Generación de datos para entrenamiento y verificación

Las diferentes condiciones de operación son generadas y simuladas en ATP, los resultados obtenidos son procesados y manipulados por medio de un software para análisis de perturbaciones SIGRA de manera de adecuar las señales obtenidas, en un formato estandarizado (COMTRADE).



Mediante el SIGRA, se establece la frecuencia de muestreo, la frecuencia del sistema, el formato del archivo DAT, la versión del archivo CFG y los canales analógicos y digitales contenidos en el COMTRADE. Así mismo SIGRA genera los archivos DAT y CFG del COMTRADE.

A los datos obtenidos se les realiza el procesamiento digital en MATLAB para la obtención de los datos para entrenamiento y verificación del sistema, siguiendo el mismo proceso visto en el numeral 3.2.

3.4 DISEÑO Y CONSTRUCCIÓN DEL MODELO ANFIS

En todo tipo de falla o perturbación, presentado en un SEP, la información proveniente de las corrientes y voltajes, dan las características del comportamiento del sistema, ya que la variación en una de ellas, denota una situación particular de la falla.

De este modo, partiendo de las corrientes de fase como entradas al algoritmo, se calculan las corrientes de secuencia cero, para la deducción del tipo de falla mediante ANFIS. El número total de modelos ANFIS dependerá de las entradas y salidas, establecidas como diseño para la detección y clasificación de la falla

Luego, a los modelos neuro-difusos creados se los entrena y se evalúa el denominado error de entrenamiento. Este error es la diferencia entre la salida de cada modelo difuso (esto es, la estimación para la detección y clasificación) y el margen de falla verdadero conocido de los datos de simulaciones.

El ANEXO D presenta información más detallada del algoritmo neuro-difuso, estudiado en este apartado.

3.4.1 Formulación del problema

A continuación se plantea el análisis para la determinación del modelo para la detección y clasificación de fallas en líneas de transmisión del sistema eléctrico ecuatoriano mediante ANFIS.

Los sistemas neuro-difusos ANFIS (también llamados sistemas de inferencia difusa basados en redes adaptivas) son una herramienta matemática relativamente nueva que sirve como una base para construir un conjunto de reglas Si-Entonces (*If-Then*), con funciones de pertenencia adecuadas para generar una salida determinada. En estos sistemas el aprendizaje se basa en el principio de aprendizaje de las redes neuronales. A menudo los sistemas ANFIS trabajan con un sistema FIS inicial el cual puede ser creado en base a conocimientos del experto o en base a información de operación del sistema clasificada como datos de entrada y salida. El escoger una u otra opción depende de la complejidad del problema.

Los algoritmos de agrupamiento de datos son capaces de construir modelos FIS a partir de datos y se usan principalmente para los casos en los que se hace difícil establecer funciones de pertenencia y reglas adecuadas al problema en cuestión. Con estas herramientas se pueden crear sistemas difusos mediante datos de entrada y salida. Estos algoritmos, en base a la



similitud que existe entre los datos, dividen una colección de datos en subconjuntos o grupos de datos. El algoritmo de agrupamiento substractivo de datos (*Subtractive Clustering-SC*) pertenece a esta clase de herramientas.

Los métodos de partición difusa sobre las variables de entrada para formar el antecedente de un sistema difuso dividen el espacio de entrada en cuadrículas. En el método de partición en grilla (*Grid Partition-GP*) cada conjunto es un hipercubo, donde algunas aristas se vuelven los prototipos iniciales. Si hay muchas dimensiones es difícil e ineficiente aplicar este método, ya que si se tiene K entradas y m funciones de pertenencia, se tendrán m^K reglas, sin embargo para un número pequeño de funciones de pertenencia y entradas, el método es bastante eficiente.

La combinación ANFIS-SC, o ANFIS-GP se usa de modo tal que el algoritmo SC o GP establece el sistema de inferencia difuso inicial, y luego el sistema neuro-difuso optimiza y adecua ese sistema al problema que se quiere resolver. Las reglas y funciones de pertenencia se crean de manera automática en base a datos de entrada y salida que representan los estados de funcionamiento del sistema, los cuales se obtienen mediante simulaciones.

A continuación se definen los siguientes parámetros para la modelación usando ANFIS:

1) Variables de Entrada:

El sistema ANFIS crea el sistema difuso en base a una cantidad de variables que recibe como entradas y que surgen de un evento de falla de una línea del sistema eléctrico que se analiza. Estas entradas están constituidas por las corrientes de las fases a, b, c y corriente de secuencia cero que son elegidas para crear el sistema difuso inicial, mediante los métodos SC o GP, para establecer el mejor modelo.

2) Base de Datos:

Se emplea aquí el término datos para referirse a los datos que surgen del proceso de un evento del sistema, esto es, a los valores obtenidos de los diferentes componentes del sistema eléctrico, en condiciones de falla, caracterizada por la topología de la red, la demanda del sistema y la generación en línea.

Estas variables de operación son obtenidas mediante medición por equipos registradores de fallas ubicadas en los diferentes subestaciones del SNT ecuatoriano en unos casos y en otros por cálculos mediante herramientas software existentes (simulaciones).

La base de datos está formada por los datos de entrada constituidos por los valores de corrientes y por los datos de salida que en este trabajo es la condición falla, no falla y tipo de falla.

Clasificación de datos



Conjunto de datos para entrenamiento y verificación, son los datos obtenidos desde las diferentes simulaciones echas a un SEP que define las condiciones de una línea típica del SNT Ecuatoriano, en este caso la L/T Zhoray-Milagro 230 kV.

Conjunto de datos para validación, corresponden a los datos obtenidos desde un registrador de fallas generados a partir de un evento real ocurrido en líneas de 230 kV del sistema eléctrico ecuatoriano.

Los datos de entrada son agrupados en una sola matriz, de los cuales el 100% de los datos simulados (600 registros aproximadamente) son para entrenamiento el 70% y para verificación el 30%, mientras que el 100% de los datos reales (aprox. 60 registros) son para validación

3) Herramientas de Software:

La modelación se realiza en MATLAB, utilizando la herramienta *Fuzzy Logic Tool* y su función *ANFIS Editor GUI*, que nos ayuda con el análisis, para la determinación del mejor modelo ANFIS a obtener.

Se puede crear, entrenar y probar el sistema Difuso de tipo Sugeno usando el *ANFIS Editor GUI*, que en el MATLAB es posible accederlo, mediante el comando ***anfisedit***. Esta función, permite realizar las siguientes tareas:

- Cargar, graficar y borrar los datos de entrada
- Generar o cargar (desde un archivo externo) la estructura FIS inicial, utilizando *Sustractive Clustering* o *Grid Partition* de los datos.
- Entrenar el FIS
- Validar el FIS entrenado

3.4.2 Desarrollo del Algoritmo

En la Figura 3.6 se ilustra el algoritmo de clasificación de fallas estudiado en la presente investigación. Como se observa, se desarrolló utilizando ANFIS y las características de la falla (corrientes de fase RMS y corriente de secuencia cero). Se utilizó un modelo del tipo Sugeno y hasta cuatro ANFIS para la detección y clasificación de la falla.

El algoritmo se compone de tres pasos básicos:

- Adquisición de las corrientes de fase.
- Cálculo de la corriente de secuencia cero.
- Deducción del tipo de falla usando ANFIS.

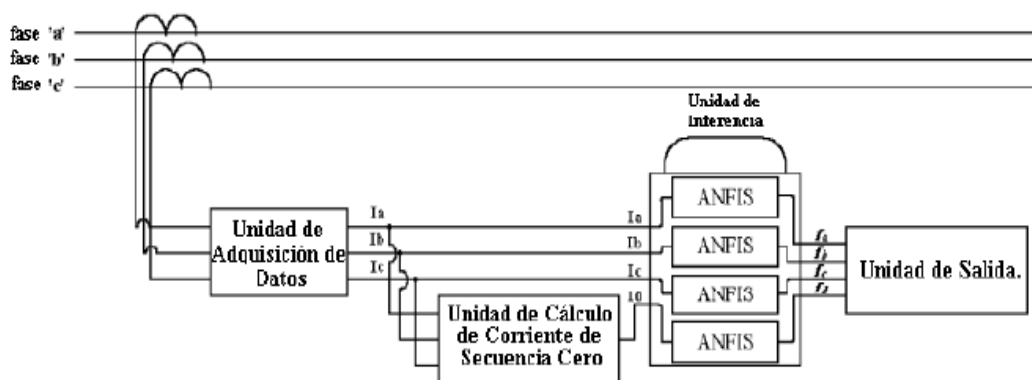


Figura 3.6 Diagrama para el Algoritmo de Detección y Clasificación de Fallas

Se obtienen las corrientes de secuencia I_a , I_b , I_c desde los registradores de falla, y una unidad de adquisición de datos, en MATLAB, obtiene los datos del COMTRADE generado.

Se calculan las corrientes de secuencia cero ($I_o = I_a + I_b + I_c$), de manera de conocer la existencia de fallas a tierra.

Finalmente la deducción para la detección y clasificación de la falla es mediante la unidad de inferencia que este caso es el ANFIS [1].

Descripción del modelo ANFIS:

Se crea un modelo FIS inicial generado por las técnicas SC o GP, el cual es usado por el ANFIS como sistema difuso inicial. El objetivo es optimizar las reglas y funciones de pertenencia al problema que se quiere estudiar.

A continuación se realiza la descripción de los modelos FIS inicial y optimizado para el desarrollo del algoritmo:

1) Modelo difuso inicial

El espíritu de los sistemas de inferencia difusos consiste en separar o dividir en grupos el conjunto de las variables de entrada. Para esto se utiliza el algoritmo de agrupamiento substractivo de datos y partición en grilla, para la obtención del FIS inicial.

Agrupamiento de Datos.

Este algoritmo entrega los parámetros de las funciones de pertenencia del antecedente de las reglas del sistema difuso inicial. Los parámetros de la parte del consecuente de cada regla se obtienen aplicando el algoritmo de los mínimos cuadrados a los datos de entrada y a los datos de salida.



En el algoritmo de agrupamiento substractivo de datos se puede manipular la variable r_a , con la cual se establece el grado de vecindad entre los elementos x_i del vector de datos que va a ser considerado a los efectos de generar diferentes centros de grupos de datos. En general un valor pequeño de r_a generará un mayor número de grupos de datos que un valor más grande.

El valor r_a se estableció en 0.5, que es el valor por defecto que utiliza el programa de cálculo del algoritmo de agrupamiento substractivo de datos implementado en MATLAB. Se recomienda que el valor r_a se encuentre entre 0.2 y 0.5.

Partición de datos en grilla.

Otro método para la generación de una estructura FIS inicial tipo Sugeno, es usando un conjunto de datos de entrenamiento y aplicando la técnica de partición de datos en grilla. En este método el antecedente está definido por el número de funciones de pertenencia y el tipo de dicha función (triangular, trapezoidal, gaussiana, campana generalizada, etc) que son especificados en el algoritmo.

2) Modelo de optimización ANFIS

ANFIS usa los modelos difusos iniciales, descritos en la sección anterior, para obtener mejores estimaciones de la detección y clasificación del tipo de falla. Esto lo hace optimizando las reglas y funciones de pertenencia obtenidas del FIS inicial, siguiendo la arquitectura que se detalla en el ANEXO D.

3.4.3 Metodología para Detección y Clasificación de la Falla:

Detección de la Falla

Para la detección de la falla, se emplea la siguiente deducción: Si los resultados de la inferencia son cero, entonces significa una situación de no falla. Sin embargo, si los resultados de la inferencia no son cero, entonces la técnica indica ambas la presencia de falla y el tipo de falla.

Clasificación de la Falla

Cuando los resultados de la inferencia no son cero, se indica que existe una falla y la clasificación de la misma, puede ser establecida así:

Método 1:

El modelo desarrollado consistió en cuatro ANFIS para las corrientes de fase 'a', 'b', 'c' y corriente de secuencia cero, respectivamente. Las entradas al ANFIS son los valores RMS de las tres corrientes de fase y corriente de secuencia cero.

Los valores de salida significan cuatro categorías asociadas con las corrientes de fase 'a', 'b', 'c' y la corriente de secuencia cero. Si cualquiera de las salidas desde las tres primeras ANFIS (por ejemplo. Ia, Ib, Ic) es '1' entonces esto



indica una falla de alta impedancia (*High Impedance Fault*-HIF), en el caso de '2', es una falla de baja impedancia (*Low Impedance Fault*-LIF), y en el caso de '0', no hay falla. Para las cuatro ANFIS (por ejemplo, lo) consideradas, '2', '1', '0' significa una falla a tierra para LIF, HIF o una falla sin tierra, respectivamente, este criterio es presentando en la Tabla siguiente:

Tabla 3.3 Salida ANFIS. Método 1

Tipo de Falla	Salida ANFIS			
	Ia	Ib	Ic	Io
SLG a	2	0	0	2
SLG b	0	2	0	2
SLG c	0	0	2	2
DLG ab	2	2	0	2
DLG bc	0	2	2	2
DLG ca	2	0	2	2
LL ab	2	2	0	0
LL bc	0	2	2	0
LL ca	2	0	2	0
3ØG abc	2	2	2	0
HIF a	1	0	0	1
HIF b	0	1	0	1
HIF c	0	0	1	1
Sin Falla	0	0	0	0



Método 2:

El modelo consiste de un solo ANFIS con una salida pero con 11 categorías diferentes, clasificadas de acuerdo al tipo de falla. Esta clasificación se realiza según el siguiente criterio:

Tabla 3.4 Salida ANFIS. Método 2

Tipo de Falla	Salida ANFIS
	Y
Sin Falla	0
SLG a	1
SLG b	2
SLG c	3
DLG ab	4
DLG bc	5
DLG ca	6
LL ab	7
LL bc	8
LL ca	9
3ØG abc	10

3.4.4 Construcción del Modelo

El algoritmo de detección de falla se implementa muestra a muestra desde el inicio hasta el final del registro, para determinar en qué instante acababa el estado estacionario y donde comienza la anomalía.

Para que el módulo de detección de falla funcione adecuadamente es necesario ingresarle los parámetros de entrada normalizados que corresponden en su orden respectivo a: las tres corrientes de fase en valores RMS y la corriente residual (3I₀) igualmente en valor RMS.

La siguiente figura, muestra los pasos a seguir para obtener el modelo analizado.

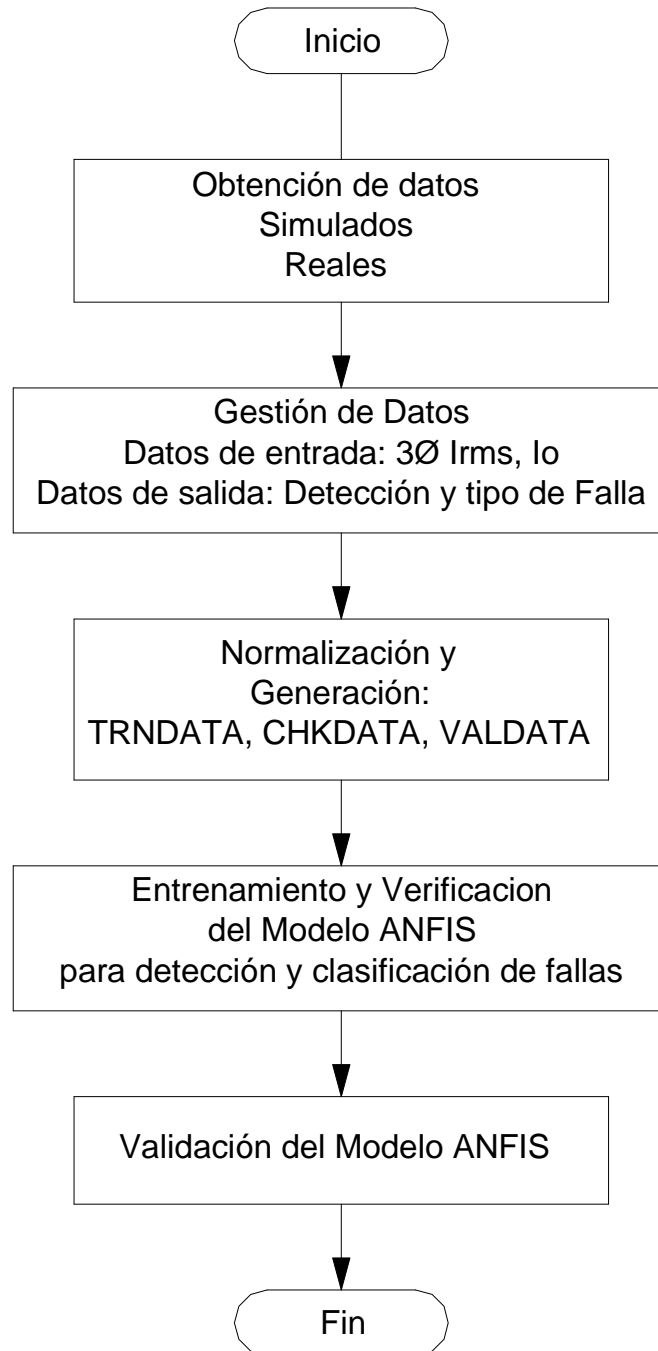


Figura 3.7 Diagrama de flujo para la construcción del Modelo ANFIS para detección y clasificación de fallas



El modelo se construye en MATLAB, de acuerdo al siguiente procedimiento:

1) Obtención de la matriz de datos de entrada

Esta matriz [X] se consigue a partir de los archivos COMTRADE unos obtenidos de un SEP simulado en ATP y otros obtenidos desde los registradores de fallas reales en líneas de transmisión de 230 kV del sistema eléctrico ecuatoriano y calcula valores RMS de las corrientes de fase por medio de FOURIER a cada ciclo.

2) Gestión de datos

Se generan los datos de entrada y salida para entrenamiento, verificación y validación normalizados y se clasifican los datos según las siguientes matrices:

[trndata]=Datos para entrenamiento
[chkdata]=Datos para verificación
[valdata]=Datos reales, para validación.

En este proceso es necesaria la depuración de los datos para eliminar aquellos que no dan valor al análisis y que puedan crear errores de interpretación.

Así mismo la generación de los datos de salida, matriz [Y], se obtienen según el siguiente detalle:

Para las corrientes de fase

[Y]=0 situación NO Falla; Valores menores a 800 A

[Y]=1 Falla Tipo HIF (Alta Impedancia); Valores entre 800-1200 A

[Y]=2 Falla Tipo LIF (Baja Impedancia); Valores mayores a 1200 A

Para las corrientes del neutro

[Y]=0 situación NO Falla; Valores menores a 200 A

[Y]=1 Falla Tipo HIF (Alta Impedancia); Valores entre 200-800 A

[Y]=2 Falla Tipo LIF (Baja Impedancia); Valores mayores a 800 A

Los valores umbrales determinados anteriormente, son referidos según datos obtenidos de CELEC EP – TRANSELECTRIC y la experiencia de expertos en este tema [25], tomando en consideración los siguientes características del SEP:

- Corriente de carga, o límite operativo de la línea en condiciones normales de operación: 860 A.
- Corriente nominal, o límite térmico del conductor según el fabricante: 1100 A, para cable 1113 MCM.
- Corriente de Sobrecarga: $I_{sc}=K \cdot I_n$ (K entre un 120% a 150%).
- Desbalance de corrientes por fallas a tierra (entre el 20 y 30% de la corriente nominal)



- Desbalance de corrientes por fallas entre fases (Desbalances del 120% de la lcc de la subestación próxima)
- Corrientes de cortocircuito

3) Utilización del ANFIS para Identificar y Clasificar la Falla

Se utiliza el MATLAB mediante la herramienta *Fuzzy Logic Toolbox* y su función *ANFIS Editor GUI*. Para mayor detalle referirse al ANEXO E.

Sea $[X_n]$ la matriz de valores de entrada normalizados que corresponden a las corrientes de fase y de secuencia cero, en una línea de transmisión a 230 kV con falla y sea $[Y]$ la matriz de los valores de salida que identifican y clasifican la falla. La utilización del ANFIS en MATLAB tiene los siguientes pasos:

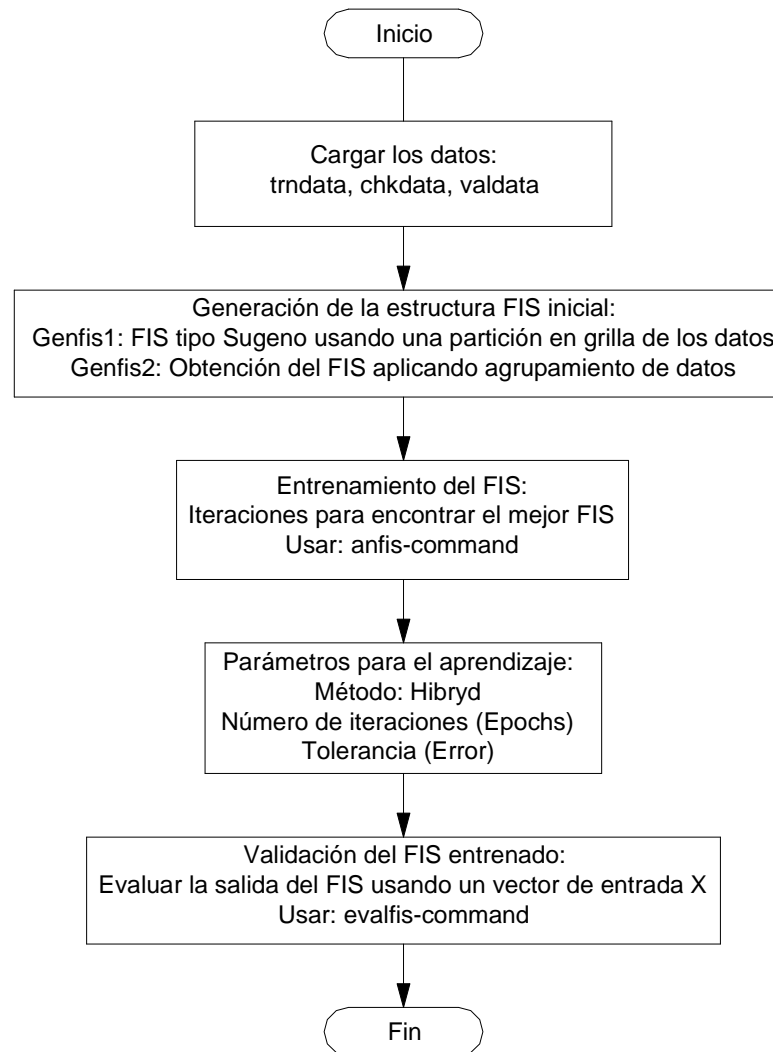


Figura 3.8 Utilización del ANFIS Editor GUI en MATLAB



3.5 ENTRENAMIENTO, VERIFICACIÓN Y VALIDACIÓN DEL MODELO.

Los modelos neuro-difusos son entrenados usando el algoritmo ANFIS, el cual optimiza los parámetros de las reglas y de las funciones de pertenencia. El entrenamiento consiste en un número predefinido de iteraciones (*epochs*) necesario para minimizar una función de error y ajustar los parámetros del sistema difuso (funciones de pertenencia y conjunto de reglas) en cada iteración, con la finalidad de lograr con el modelo obtenido una mejor estimación de la detección y clasificación de la falla.

El modelo necesita a su vez la verificación de que en el proceso de entrenamiento, los valores estimados como salida del ANFIS, lleven concordancia, con la salida deseada y no se produzca el fenómeno llamado sobreentrenamiento (*overfitting*). Este fenómeno se produce cuando el sistema obtenido no es capaz de generalizar adecuadamente la salida con datos diferentes a los datos de entrada

El último paso de la metodología es la validación del modelo o de los modelos obtenidos. El procedimiento de validación consiste en alimentar cada modelo neuro-difuso con los datos de entrada tomados del conjunto de datos de validación, obtener la salida correspondiente (que es la detección y clasificación de la falla) y comparar esta salida con los datos de salida del conjunto de datos de validación (que es el valor real de fallas del sistema ecuatoriano).

Se muestran los resultados para diferentes casos y se realiza un análisis del error incurrido entre los datos reales y datos estimados obtenidos del modelo, para cada uno del conjunto de datos de entrenamiento, verificación y validación.

3.5.1 Datos para Entrenamiento, Verificación y Validación

El entrenamiento completo significa emplear separadamente varios conjuntos de datos de entrenamiento y de verificación, obtenidos de varias perturbaciones simuladas en una línea de transmisión típica que se analiza. Este entrenamiento se realiza empleando el algoritmo de entrenamiento híbrido implementado en el sistema ANFIS.

En este paso el conjunto de datos de entrenamiento (*training*) sirve para entrenar el modelo ANFIS creado mediante un procedimiento iterativo que minimiza una función de error y a la vez ajusta los parámetros del modelo (funciones de pertenencia y conjunto de reglas) con la finalidad de lograr con cada modelo difuso ajustado la mejor estimación de la detección y clasificación de la falla.

Los datos de verificación (*checking*) sirven en cambio, para establecer en cada paso de entrenamiento la capacidad de generalización o aprendizaje que va adquiriendo el modelo neuro-difuso. Los datos de verificación evitan también que se presente sobreentrenamiento en el modelo. En principio, el error para el conjunto de datos de verificación tiende a disminuir a medida que el entrenamiento toma lugar hasta el punto en que el sobreentrenamiento



comienza, entonces el error para los datos de verificación aumenta repentinamente.

Después de que el modelo ANFIS ha sido entrenado, corresponde probar esos modelos con los datos de validación (*testing*), para indagar que el modelo, provea como resultado, la mejor estimación para la detección y clasificación de la falla. Esta prueba se realiza con diferentes conjuntos de datos reales de eventos ocurridos en el SNT Ecuatoriano.

El conjunto de datos de entrada-salida se seleccionan en una forma que sea utilizable por el modelo ANFIS, tanto para el entrenamiento, verificación y validación. En general, este tipo de modelo funciona bien si los datos de entrenamiento presentados al ANFIS para el entrenamiento de los parámetros de la función de pertenencia, es plenamente representativo de las características de los datos que se destine al FIS que se intenta modelar.

Un problema con la validación del modelo para los modelos construidos utilizando técnicas adaptivas es la selección de un conjunto de datos que sea representativo de los datos que se destinan al entrenamiento del modelo, y a su vez lo suficientemente distinta de los datos de entrenamiento para no hacer del proceso de validación trivial.

3.5.2 Evaluación del Error:

Es deseable obtener un margen de error lo más reducido posible, sin embargo no existe un método formal que permita estimar el margen de error deseable directamente. Por esto, el proceso para la creación de los modelos ANFIS se convierte en un proceso de prueba y error, variando los diferentes parámetros de la técnica empleada.

Para efectos de evaluar que el modelo conduce a la mejor estimación de la salida deseada, se define el Error Medio Cuadrático (MSE) como:

$$MSE = \frac{\sum_{i=1}^n [Y_i - D_i]^2}{n} \quad (3.2)$$

Donde:

- n: Número total del conjunto de datos de entrada
- Y_i: Valor que determina la detección y clasificación de la falla según la metodología del punto 3.4.3
- D_i: Valor estimado por el ANFIS, para la detección y clasificación de la falla.

En el presente trabajo, se analiza la variación del error medio cuadrático únicamente, que es el error que define la herramienta de MATLAB.

3.5.3 Entrenamiento, verificación y validación del modelo

Se realiza el entrenamiento del modelo ANFIS y su respectiva verificación y posterior validación. La base de datos formada para aquello, corresponde a



casi 600 registros simulados, para diferentes escenarios de fallas en el SEP analizado y a 60 registros de fallas reales del SNT Ecuatoriano.

Mediante ANFIS, se procede con el entrenamiento y verificación del modelo, con los registros obtenidos de las simulaciones (565 registros), de los cuales aleatoriamente, un total aproximado al 70% se utilizan para el entrenamiento, mientras que el 30% restantes se utilizan para la verificación.

Finalmente, para validar el modelo, se utilizan los 60 registros reales de fallas en el SNT Ecuatoriano y se procede a validar el algoritmo de detección y clasificación de fallas.

La base de datos que conforma los datos para validación, son fallas reales ocurridas en líneas de transmisión del SNT a 230 kV, registrados desde el 2010 hasta el 2012.

Con lo anterior, se establece el error de validación, de manera de observar que tan bien está estimando el modelo ANFIS, la detección y la clasificación de la falla. Con estos errores se realiza el análisis correspondiente, para su utilización o no. Los resultados de este proceso, se muestran en el capítulo siguiente.



CAPITULO 4. RESULTADOS

4.1 ENTRENAMIENTO, VERIFICACIÓN Y VALIDACIÓN DE LOS MODELOS ANALIZADOS

A continuación, se presentan y analizan los resultados del proceso de entrenamiento, verificación y validación según la metodología desarrollada en el capítulo anterior, mediante los métodos *Grid Partition* (GP) y *Subtractive Clustering* (SC). Para la obtención del ANFIS se eligen como datos de entrada todas las muestras de más de los 600 registros obtenidos en el proceso de simulación y más de 60 registros de fallas reales del SNT ecuatoriano. En esta condición, se analizan:

- a) Cuatro ANFIS que corresponden a los datos de corrientes de las Fase A, B, C y secuencia cero por separado.
- b) Un solo ANFIS al que se le ingresan datos de corrientes de las fases A, B, C y secuencia cero en conjunto.

4.1.1 Resultados preliminares usando como datos de entrada el valor representativo en la ventana de falla.

Inicialmente se realiza un análisis de sensibilidad con varios modelos ANFIS con el fin de establecer un error de estimación adecuado para los propósitos del trabajo. Se utilizan los dos métodos para la detección y clasificación de la falla visto en la metodología, es decir 4 ANFIS para las fases A, B, C y secuencia cero y un solo ANFIS al que se le ingresan las fases y secuencia cero en conjunto.

Los datos de entrada para este análisis corresponden a un total de más de 600 registros tanto para el entrenamiento como para la verificación y validación y toman únicamente el valor representativo en la ventana de falla, del registro a analizar.

Para la creación del FIS inicial se utilizan las técnicas conocidas como *Grid Partition*, y *Sustractive Clustering*. En la primera técnica se varía el tipo y número de funciones de pertenencia: entre 3 y 5 MF (Funciones de Pertenencia o en inglés *Membership Functions*) y tipos triangular, gaussiana y campana generalizada. En la segunda técnica se varía el radio de proximidad r_a ; entre 0.1 y 0.7. Con $r_a=0.2$ se produce un modelo con mayor cantidad de reglas; lo contrario sucede cuando se usa un valor más grande $r_a=0.5$.

Las tablas 4.1 y 4.2 muestran el error medio cuadrático (MSE) para los 4 ANFIS obtenidos para las fases A, B, C y secuencia cero por separado, mientras que la tabla 4.3 muestra los resultados de un solo ANFIS obtenido para las fases A, B, C y secuencia cero en conjunto.



Tabla 4.1 Error MSE para diferentes ANFIS obtenidos mediante el método *Grid Partition*, para las fases A, B, C y secuencia cero

DATOS DE ENTRADA/SALIDA					Error MSE			
ENTRADA	N	TRN	CHK	VAL	Tipo	TRN	CHK	VAL
Fase A	643	423	141	79	3MF-gbell	0.089345	0.093788	0.15944
	643	423	141	79	5MF-gbell	0.083914	0.089771	0.15364
	643	423	141	79	5MF-tri	0.088227	0.096	0.15978
	643	423	141	79	3MF-gauss	0.084207	0.090614	0.16985
	643	423	141	79	3MF-gbell	0.068008	0.069928	0.15927
	643	423	141	79	4MF-gbell	0.063374	0.063798	0.15086
	643	423	141	79	5MF-gbell	0.060342	0.060291	0.12222
	601	412	138	51	5MF-gbell	0.075613	0.085727	0.15664
Fase B	601	412	138	51	5MF-gbell	0.060871	0.066074	0.14286
Fase C	601	412	138	51	5MF-gbell	0.041046	0.057117	0.15556
Secuencia cero	651	423	141	87	3MF-gbell	0.11249	0.0416	0.11126
	651	423	141	87	5MF-gbell	0.11436	0.043313	0.11025
	651	423	141	87	3MF-gauss	0.11433	0.042088	0.11258
	635	414	139	82	3MF-gbell	0.0082812	0.17016	0.023557
	635	414	139	82	5MF-gbell	0.0084112	0.17009	0.01925
	601	412	138	51	3MF-gbell	0.058152	0.074695	0.20028

Tabla 4.2 Error MSE para diferentes ANFIS obtenidos mediante el método *Sustractive Clustering*, para las fases A, B, C y secuencia cero



DATOS DE ENTRADA/SALIDA					Error MSE			
ENTRADA	N	TRN	CHK	VAL	Tipo	TRN	CHK	VAL
Fase A	643	423	141	79	2MF - ra=0.5	0.082958	0.091897	0.15141
	643	423	141	79	4MF - ra=0.2	0.087209	0.099494	0.1575
	643	423	141	79	8MF - ra=0.1	0.074464	0.079877	0.14166
	643	423	141	79	2MF - ra=0.7	0.083321	0.091081	0.16168
	643	423	141	79	2MF - ra=0.5	0.051344	0.048701	0.11168
	643	423	141	79	4MF - ra=0.2	0.048722	0.042422	0.097584
	643	423	141	79	8MF - ra=0.1	0.037974	0.035329	0.088609
	601	412	138	51	2MF - ra=0.5	0.069953	0.082335	0.15072
Fase B	601	412	138	51	4MF - ra=0.2	0.048498	0.053059	0.12508
Fase C	601	412	138	51	3MF - ra=0.2	0.033237	0.051	0.13419
Secuencia cero	651	423	141	87	2MF - ra=0.5	0.11708	0.035841	0.11564
	651	423	141	87	3MF - ra=0.2	0.11353	0.042672	0.11022
	651	423	141	87	8MF - ra=0.1	0.11366	0.042474	0.10861
	635	414	139	82	2MF - ra=0.5	0.0044377	0.16986	0.009691
	635	414	139	82	4MF - ra=0.1	0.00059699	0.16965	0.00069859
	601	412	138	51	3MF - ra=0.4	0.053973	0.072771	0.18572

Tabla 4.3 Error MSE para diferentes ANFIS obtenidos mediante los métodos *Grid Partition* y *Sustractive Clustering*, para las fases A, B, C y secuencia cero consideradas en conjunto



DATOS DE ENTRADA/SALIDA					Error MSE - Grid Partition Method				Error MSE - Subtractive Clustering Method			
ENTRADA	n	TRN	CHK	VAL	tipo	TRN	CHK	VAL	tipo	TRN	CHK	VAL
Fases ABC y Secuencia cero	630	423	142	65	3x4MF-gbell	0.38251	0.98858	9.434	7MF - ra=0.5	0.84067	1.0033	1.035
	630	423	142	65	3x4MF-tri	0.50599	4.3064	9.8552	22MF - ra=0.3	0.54844	0.91282	1.7581
	630	423	142	65	3x4MF-gauss	0.38584	1.1056	6.0021	36MF - ra=0.2	0.51562	0.92447	1.7309
	630	423	142	65	4x4MF-gbell	0.37353	4.8063	6.6887	64MF - ra=0.1	0.39741	1.007	2.6461
	592	399	133	60	3MF-gbell	0.27058	1.4414	3.787	7MF - ra=0.5	0.57547	0.60109	0.80786
	592	399	133	60	4MF-gbell	0.28326	1.1505	5.1551	31MF - ra=0.2	0.37254	1.4059	4.3264
	601	412	138	51	3MF-gbell	0.028845	0.1199	1.2956	33MF - ra=0.2	0.018622	0.079318	1.5587



Los resultados muestran lo siguiente:

- Mientras más funciones de pertenencia y reglas de decisión se usan, el modelo estima valores con errores más bajos.
- Con la utilización de un amplio número de reglas de decisión, el modelo puede caer en un proceso trivial, o peor aún converger en un tiempo largo o simplemente no converger debido a la alta capacidad de memoria que requiere.
- Los resultados obtenidos para una función de pertenencia tipo campana generalizada (*gbell*) y 3MF, se adapta adecuadamente al universo de entrada considerado.
- En el entrenamiento, el método *Sustractive Clustering* obtiene mejores resultados que su homólogo *Grid Partition*.
- El tiempo de convergencia es más rápido, con el método SC, llegando a considerar hasta más de 30 MF sin inconvenientes

4.1.2 Resultados usando el registro de fallas completo

Se procede a entrenar el ANFIS con más de 18000 muestras para entrenamiento, verificación y validación tanto para el caso 4 ANFIS como para el caso de un solo ANFIS, para la detección y clasificación.

Para la obtención del FIS inicial, se utilizan 3 funciones de pertenencia tipo campana generalizada para el método GP y variaciones de r_a entre 0.1 y 0.2 para el método SC.

Los resultados del error MSE obtenido, se muestran en la tabla 4.4.



Tabla 4.4 Error MSE para diferentes ANFIS obtenidos mediante los métodos Grid Partition y Sustractive Clustering, para las fases A, B, C y secuencia cero consideradas en conjunto y por separado, pero con las muestras completas de cada registro.

DATOS DE ENTRADA/SALIDA					Error MSE - Grid Partition Method				Error MSE - Subtractive Clustering Method			
ENTRADA	n	TRN	CHK	VAL	tipo	TRN	CHK	VAL	tipo	TRN	CHK	VAL
Fase A	24550	12444	4148	7958	3MF-gbell	0.055453	0.06611	0.091768	2MF - ra=0.2	0.056284	0.071854	0.23087
	24550	12444	4148	7958	3MF-gbell	0.096715	0.10867	0.2963	2MF - ra=0.2	0.10785	0.12162	0.077364
	18877	11628	3876	3373	3MF-gbell	0.048248	0.060715	0.082181	3MF - ra=0.2	0.042564	0.055808	0.2317
Fase B	18877	11628	3876	3373	3MF-gbell	0.040434	0.054143	0.12658	3MF - ra=0.2	0.031324	0.043666	0.44903
Fase C	18877	11628	3876	3373	3MF-gbell	0.030046	0.038871	0.098387	3MF - ra=0.2	0.024102	0.034894	0.29489
Secuencia cero	18877	11628	3876	3373	3MF-gbell	0.041583	0.052193	0.0707	3MF - ra=0.1	0.041132	0.05026	0.065932
Fase ABC y secuencia cero	24550	12444	4148	7958	3MF-gbell	0.30544	0.46803	11.0748	32MF - ra=0.2	0.20131	0.40879	4.2017
	18877	11628	3876	3373	3MF-gbell	0.11617	0.42866	5.3711	25MF - ra=0.2	0.1437	0.35457	1.0892
	18134	11527	3843	2764	3MF-gbell	0.13525	0.15534	0.2809	32MF - ra=0.2	0.18749	0.20869	2.4701

4.1.3 Resultados de los 4 ANFIS para las corrientes de las fases A, B y C y corriente de secuencia cero.

Se realiza el entrenamiento de los 4 ANFIS para las corrientes de fase y de secuencia cero, utilizando 11628 muestras de entrenamiento, 3876 muestras para verificación y 3373 muestras de validación. El análisis se realiza utilizando como datos de entrada las corrientes de la fase C, para las fases A, B y corrientes de secuencia cero, no fue necesario exponer el análisis ya que se obtienen valores similares.

La primera gráfica ilustra el conjunto de datos de entrenamiento, verificación y validación versus la salida deseada, que en este caso es “0” cuando no existe falla, “1” para fallas de alta impedancia y “2” para fallas de baja impedancia.

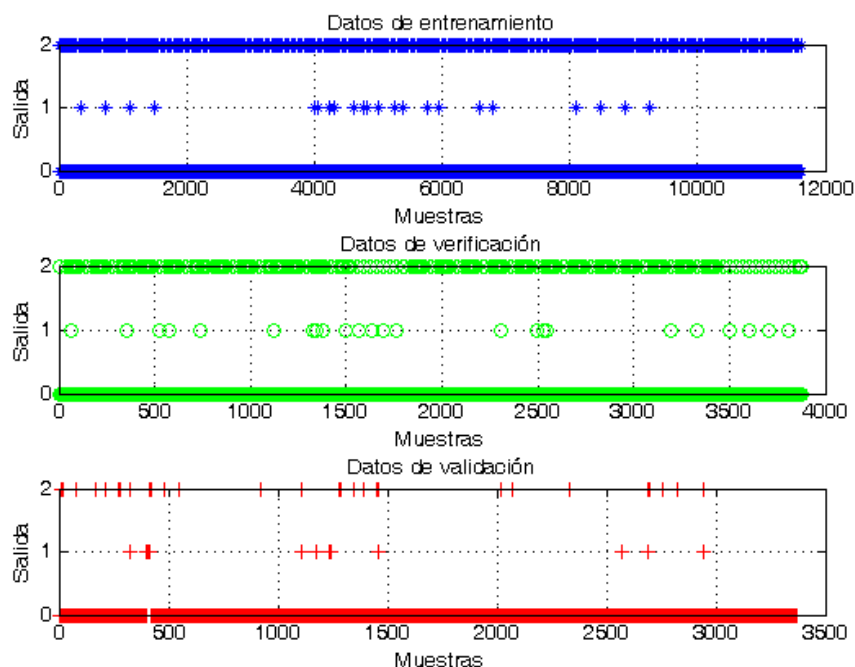


Figura 4.1 Conjunto de datos de entrenamiento, verificación y validación VS. la salida deseada, para la corriente de la fase C.

La Figura 4.2 muestra la correspondiente función de pertenencia del FIS inicial obtenida aplicando el algoritmo de *Grid Partition* con 3MF tipo campana generalizada, mientras que la figura 4.3 ilustra la función de pertenencia pero usando el sistema ANFIS. Aplicando el sistema ANFIS, los parámetros de las funciones de pertenencia se afinan para lograr mejores estimaciones para la detección y clasificación de la falla.

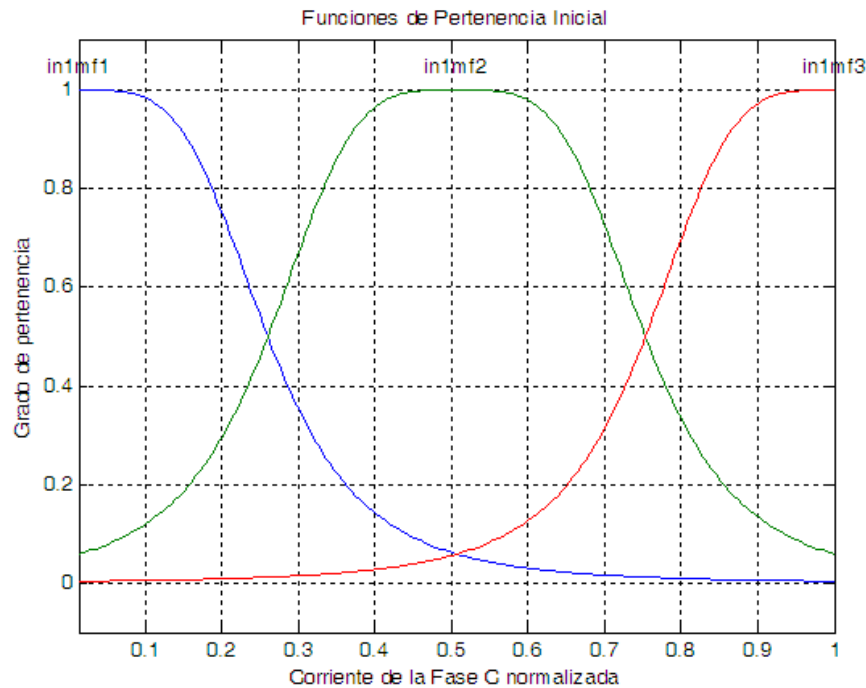


Figura 4.2 Funciones de pertenencia del FIS inicial, de la corriente de la fase C

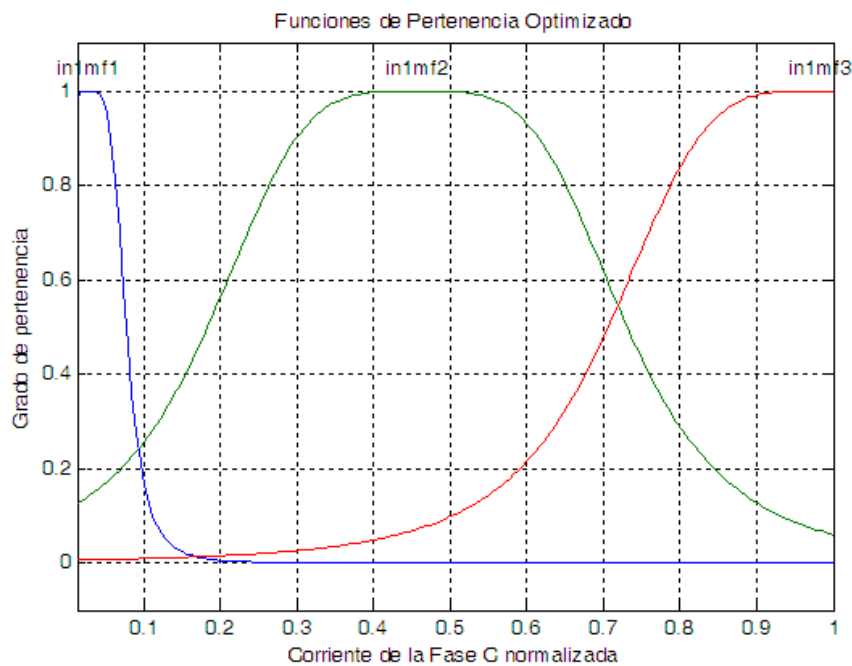


Figura 4.3 Funciones de pertenencia de la corriente de la fase C posterior al entrenamiento y verificación.

Para indagar cómo influye en los errores de entrenamiento y de verificación la cantidad de iteraciones con que se prueban los modelos neuro difusos se ha construido la Figura 4.4 donde se ilustra el número de iteraciones (EPOCHS) versus el Error medio cuadrático (RMSE) de entrenamiento y verificación, para las muestras de la corriente de la fase C. Para el presente caso de estudio, se logró un error de entrenamiento de 0.030046 y un error de

verificación de 0.038871 justo antes de las 20 iteraciones, obtenidas mediante el método *Grid Partition*.

La tabla 4.4 también describe el error del análisis realizado mediante el método *Subtractive Clustering* el cual obtiene un error RMSE mínimo de entrenamiento de 0.024102 y de verificación de 0.034894.




Figura 4.4 Evolución del error de entrenamiento y verificación usando un ANFIS para la corriente de la Fase C como entrada

En las Figuras 4.5 y 4.6 se ilustra la salida FIS que es la clasificación de la falla versus las muestras de entrenamiento y verificación para la corriente de la fase C, mostrando que éstas últimas son adecuadamente clasificadas por el modelo con un error razonable.

La figura 4.7 muestra la salida FIS para el conjunto de datos de entrenamiento y verificación, para la corriente de la fase C normalizada entre [0,1], donde se indica el proceso de clasificación "0", "1" y "2" de acuerdo al valor de la corriente.




Figura 4.5 Salida FIS Vs los datos de entrenamiento de la corriente de la fase C




Figura 4.6 Salida FIS Vs los datos de verificación de la corriente de la fase C

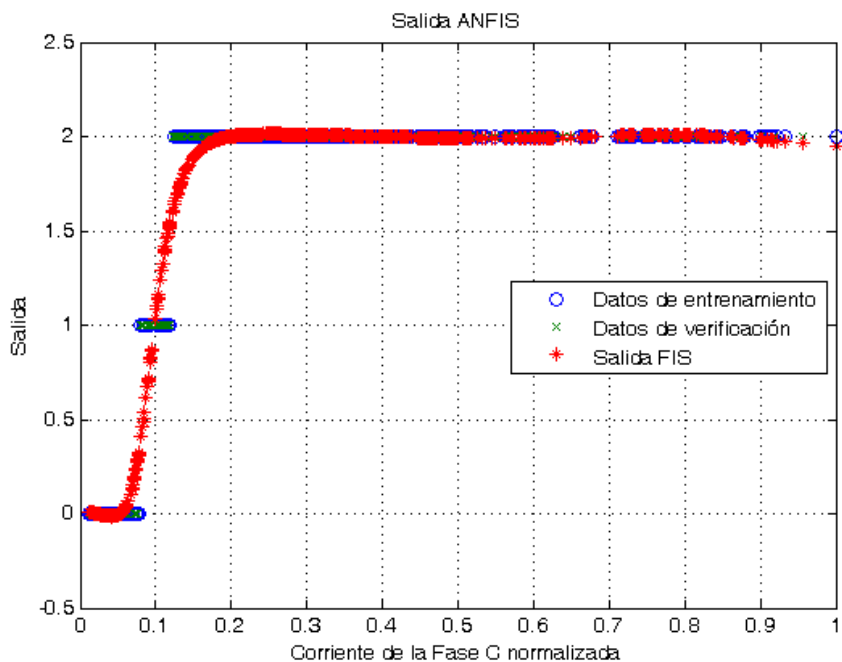


Figura 4.7 Salida FIS Vs el valor de la corriente de la fase C normalizada, que evidencia la evolución de la clasificación

Finalmente la Figura 4.8 ilustra la salida FIS vs las muestras de validación para la corriente de la fase C. El error medio cuadrático muestra un valor de 0.098387.

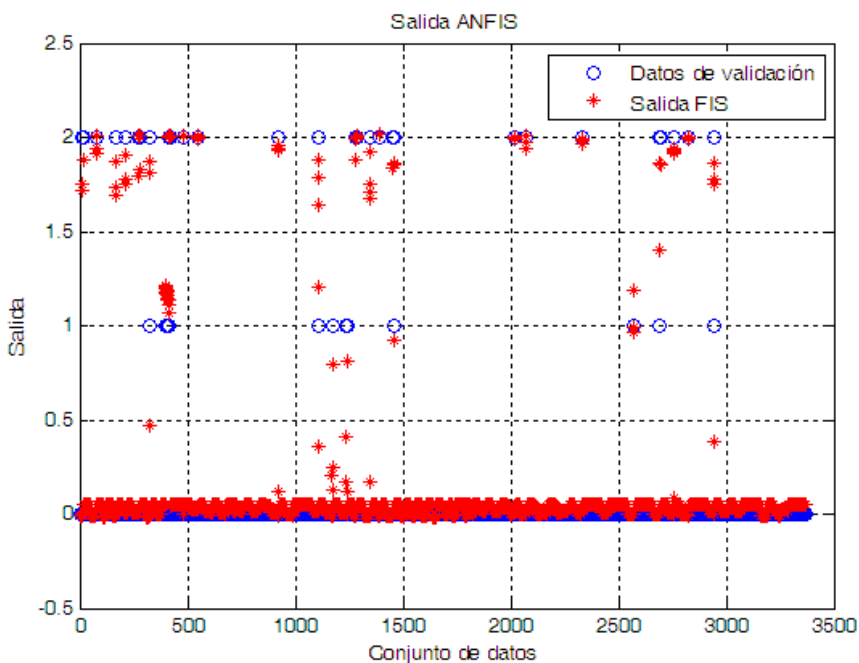


Figura 4.8 Salida FIS Vs los datos de validación de la corriente de la fase C

4.1.4 Resultados para el ANFIS tomando como datos de entrada las corrientes de las fases A, B, C y corriente de secuencia cero en conjunto.

Se realiza el entrenamiento de un único ANFIS tomando como datos de entrada las corrientes de las fases A, B, C y secuencia cero en conjunto, para este análisis se utilizan 11527 muestras de entrenamiento, 3843 muestras para verificación y 2764 muestras de validación.

En la figura 4.9 se muestra el conjunto de datos de entrenamiento, verificación y validación versus la salida deseada, que en este caso es un valor entre [0 y 10] dependiendo del tipo de falla (por ejemplo: "0" sin presencia de falla, "1" falla tipo A-T, "2" falla tipo B-T, etc.)

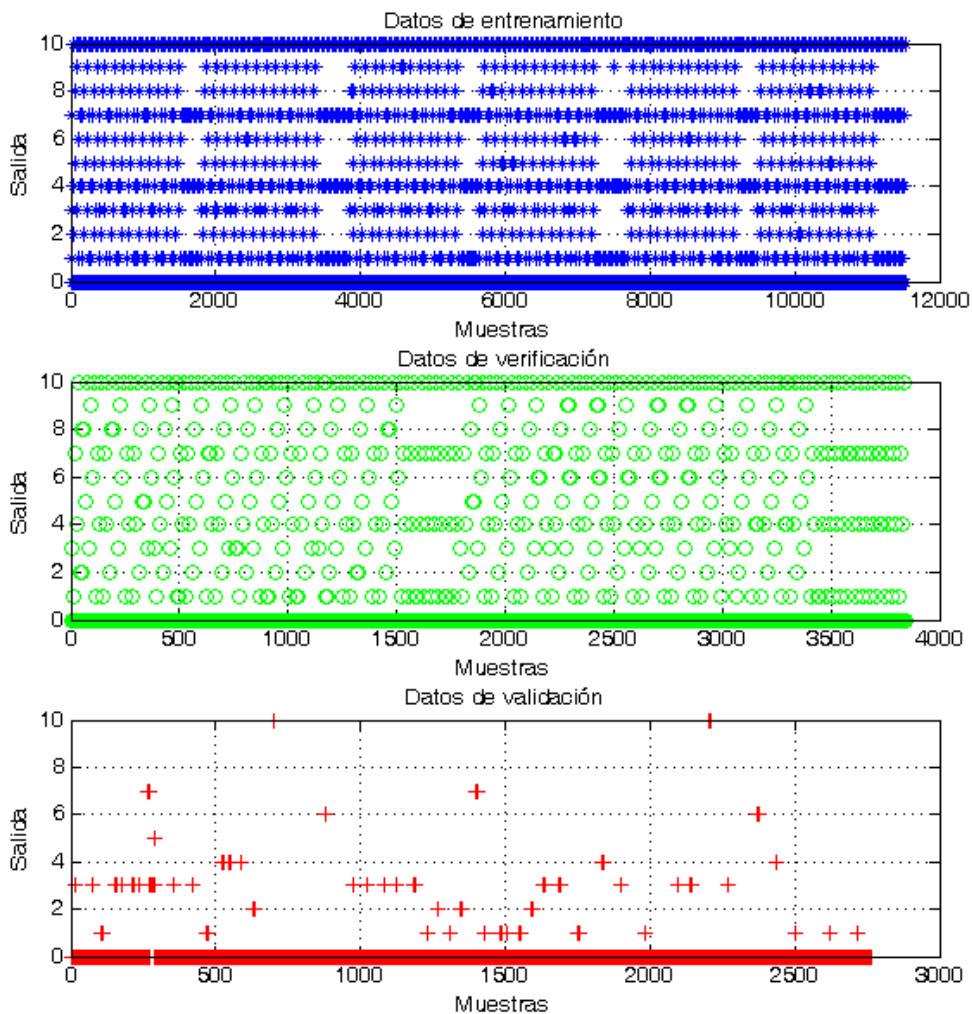


Figura 4.9 Conjunto de datos de entrenamiento, verificación y validación Vs la salida deseada

Las funciones de pertenencia inicial, mediante el método GP y optimizada utilizando ANFIS se ilustran en las figuras 4.10 y 4.11.

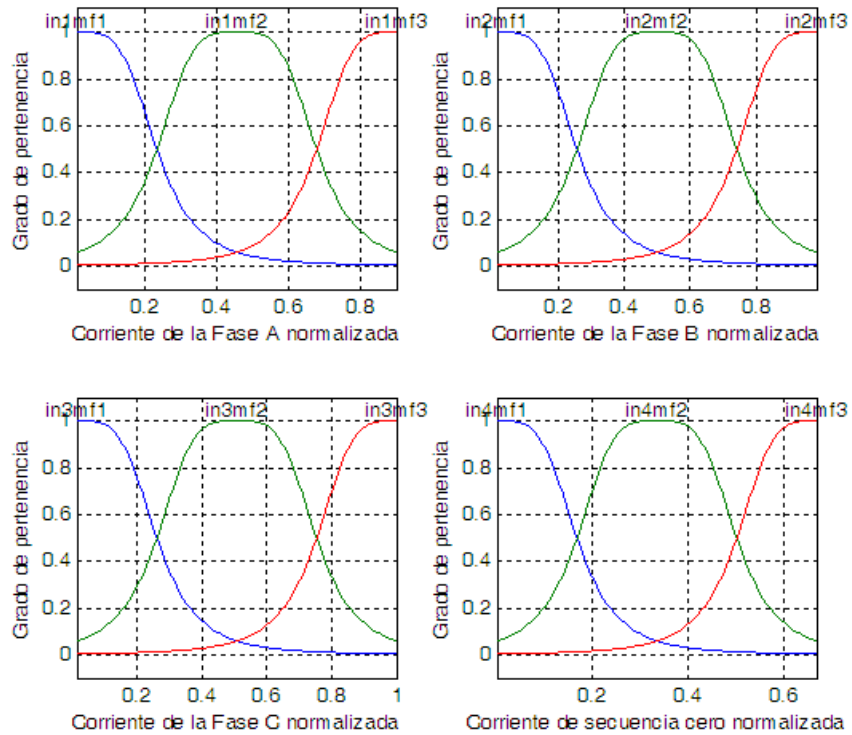


Figura 4.10 Funciones de pertenencia iniciales para las fases A, B, C y secuencia cero

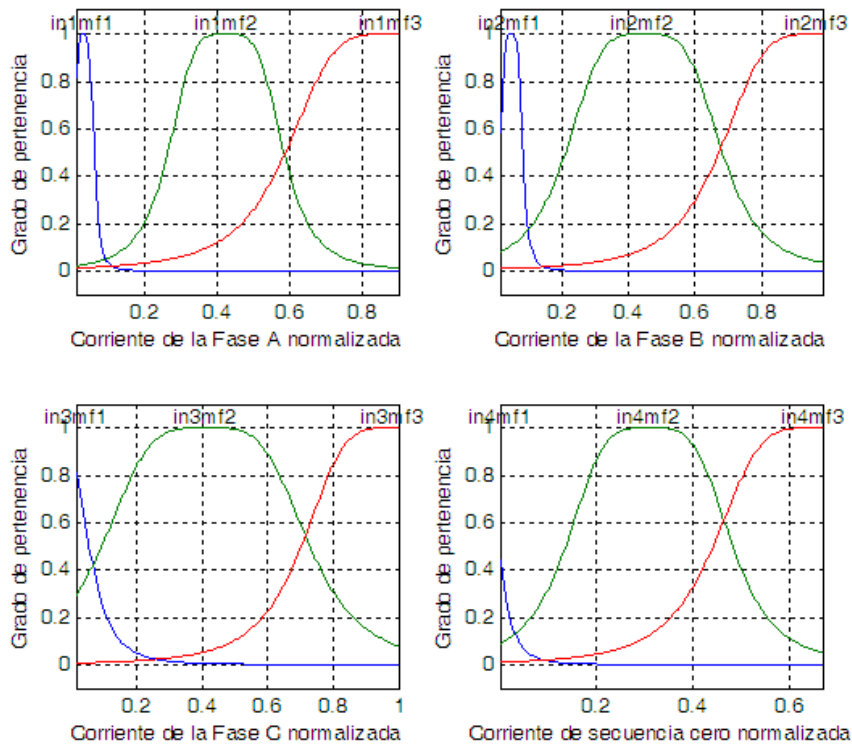


Figura 4.11 Funciones de pertenencia optimizadas para las corrientes de fases y secuencia cero.

El número de iteraciones (EPOCHS) vs el Error medio cuadrático de entrenamiento y verificación, para las muestras de corrientes de fase y secuencia cero se ilustran en la figura 4.12. Para el presente caso de estudio, se logró un error de entrenamiento de 0.13525 y un error de verificación de 0.15534 justo antes de las 50 iteraciones.




Figura 4.12 Evolución del error de entrenamiento y verificación usando un ANFIS para las corrientes de fase y secuencia cero como entrada

En las Figuras 4.13, 4.14 y 4.15 se ilustra la salida FIS vs las muestras de entrenamiento, verificación y validación para el presente caso de estudio. El error MSE para las muestras de validación, es de 0.2809.




Figura 4.13 Salida FIS Vs los datos de entrenamiento

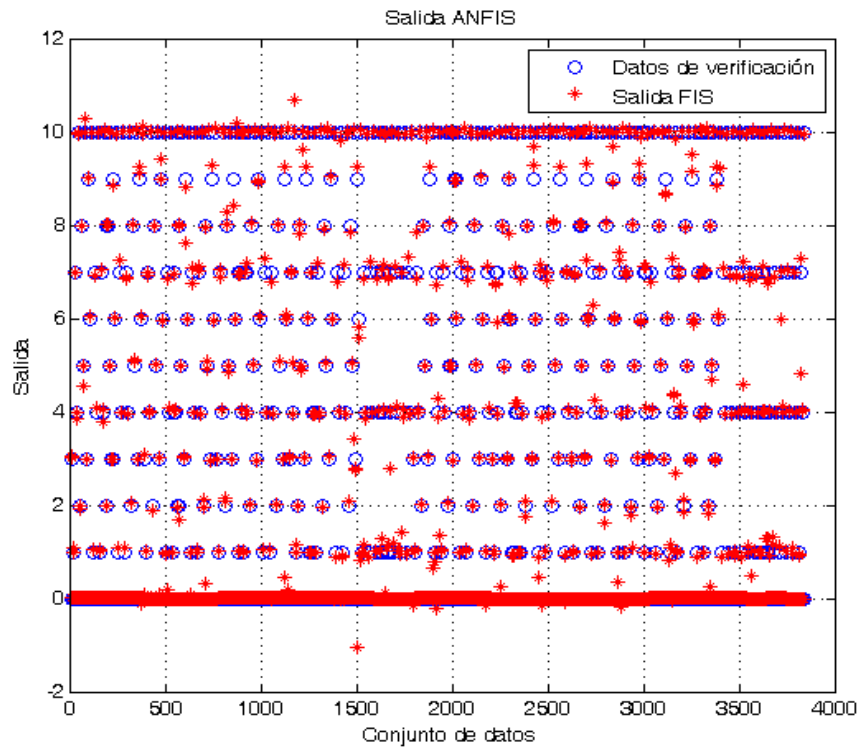


Figura 4.14 Salida FIS Vs los datos de verificación

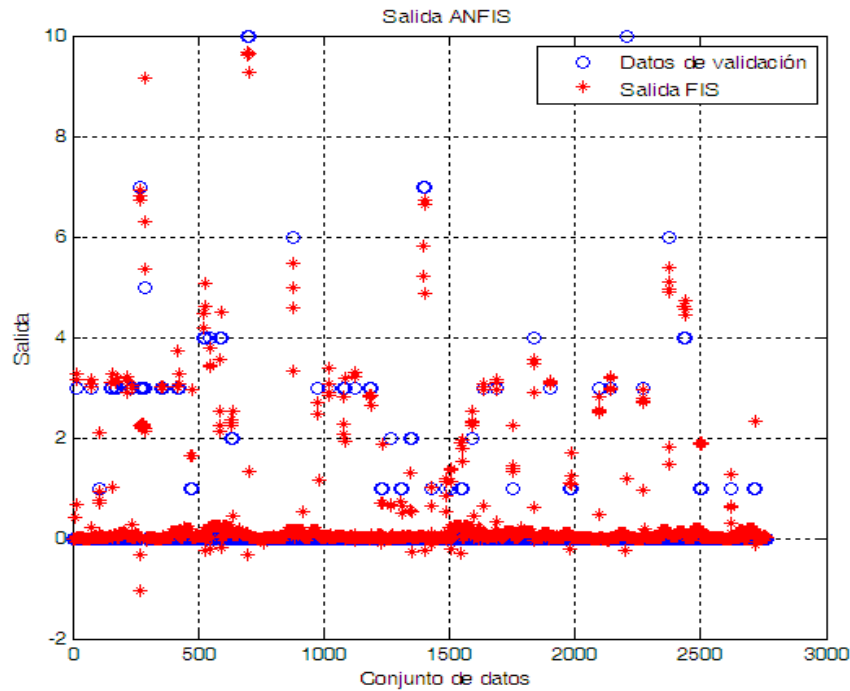


Figura 4.15 Salida FIS Vs los datos de validación

4.2 ANÁLISIS DEL PROCESO DE ENTRENAMIENTO, VERIFICACIÓN Y VALIDACIÓN

Los resultados anteriores muestran que mediante el modelo ANFIS se puede lograr un mapeo adecuado entre las entradas y las salidas en un amplio rango de variación de las señales de entrada manteniendo a su vez un error de clasificación bajo.

Sin embargo, del análisis realizado, al igual que presenta también en la referencia [1], se pudieron identificar varias falencias del modelo, cuando se varían ciertas condiciones del sistema eléctrico de potencia, que hace que las muestras de entrada generadas no logren clasificarse adecuadamente con un error bajo.

Para lograr minimizar el error, en algunos casos detectados, se realizó una depuración del conjunto de muestras de entrada de tal manera que se lograra el objetivo deseado.

La falla trifásica aislada y la falla trifásica a tierra arrojaron resultados muy similares y con ello se generaban errores altos debido a que el algoritmo no lograba separar adecuadamente ambas situaciones. En este caso se optó por retirar las muestras de entrada correspondientes con la falla trifásica a tierra.

Obstáculos similares se tuvieron con la variación de la impedancia de falla presentándose grandes dificultades de clasificación a medida que el valor de impedancia se iba subiendo y haciendo que los valores resultantes tendieran a confundirse con las corrientes de estado estacionario. En este caso, se



hizo, necesario considerar la variación de la impedancia de falla hasta un valor máximo de 30 ohmios.

Situaciones similares se experimentaron a medida que se subía el valor de las impedancias fuente (para simular sistemas más débiles). En este caso, fue necesario considerar impedancias fuente de ciertos valores que permitieran una clasificación adecuada de las fallas (es decir, seleccionar valores que permitieran discriminar entre estado estable y condiciones de falla).

En primera instancia, y tal como se expone en la referencia [2] se utilizaron 4 ANFIS diferentes, uno para cada una de las fases. Es decir, la entrada de cada modelo es el valor RMS de la fase correspondiente, y la salida es un valor numérico que especifica si tal fase se encuentra fallada o no. Esta aproximación supone un inconveniente, el sistema sólo es capaz de determinar un tipo de falla específico para unas características muy específicas del sistema eléctrico en que se produjeron, lo que se traduce en errores de validación y chequeo muy altos.

En segunda instancia se utilizó el modelo ANFIS de otra manera diferente. En este caso se utilizó un solo modelo ANFIS en el que las entradas corresponden a las 4 corrientes y la salida corresponde al tipo de falla. Este modelo presentó un grado de robustez mayor respecto a la aproximación anterior pues las entradas se evaluaron de manera conjunta.

De lo anterior se observa una gran dificultad de adaptarse a fallas de alta impedancia, debido a que los valores se confunden entre un valor de falla y un valor de carga.

4.3 EJEMPLO DE APLICACIÓN DEL MODELO

Se realiza varios análisis para fallas reales ocurridas en el SNT Ecuatoriano, para validar el desempeño del modelo ANFIS obtenido.

Se realizó el análisis con los siguientes casos:

a) Falla tipo fase C a tierra de la L/T Milagro-Zhoray 230 kV CTO 1.

Se utilizaron 4 ANFIS para cada una de las fases y secuencia cero. Para el caso de las fases sin falla (A y B), el resultado del ANFIS debe ser cero, mientras que para la fase fallada C y secuencia cero, el resultado del ANFIS debe ser 2, al tratarse de una falla de alta impedancia.

En la figura 4.16 se observa los resultados de los 4 ANFIS versus la salida deseada. Se evidencia claramente que las salidas para las fases A y B son cero (sin falla) mientras que la fase C y la secuencia cero muestran un valor de 2 en la ventana de falla, que corresponde a la clasificación tipo fase C a tierra.




Figura 4.16 Resultados de los 4 ANFIS para las corrientes de las fases A, B, C y secuencia cero, para el caso de una falla de alta impedancia tipo C-T

b) Falla Fase C a tierra de baja impedancia, ocurrido en la L/T Jamondino-Pomasqui 230 kV en el CTO. 4.

En este caso, el resultado deseado para una falla tipo C-T de baja impedancia, debe ser 1, según la clasificación propuesta.

La figura 4.17 muestra que el valor obtenido para el ANFIS de cada una de las fases y secuencia cero son "0" para el caso sin falla y "1" para una falla de baja impedancia.

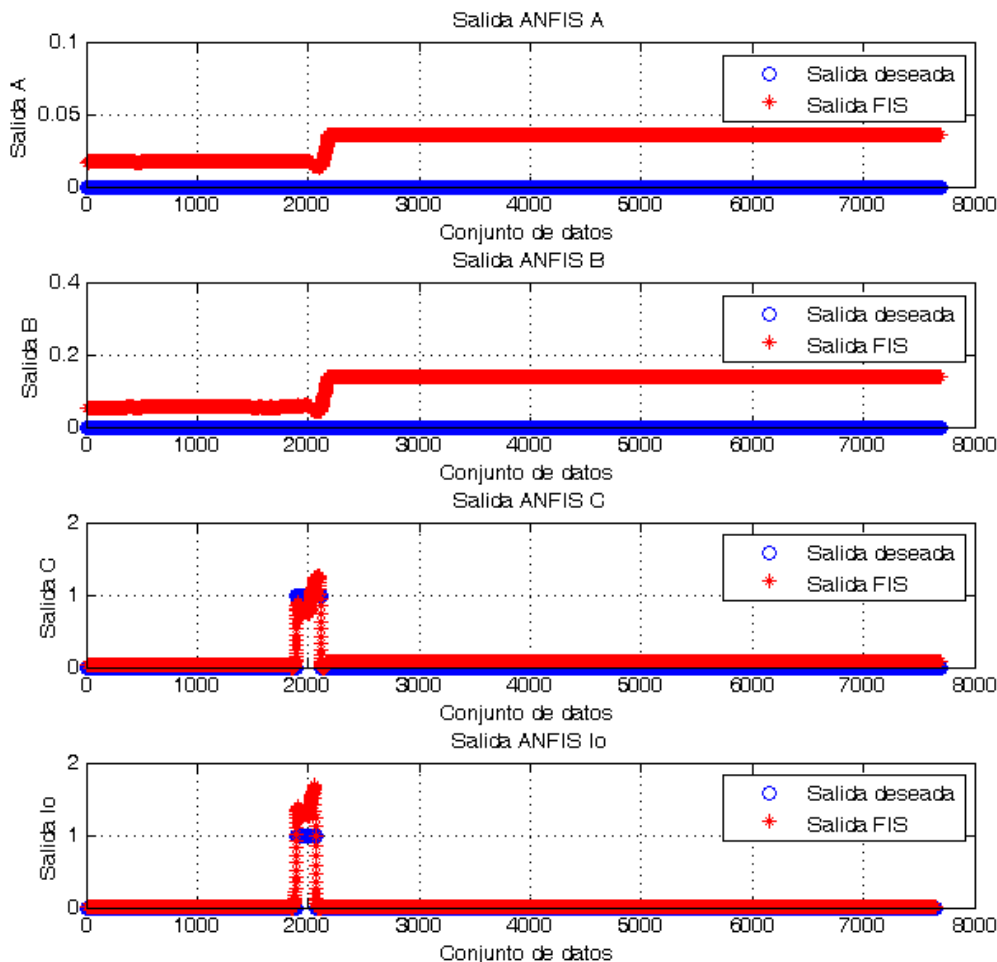


Figura 4.17 Resultados de los 4 ANFIS para las corrientes de las fases A, B, C y secuencia cero, para el caso de una falla de baja impedancia tipo C-T

Para los resultados de los ejemplos a y b se utilizó el método GP con 3 funciones de pertenencia tipo campana generalizada para el FIS inicial, tomando como dato de entrada todas las muestras del registro COMTRADE de la falla (entre 3000 a 8000 muestras). La optimización se logra con 50 iteraciones en un tiempo aproximado de 10 segundos por cada fase.

c) Falla de las fases AB a tierra, de la L/T Santa Rosa – Pomasqui CTOS 1 y 2 230 kV.

Se utiliza un solo ANFIS para las corrientes de las fases A, B, C y secuencia cero, para la detección y clasificación de la falla, según la metodología propuesta en el capítulo 3. La salida deseada para este tipo de falla AB-T da un valor de 4 como clasificación.

La figura 4.18 ilustra dos graficas, que muestran la salida ANFIS. Los valores estimados por el ANFIS logran satisfacer el requerimiento, es decir el valor numérico 4, aunque el error obtenido supera el valor de 0.2474.

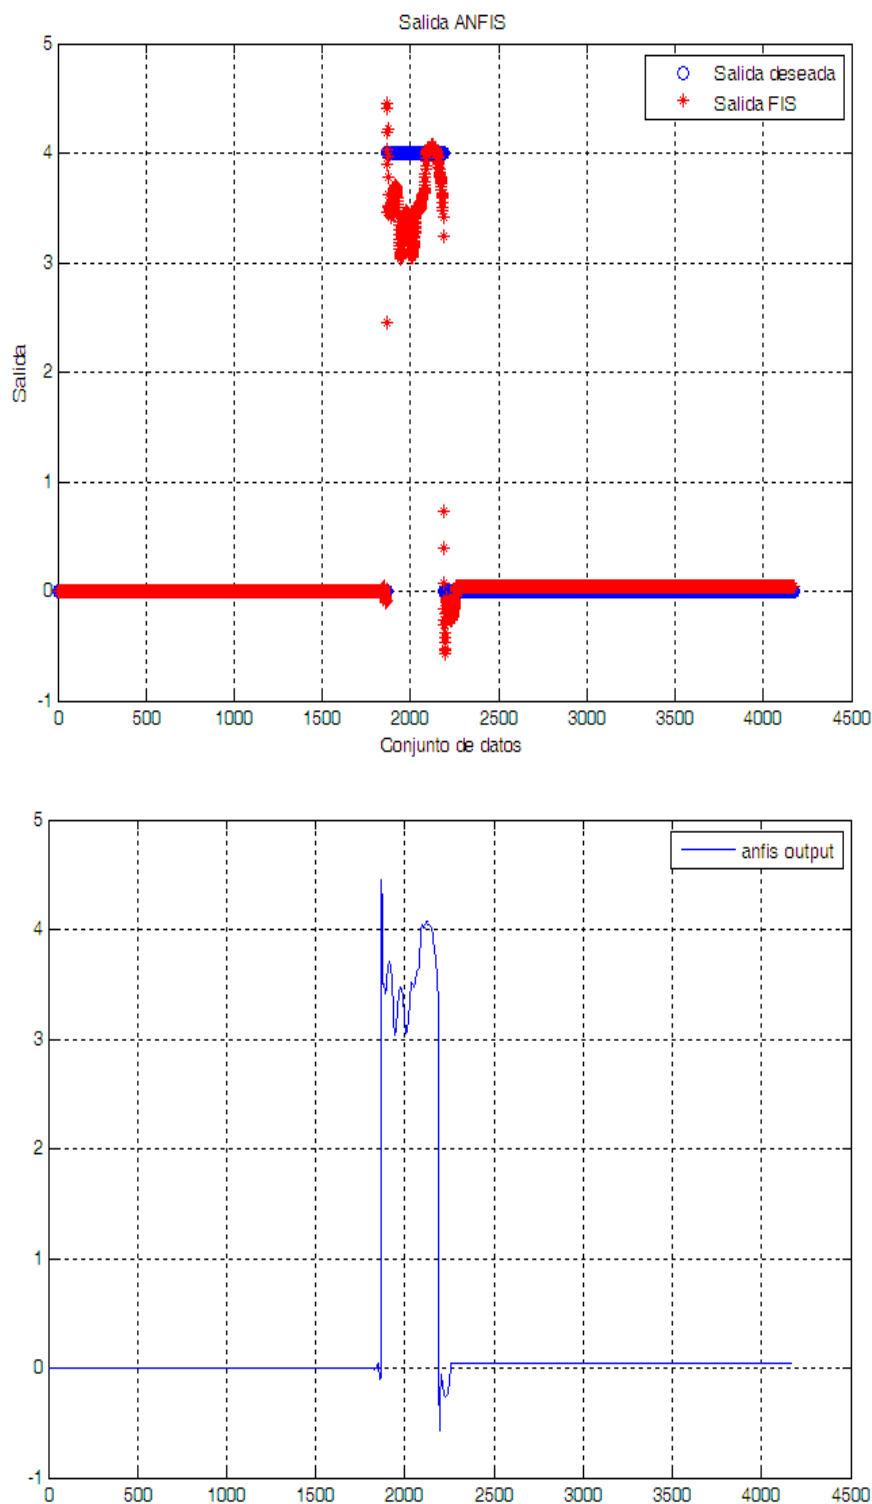


Figura 4.18 Resultados del ANFIS para una falla tipo AB-T. 1) *Gráfica superior*: Salida ANFIS Vs Salida deseada. 2) *Gráfica inferior*: Salida ANFIS

d) **Falla trifásica ABC en la L/T Pomasqui-Jamondino 230 kV CTOS. 3 y 4.**

Para el tipo de falla trifásico, la clasificación es un valor numérico de 10 según la metodología estudiada en el capítulo 3. La figura 4.19 evidencia que la salida del ANFIS cumple con el objetivo, con bastante aproximación.




Figura 4.19 Resultados del ANFIS Vs la salida deseada para una falla trifásica A-B-C

e) Falla en la fase BC sin tierra, en la L/T Molino-Zhoray CTO2 230 kV.

La clasificación para el tipo de falla BC-T es un valor numérico de 8 y los resultados del ANFIS se muestran en la figura 4.20.

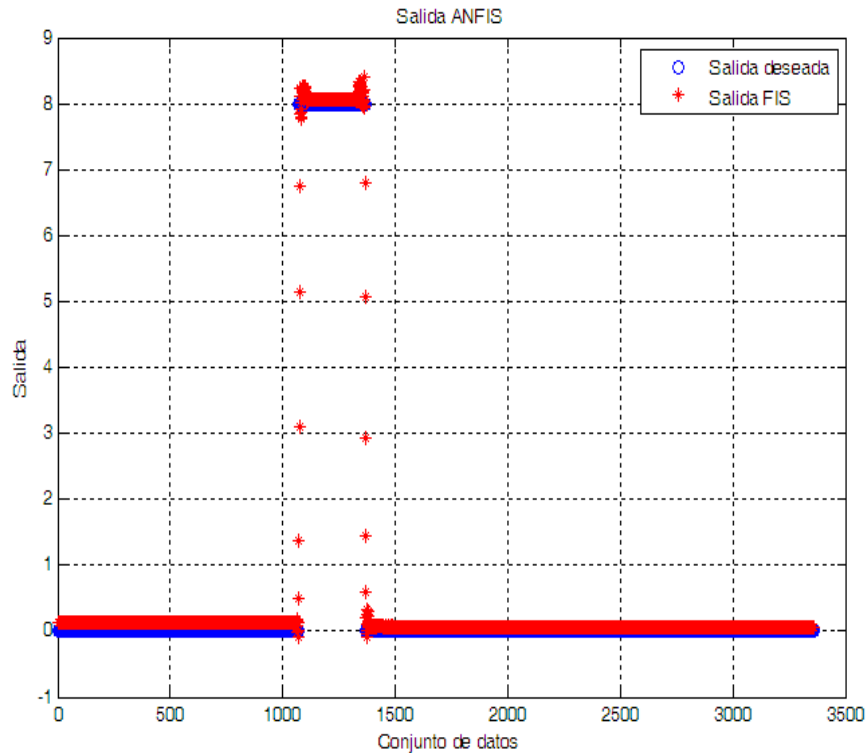


Figura 4.20 Resultados del ANFIS Vs. salida deseada para una falla tipo AB-T

Se observa que el modelo identifica y clasifica la falla satisfactoriamente, los errores presentan un mínimo, que realizando alguna depuración extra, satisfacen los requerimientos del problema.

Para los casos c, d y e se utilizó el método SC, como mejores resultados, con un $r_a=0.2$ para la obtención del FIS inicial, y la optimización se logra en aproximadamente 20 minutos con un número de 50 iteraciones.



CAPITULO 5. CONCLUSIONES Y TRABAJOS FUTUROS

5.1 CONCLUSIONES

La investigación realizada se enfocó en la detección y clasificación de fallas en los sistemas de transmisión, considerando los siguientes aspectos fundamentales: El procesamiento de los datos de entrada, la extracción de características del SEP para la obtención de patrones de entrenamiento y verificación, el desarrollo y selección del modelo ANFIS y su validación con registros de falla reales del SNT Ecuatoriano.

En el procesamiento de señales digitales, las técnicas de filtrado analizadas para su aplicación al procesamiento de registros de oscilografía son el filtro Butterworth de segundo orden y frecuencia de corte de 360 Hz para el filtrado analógico y el filtro de Fourier de un ciclo para el filtrado digital y la obtención de valores RMS de las corrientes como el más adecuado.

Es necesaria la normalización de la señal para trabajar en los modelos ANFIS analizados. El procesamiento con valores RMS combinado con la normalización de la señal produjo el mejor desempeño en cuanto al error de clasificación resultante en los algoritmos analizados.

Para el análisis de fallas en líneas de transmisión, se recomienda que los registros de fallas estén en una base de datos estructurada, para que el análisis sea realizado de una manera ágil y precisa.

La detección y clasificación de la falla se realiza mediante las corrientes de fase y la corriente de secuencia cero como entradas al modelo ANFIS, y su salida representa una estimación que identifica la falla y la clasifica según su tipo. Esta salida puede ser interpretada mediante cuatro ANFIS una por cada fase incluida la de secuencia cero, o un solo ANFIS al que se le ingresan las cuatro corrientes en conjunto.

Por su parte, los resultados del proceso de entrenamiento de la investigación muestran que la metodología propuesta para la exploración sistemática de las condiciones eléctricas es suficiente para lograr el objetivo planteado, sin embargo se podría ampliar la adquisición de los datos de entrenamiento, para obtener una estimación más eficaz.

Los resultados de la evaluación realizada, mostraron que el modelo ANFIS es adecuado para la clasificación de fallas en un SEP como el ecuatoriano, ya que se obtienen errores inferiores al 5%, que determinan una base, para seguir trabajando en la obtención de un modelo con menos niveles de error. Además satisface dos aspectos fundamentales a la hora de la decisión de una metodología para este tipo de análisis, que son la velocidad de procesamiento y la facilidad en la obtención de la estimación, por supuesto



sin incurrir en el empleo de grandes recursos, ya que su implementación no requiere equipos costosos.

Finalmente, las pruebas realizadas, con casos reales de fallas ocurridas en la red eléctrica ecuatoriana, validaron el desempeño del método ANFIS propuesto, detectando y clasificando la falla adecuadamente.

Así mismo, hay que hacer notar que los resultados mostraron que el modelo ANFIS utilizado presenta ciertos inconvenientes de adaptabilidad especialmente con fallas de alta impedancia, debido a que solamente utiliza una única variable de entrada para generar una correspondiente salida. Es decir, este modelo se desempeña muy bien si las corrientes (I_a , I_b , I_c , e I_o) presentan variaciones significativas entre ellas, sin embargo, cuando las corrientes tienden a parecerse entre sí el algoritmo no es capaz de identificar estas diferencias sutiles y tiende irremediablemente a clasificar erróneamente el tipo de falla.

Como conclusión el presente proyecto para la detección y clasificación de fallas mediante registros de oscilografías, se presenta como una herramienta que puede lograr una mejora en la oportunidad de identificación de las perturbaciones que afectan los activos asociados a la transmisión de energía eléctrica. La información obtenida de una herramienta de este tipo representa un valor agregado para los analistas expertos al momento de evaluar y analizar un evento de cualquier registro de falla convencional.

5.2 TRABAJOS FUTUROS

En el presente trabajo se ha analizado la solución para la identificación y localización de fallas mediante técnicas de inteligencia artificial (ANFIS), sin embargo como trabajos futuros se puede continuar con el estudio de la aplicación de otras técnicas de IA, que arrojen resultados más precisos que los descritos en esta investigación.

También se debe hacer extensivo a futuro un análisis del comportamiento del sistema de transmisión de energía eléctrica, con el objeto de identificar cuáles son las variables de interés a la hora de realizar una aproximación para la localización de la falla, y de seleccionar cuales de las técnicas de IA producen los mejores resultados en la solución de este problema.

Así mismo, es recomendable ampliar la investigación para analizar otras características de las fallas además de su localización, entre las que se destacan la causa de la falla, detección de los equipos en los que se presentó la falla y el diagnóstico de los dispositivos de protección y maniobra; para así continuar con otros tópicos del diagnóstico automático de fallas como son la identificación de la causa de la falla, la identificación del componente fallado y la localización de la falla.

La investigación, puede ser desarrollada para que sea implementada en los centros de control del sistema ecuatoriano, para que en base a registros



oscilográficos capturados por los Registradores de Fallas existentes, se obtenga una estimación para el diagnóstico de fallas, y de esta manera poder realizar las acciones respectivas para la reposición del servicio ante la ocurrencia de estos eventos.

En un trabajo futuro se puede considerar también como variables de entrada los voltajes de una condición de falla, con el objeto de realizar también la localización de falla, que será considerado como objeto de estudio futuro al alcance de este proyecto.



Bibliografía

- [1] Calderón Jhon Albeiro, “Modelo Adaptivo de Inteligencia Artificial para el Diagnóstico Automático de Fallas a partir de Registros de Osciloperturbografía”. Universidad Nacional de Colombia, Tesis de Maestría, Medellín, 2007.
- [2] Calderón Jhon, Zapata Germán, Demetrio Ovalle, “Algoritmo Neuro-Difuso para la Detección y Clasificación de Fallas en Líneas de Transmisión”. Revista Avances en Sistemas de Informática, Medellín, 2007.
- [3] Quintero Erwin, “Desarrollo de un Modelo para la Localización de Fallas en Sistemas de Transmisión de Energía Eléctrica utilizando Técnicas de Inteligencia Artificial”. Universidad Nacional de Colombia, Tesis de Maestría, Medellín, 2010.
- [4] Roger Jang Jyh-Shing, “ANFIS: Adaptive Network Based Fuzzy Inference System”. IEEE, University of California, 1993.
- [5] Zamora Ma. Inmaculada, Mazón Angel, “Simulación de Sistemas Electricos”. Paerson Educación S. A., Madrid, 2005.
- [6] Gomez Expósito Antonio. “Análisis y Operación de Sistemas de Energía Eléctrica”. McGraw-Hill, Madrid, 2002.
- [7] Erazo Páez Mauro, “Análisis de los Sistemas de Protecciones Eléctricos”. CENACE, Quito, 2000.
- [8] IEEE, “Tutorial on Fuzzy Logic Applications in Power Systems”. IEEE, Singapore, 2000.
- [9] Sória Emilio, Martín José, “Introducción a las Redes Neuronales”. Universidad de Valencia, Valencia, 2000.
- [10] Gilcrest, Rockfeller, Udren. “High Speed Distance Relaying Using a Digital Computer, Part I - System Description”. IEEE, 1972.
- [11] H. Khorashdi-Zadeh, “Artificial Neural Network Approach to Fault Classification For Double Circuit Transmission Lines”. IEEE/PES, 2004.
- [12] Mahanty R. N, Dutta P. B. “A fuzzy logic based fault classification approach using current samples only”. Electric Power System Research, 2007.
- [13] Ghani Rasli, Mohamed, Azah, Shareef Hussain, “ANFIS Approach for Locating Precise Fault Points with Coordinated Geometries in a Tes Distribution System”. Euro Journals of Scientific Research, 2009.



- [14] Kamel Tamer, Hassan Moustafa, "Adaptive Neuro Fuzzy Inference System (ANFIS) For Fault Classification in the Transmission Lines". OJEEE, Cairo University, 2008.
- [15] Wang Huisheng, Keerthipala W. L. "Fuzzy-Neuro Approach to Fault Classification for Transmission Line Protection". University of Singapore, IEEE, 1998.
- [16] Joorabian M. Monadi M. "ANFIS Based Fault Location for EHV Transmission Lines". Elsevier Journal, Iran, 2004.
- [17] Jayabharata M. Kumar Dusmanta, "A comparative Study of artificial Neural Network (ANN) and Fuzzy Inference System (FIS) Approach for Digital Relaying of Transmission Line Faults". Department of Electrical and Electronic Engineering, AIML Journal, India, 2006.
- [18] Dash P. K., Pradhan A. K., Panda G. "A Novel Fuzzy Neural Network Based Distance Relaying Scheme". IEEE, 2000.
- [19] Jain Anamika, Thoke A. S., Patel, R. N. "Fault Classification of Double Circuit Transmission Line Using Artificial Neural Network". International Journal of Electrical and Electronics Engineering, 2008.
- [20] Raval Pranav, "ANN based Classification and Location of Faults in EHV Transmission Line". Proceedings of the International MultiConference of Engineers and Computer Scientists, Hong Kong, 2008.
- [21] Gracia J., Mazon A. J., Zamora I. "Best ANN Structures for Fault Location in Single and Double Circuit Transmission Lines". IEEE, 2005.
- [22] Ballesteros David, "Clasificación y Procesamiento de los Registros de Perturbaciones de la Red de Transmisión de ISA". Universidad Tecnológica de Pereira, Tesis de Ingeniería, 2008.
- [23] Llano Luis, Zapata German y Ovalle Demetrio, "Sistema de Inferencia Difuso para Identificar Eventos de Falla en Tiempo Real del STE usando Registros SOE". Revista Avances en Sistemas e Informática, Medellín, 2007.
- [24] Torres Santiago, "Evaluación de la Estabilidad de Tensión usando Modelos Neuro Difusos". Universidad Nacional de San Juan, Tesis de Doctorado, Argentina 2007.
- [25] Orduña Eduardo, "Protección de Sistemas Eléctricos". Universidad Nacional de San Juan, 2009.



- [26] IEEE, "Standard Common Format for Transient Data Exchange (COMTRADE) for Power Systems". IEEE, New York, 1999.
- [27] The MathWorks Inc., "Signal Processing Toolbox". Tutorial The MathWorks Inc, 2006.
- [28] Perez Enrique, "Nuevo Método de Detección y Análisis en Tiempo Real de Eventos en la Tensión de Suministro de Energía Eléctrica Empleando un Modelo Combinado Wavelets-Filtro de Kalman Extendido". Universidad de Cantabria, Tesis de Doctorado, 2006.
- [29] Digsilent PF, "Manual Digsilent 14.0.520". Power Factory, 2010.
- [30] Fonseca Antonio, "Análisis del Sistema de Protecciones de las Líneas de Transmisión de 230 kV del SNT Ecuatoriano". Transelectric, Quito, 2009.
- [31] Martinez Juan A, "El paquete de simulacion ATP". Univesrsidad de Catalunya, España, 2000.
- [32] Martinez Juan A, "Catalogo de aplicaciones del ATP". Universidad de Catalunya, España, 2001.
- [33] The MathWorks Inc., "Tutorial Matlab-Fuzzy Logic Toolbox". The MathWorks Inc., 2009.
- [34] The MathWorks Inc., "Tutorial Matlab-Neural Network Toolbox". The MathWorks Inc., 2009.
- [35] Chaura Jose. Sistemas Neuro-Difusos. Tesis Doctoral UNMSM, 2009.
- [36] Roger Jang Jyh-Sing, Sun Chuen-Tsai, "Neuro-Fuzzy Modeling and Control". IEEE, Singapore, 1995



ANEXOS



A. REGISTRADORES DE FALLAS Y EVENTOS EN LÍNEAS DE TRANSMISIÓN ELÉCTRICAS

Para los centros de análisis encargados del estudio de las perturbaciones de la red, es de vital importancia llevar un registro que muestre segundo a segundo que está pasando en el sistema y archivar esta información para estudios posteriores, especialmente cuando ocurre una perturbación. Por lo tanto es un punto crítico para el sistema de protecciones y especialmente para los análisis post-operativos de fallas, que los equipos utilizados posean la capacidad suficiente para detectar el instante en que se presenta una falla y que los registradores de falla asociados, guarden las lecturas correspondientes a estas anomalías.

Un registrador de fallas no es un equipo de protección. Como su nombre lo indica los registradores están encargados de almacenar los datos de tensiones y corrientes una vez que se ha detectado una perturbación en el sistema, con el propósito de contar con esta herramienta para el análisis posterior a la falla, el cual debe apuntar a la identificación de la causa de la anomalía y las razones por las que ésta se presentó.

Existen diferentes tipos de posibilidades de estados que deben ser considerados al momento de analizar una falla y su correspondiente registro: Inicialmente los registradores se encuentran recibiendo y grabando las señales asociadas, existe un momento en el cual ocurre una falla y es en este instante donde los relés deben detectar esta situación y mandar una señal de disparo a los disyuntores. Posteriormente y en el tiempo de operación establecido se abre el interruptor para despejar la falla, a partir de ese momento se empieza a contabilizar un tiempo (generalmente del orden de los milisegundos) para realizar un recierre, es decir volver a cerrar el interruptor y comprobar si la falla fue aclarada. A este lapso de tiempo se le conoce como tiempo muerto; si la anomalía fue despejada se deja cerrado el interruptor definitivamente y se normaliza el sistema. Si la falla aun no ha sido despejada al momento de realizar el recierre, el interruptor es abierto nuevamente y se realiza una apertura definitiva pues la anomalía aun persiste en el sistema [22].

A.1 ANÁLISIS POST-OPERATIVO

La metodología para analizar perturbaciones consiste en dos estados operativos: primero la identificación rápida de la falla y la normalización del sistema afectado y segundo el análisis detallado del evento y los pormenores; una vez que se detecta la ocurrencia de una falla, es despejar la misma o bien aislarla del SEP. Sin embargo hacer este tipo de maniobras operativas conlleva un impacto directo sobre el sistema, pues se pueden presentar cambios incluso topológicos de la red en comparación con la que estaba antes de ocurrir la anomalía. En este orden de ideas, para determinar con exactitud las condiciones que llevaron al sistema a fallar en un momento determinado, las consecuencias transitorias y permanentes que afectaron la red, entre otros, se hace necesario un análisis más exhaustivo y detallado de



toda la información obtenida y registrada en el momento que se presentó la anomalía. De esta manera se puede determinar los verdaderos orígenes y los detalles de la perturbación: qué tipo de falla fue, que la ocasionó y que efectos dejó sobre el sistema.

Para llevar a cabo este tipo de estudios, los analistas expertos cuentan con diferentes herramientas que monitorean la red en tiempo real tales como el SOE, el SCADA, los DFR. Alternativamente a estas herramientas existen otras tales como relés de protección que también registran datos análogos y digitales, existe también la red de localización de descargas eléctricas, el sistema general de alarmas y anunciadores de las subestaciones, localizadores de fallas disponibles en las líneas de transmisión, entre otras.

SOE (*Sequence Of Events*): es un sistema integrado de información que reporta con precisión de milisegundos los cambios de estado en los contactos de señalización de los elementos seleccionados previamente y que forman parte del sistema eléctrico de potencia.

SCADA (*Supervisory Control And Data Acquisition*): es una tecnología que permite obtener y procesar información de procesos industriales dispersos o lugares remotos inaccesibles, transmitiéndola a un lugar para supervisión, control y procesamiento.

DFR (*Digital Fault Records*): Registradores de falla digitales, son equipos que están diseñados para registrar y almacenar datos de los valores de tensión y corriente conectados a sus terminales, a una frecuencia determinada y dentro de sus rangos de operación.

El lenguaje de comunicación utilizado por éstos equipos, son los registros COMTRADE (*Standard Common Format for Transient Data Exchange for Power Systems*), que es una herramienta utilizada para realizar los respectivos análisis, procesos y tratamientos que permitan una mejora en la oportunidad del diagnóstico e identificación de fallas en líneas de transmisión.

De la integración y comparación de las diversas fuentes de información extraídas de las diferentes herramientas mencionadas, es posible plantear varias hipótesis que permitan diagnosticar el origen de la perturbación, de las cuales se debe unificar una sola teoría que de explicación a las condiciones presentadas en el sistema de potencia al momento de la falla [22].

A.2 IMPORTANCIA DE LOS REGISTRADORES DE FALLA

El estudio post-operativo del SEP, es una tarea en la cual una empresa de transmisión enfoca grandes esfuerzos reuniendo a los mejores analistas expertos de operación en todo lo que concierne a eventos y solución de anomalías. Los estudios y resultados obtenidos mediante este proceso constituyen el pilar fundamental para lograr un restablecimiento oportuno del servicio. Para alcanzar este propósito es necesario realizar exhaustivos análisis cuantitativos y cualitativos de la red, antes y después de la falla y así



poder encontrar las razones que ocasionaron la perturbación para posteriormente obtener una solución concreta y eficaz que lleve a restablecer la operación normal del sistema en el menor tiempo posible en todas las zonas que se vieron afectados al ocurrir la perturbación.

En el proceso de diagnóstico e identificación de fallas y solución de problemas existen diversas herramientas, que apoyan a los analistas para que las hipótesis planteadas sean lo más acertadas posible. Una de estas herramientas la constituyen los registradores digitales de falla o DFR (por sus siglas en inglés *Digital Fault Record*) que a pesar de su nombre, permite obtener un registro de las señales análogas de tensión y corriente asociadas a eventos, además de las señales digitales establecidas para el registrador, y que corresponden al momento o los momentos de la perturbación.

Los registradores de falla digitales son equipos que están diseñados para registrar y almacenar datos a una frecuencia determinada, de los valores de tensión y corriente conectados a sus terminales y dentro de sus rangos de operación. Con frecuencias de muestreo de más de un 1kHz, estos equipos hacen posible la reproducción de los parámetros de tensión y corriente de las unidades del SEP durante fallas que los afecten, pudiéndose determinar características como su forma de onda y valores instantáneos.

Los canales análogos son los que registran y almacenan los datos de corriente y tensión, mientras que los canales digitales son los que sirven para el monitoreo de los contactos de señalización de equipos de protección, control o interrupción.

En el momento en que se presenta una condición anormal de la red, que algunas veces puede ser por una falla, el registrador recibe la orden de comenzar a construir un registro. La activación de esta orden se da de acuerdo a los parámetros y umbrales bajo los cuales este configurado el equipo cuando las señales presenta algún tipo de modificación. Así, el rango de tiempo que dura el registro, corresponde al instante donde se presenta la condición anormal y dura hasta que ésta desaparece del sistema. Sin embargo, en los registradores fallas puestos a disposición de los expertos, es muy importante conocer como se estaba comportando el sistema antes de que se presentara la condición anormal, es decir, es necesario un estado de pre-anomalía o un estado estacionario antes de la perturbación. Para reconstruir este lapso de tiempo previo a la orden de inicio del registrador y empalmarlo con las lecturas ya registradas, los DFR hacen uso de un buffer de memoria que poseen, el cual va guardando en periodos cortos de tiempo las señales censadas; dentro de esta ventana de tiempo, el DFR va remplazando siempre las últimas lecturas con las nuevas para de esta manera optimizar el uso de la memoria propia del equipo. Por lo general estos buffer pueden proveer lecturas de 100 a 200 milisegundos aproximadamente [22].



A.3 FORMATO COMTRADE

El COMTRADE es un formato estandarizado que utilizan los registradores de falla para almacenar los datos leídos y generar archivos planos que puedan ser fácilmente reconocidos por varios software. Actualmente existen dos tipos de formato COMTRADE, el primero fue normalizado en el año 1991 y el segundo en el año de 1999 y los campos que son requeridos para la implementación de los algoritmos del diagnóstico de fallas, son comunes a los dos tipos de COMTRADE.

Debido a que el COMTRADE es utilizado por los analistas para los diferentes estudios y análisis del sistema, aprender la forma como está estructurado este formato de la IEEE, resulta ser un punto clave del proyecto, pues es gracias a los archivos planos generados por éste (archivos tipo .cfg y .dat) que es posible procesar los registros en un software diferente como es el Matlab, que resulta ser muy diferente a los establecidos comúnmente para el análisis de perturbaciones.

El formato COMTRADE crea principalmente dos tipos de archivos planos que son necesarios para la reconstrucción de los datos registrados, estos son los archivos cuya extensión es .cfg y archivos con extensión .dat [22], [26], [27].

Archivos de configuración (.CFG)

Información adicional que permite una clara identificación del registro y lo que hay en él. Entre la información más relevante que posee este tipo de archivos se encuentra:

1. Subestación de origen del registro
2. Número total de canales que posee el registro
3. Número de canales análogos
4. Número de canales digitales
5. Etiqueta con el nombre asignado al canal del registrador, de esta etiqueta se obtiene la nomenclatura de la bahía de línea hacia dónde va el registro: MOL/PAS1
6. Unidad de medida asociada a este canal: V, A
7. Factor de conversión **a** producto de la conversión A/D
8. Factor de conversión **b** producto de la conversión A/D
9. Frecuencia de la señal
10. Frecuencia de muestreo
11. Número de la última muestra registrada

Archivos de Datos (.DAT)

Los .dat igualmente son archivos de texto planos que contienen la información o los datos correspondientes a la conversión análoga/digital y que se simbolizan como valores numéricos que son representaciones a escala del evento almacenado por el registrador de fallas en los canales asignados y descritos en el archivo de configuración. Es decir que la información almacenada en un .dat es una representación de las magnitudes y datos



asociados al evento registrado por el DFR, de donde se puede obtener los valores reales mediante la interacción con el archivo de configuración.

La información asociada a estos archivos es la base para lograr una posterior reconstrucción de las señales almacenadas en el registro mediante cualquier software que permita leer y correlacionar este tipo de archivos. Así, los archivos .cfg necesitan de los .dat y viceversa para obtener la información contenida tanto en los canales análogos como en los digitales. Como se mencionó, en la reconstrucción de las señales del registrador son utilizados los parámetros a y b resultado de la conversión análoga/digital que se encuentran en el .cfg. Los programas de análisis de registros de perturbaciones que permiten llevar a cabo el proceso de recuperación de señales análogas, se basan fundamentalmente en el siguiente parámetro:

Valor instantáneo = $a \cdot X_i + b$

Donde X_i corresponde a cada valor asignado dentro del archivo .dat para cada muestra de los diferentes canales. De esta manera se crea un conjunto de puntos que puestos en un plano de tiempo contra la magnitud de la señal leída, constituyen la imagen y los valores reales correspondientes a toda la información registrada inicialmente por el DFR.

En el final de cada archivo .cfg debe quedar estipulado el tipo de lenguaje en el que está cifrada la información, bien sea en forma binaria o en código ASCII.

La información del .dat se divide en filas y columnas. El número de filas varía de acuerdo a la duración del registro, es decir al número de muestras que se haya tomado. Cada fila debe estar dividida en $N+2$ columnas, donde N es el número total de canales, los análogos sumados a los digitales.

La distribución de las columnas especifica:

- El número de muestra registrado.
- El tiempo del registro al que corresponde la muestra, donde la primera muestra se considera como el tiempo $t=0$. Este tiempo está medido en microsegundos (μs). Cabe destacar que las variaciones de tiempo entre muestra y muestra corresponden al periodo de muestreo, es decir el inverso de la frecuencia de muestreo.
- Los valores X_i mencionados anteriormente para los canales análogos, es decir representan los valores a escala de las señales análogas muestreadas. Cada columna representa un canal diferente; los canales siguen el orden que traen las señales desde el archivo de configuración (.cfg), es decir si está primero las tres tensiones y luego las tres corrientes de una bahía, en el .dat las tres primeras columnas corresponden a las tensiones y las tres siguientes a las corrientes.
- Los valores (unos y ceros) asociados los canales digitales.



Los datos de un canal están separados de los del canal siguiente por medio de una coma (,) indicando que el valor muestreado para el canal termina allí. Este tipo de estructura se llama “formato de delimitación por coma”.

Los últimos valores de los canales digitales no poseen comas, indicando que ese es el fin de la muestra correspondiente. Si por alguna razón el número de canales es muy grande y no se puede transcribir en una sola línea, se observará que el último dato de la fila también posee una coma, indicando que los valores correspondientes a esa muestra continúan en la fila siguiente con los canales restantes.

Todos los valores del .dat son números enteros. Esto implica que, aunque mínima existe una pérdida de información cuando se crea el archivo COMTRADE. Sin embargo, para los cálculos y los análisis realizados por los analistas expertos, la pérdida de información no resulta significativa, pues las formas de onda y los valores obtenidos a través de los registros oscilográficos de los DFR son lo suficientemente válidos y aproximados al comportamiento real del sistema.



B. PROCESAMIENTO DE SEÑALES

A continuación, se expone los filtros analógicos y digitales, para el procesamiento de la señal digital obtenida de [1] con el sustento de [28].

Filtro Butterworth:

El filtro analógico se considera un dispositivo selectivo a la frecuencia que permite dar forma a la respuesta en magnitud o en fase. El diseño de éstos se basa principalmente en la aproximación de las especificaciones de magnitud o de fase mediante polinomios o funciones racionales, por lo general, en especificaciones de frecuencia (aristas de las bandas de paso y supresión) y en especificaciones de magnitud (atenuación máxima en la banda de paso y atenuación mínima en la banda de supresión) para generar la función de transferencia de fase mínima del filtro con el orden más pequeño que cumpla las especificaciones. Las especificaciones de magnitud de un filtro por lo general son dadas por la atenuación en la banda de paso y la atenuación en la banda de supresión o rechazo, expresadas en decibeles.

Los filtros clásicos aproximan el cuadrado de la función de magnitud $|H(v)|^2$ de un prototipo pasa-bajas por un polinomio o razón de polinomios en v^2 ; se obtiene una función de transferencia de fase mínima a partir de esta aproximación [xx]. El cuadrado de la función de magnitud y la atenuación de un prototipo pasa-bajas de n-ésimo orden tienen la forma:

$$|H(v)|^2 = \frac{1}{1 + \alpha^2 L_n^2(v)} \quad ; \quad A_{dB}(v) = 10 \log[1 + \alpha^2 L_n^2(v)] \quad (dB) \quad (B.1)$$

En estas expresiones, $L_n(v)$ es un polinomio o función racional de n-ésimo grado, y α controla el rizo en la banda de paso. La diferencia entre los distintos tipos de filtros clásicos se encuentra principalmente en la selección de $L_n^2(v)$, la cual se hace con la finalidad de satisfacer las especificaciones deseadas. Se necesita que $L_n^2(v) \approx 0$ en la banda de paso (para asegurar en ella una ganancia casi unitaria) y que $L_n^2(v) \gg 0$ en la banda de supresión (para asegurar que la ganancia en ella sea casi cero). La única ecuación de diseño que se necesita es la de atenuación. El orden del filtro n y el parámetro α se obtienen evaluando la relación de atenuación en los límites de la banda de paso y de supresión. Con esto se establece la forma exacta de $|H(v)|^2$, a partir de la cuál es fácil obtener la función de transferencia $H_p(s)$ del prototipo.

El Filtro Butterworth es fundamentalmente plano debido a que la elección de $L_n(v) = v^n$ obliga a que todas sus derivadas sean cero en $v=0$, lo que garantiza no sólo la respuesta más plana en $v=0$ sino también la menor desviación con respecto a la ganancia unitaria en la banda de paso. Con esto se obtiene una respuesta en frecuencia monótona libre de sobretiros, pero a costa de una transición lenta de la banda de paso a la de supresión.

Algoritmo de Fourier:



La obtención de los coeficientes del filtro se basa en el análisis en frecuencia de la señal $x[n]$ correspondiente a la señal muestreada de voltaje y corriente. Esta señal $x[n]$ se puede reconstruir por medio de su correspondiente Transformada Discreta de Fourier Inversa (IDFT):

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j2\pi kn/N} \quad , \quad n = 0, 1, \dots, N - 1 \quad (\text{B.2})$$

En la cual los valores de $X(k)$ estarán dados por la transformada discreta de Fourier (DFT):

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi kn/N} \quad , \quad n = 0, 1, \dots, N - 1 \quad (\text{B.3})$$

Mediante una expansión de la ecuación (4.2), agrupando términos y teniendo en cuenta que las señales muestreadas son reales se llega a la siguiente ecuación:

$$x(n) = \frac{1}{N} \left[X(0) + 2X(1) \cos\left(\frac{2\pi}{N} + \delta_1\right) + 2X(2) \cos\left(\frac{2\pi 2n}{N} + \delta_2\right) + \dots \right] ; \quad (\text{B.4})$$
$$n = 0, 1, \dots, N - 1$$

Donde $\delta_1, \delta_2, \dots$ son los ángulos de $X(1), X(2), \dots$. Respectivamente.

El término que reconstruye la componente de frecuencia fundamental de la señal $x[n]$, con una ventana de un ciclo y un número de muestras por ciclo dado por N_c , es:

$$X_0(n) = \frac{2X(1)}{N_c} \cos\left(\frac{2\pi F_0 n}{F_s} + \delta_1\right) \quad , \quad n = 0, 1, \dots, N_c - 1 \quad (\text{B.5})$$

Como el objetivo es obtener el fasor (magnitud y ángulo) de la componente fundamental presente en la señal $x[n]$, las ecuaciones que dan las componentes del fasor y de las cuales se pueden extraer los coeficientes del filtro son:

$$X_{0r} = \frac{2}{N_c} \sum_{n=0}^{N_c-1} x(n) \cos\left(\frac{2\pi n}{N_c}\right)$$



$$X_{oi} = \frac{2}{N_c} \sum_{n=0}^{N_c-1} x(n) \sin\left(\frac{2\pi n}{N_c}\right)$$

(B.6)

X_{or} Representa el valor pico de la componente real del fasor de frecuencia fundamental de la señal $x(n)$.

X_{oi} Representa el valor pico de la componente imaginaria del fasor de frecuencia fundamental de la señal $x(n)$.

La representación en forma polar del fasor correspondiente es:

$$|x_0| = \sqrt{(x_{or})^2 + (x_{oi})^2}$$

$$\varphi_0 = \tan^{-1}\left(\frac{x_{oi}}{x_{or}}\right)$$

(B.7)



C. PARÁMETROS DEL SISTEMA DE PRUEBA

A continuación se presentan las características y parámetros del sistema eléctrico de las L/T Zhoray-Molino 230 kV.

Generadores:

Los parámetros que se utilizaron para los generadores ubicados a los extremos de la línea, se obtienen mediante una simulación de cortocircuito en barras de 230 kV de las subestaciones Zhoray y Milagro, con el objeto de obtener las impedancias equivalentes de los mismos. Se utiliza el programa Power Factory – Digsilent [29], con las siguientes imposiciones:

- Calculo con alta hidrología y demanda máxima, es decir con máxima generación hidráulica en la zona Zhoray. (Central Paute con 10 unidades, 1100 MW), y máxima carga en el sistema.
- Los dos circuitos se encuentran en servicio.
- Voltaje Base 230 kV, Potencia Base 100 MVA, Impedancia Base 529 Ohms.

Los resultados obtenidos se muestran a continuación:

Tabla C.1 Datos Equivalentes de la S/E Zhoray

IMPEDANCIAS DE SECUANCIA	MAXIMA				CORRIENTES DE CORTOCIRCUITO			
	Ohmios		pu		Trifásica		Monofásica	
	R	X	R	X	(kA)	MVA	(kA)	MVA
Z0	0.91	9.320	0.002	0.018	14.38	5478.87	14.52	1844.17
Z1	0.61	9.7	0.001	0.018				
Z2	0.57	9.77	0.001	0.018				

Tabla C.2 Datos Equivalentes de la S/E Milagro

IMPEDANCIAS DE SECUANCIA	MAXIMA				CORRIENTES DE CORTOCIRCUITO			
	Ohmios		pu		Trifásica		Monofásica	
	R	X	R	X	(kA)	MVA	(kA)	MVA
Z0	1.13	12.25	0.002	0.023	12.050	4590.72	11.73	1489.37
Z1	0.98	11.56	0.002	0.022				
Z2	1.01	11.8	0.002	0.022				

Tabla C.3 Parámetros de los Generadores equivalentes

GENERADOR	ZHORAY	MILAGRO	Unidad
DESIGNACION	E1	E2	Texto
Voltaje Pico	187794.21	187794.21	V
Frecuencia	60	60	Hz
Angulo	0	10	°
IMPEDANCIA	R	X	Unidad
DESIGNACION	Z1		Texto
Z0	0.91	9.32	Ohms
Z1	0.61	9.7	Ohms
Ictocto (1Ø)	14.52		KA
Ictocto (3Ø)	14.38		KA
P (Por circuito)	126.89		MW
Q (Por circuito)	14.26		MVAR
I (Por circuito)	310		A

Estructuras y conductores de L/T's modeladas:

En la figura C.1 se indican las estructuras de suspensión típicas utilizadas en la red de 230 kV del SNT ecuatoriano, con sus respectivas distancias entre conductores expresadas en metros.




Figura C.1 Estructuras Típicas de la red de 230 kV del SNT Ecuatoriano

La primera estructura denominada “SL1-ZONA 1” corresponde a una típica estructura de suspensión utilizada hasta los 1000 msnm, altura que



generalmente corresponde a la zona costera ecuatoriana. La segunda estructura "SL2-ZONA 2" corresponde a una típica estructura de suspensión utilizada sobre los 1000 msnm, altura que generalmente corresponde a la sierra ecuatoriana. Se puede observar que en la estructura "SL2-ZONA 2", se utilizan dos conductores de guarda como consecuencia de que en la sierra ecuatoriana se tiene un nivel isocerámico mayor que el de la costa [30].

En las figuras anteriores se indica la disposición física de los conductores de fase en cada uno de los circuitos en la estructura paralela. Las máximas flechas consideradas corresponden a 18 metros para conductores de fase y 4.5 metros para el cable de guarda. El análisis considera líneas sin transposición.

Con relación a los conductores para las fases y para la guarda, el detalle de los parámetros utilizados correspondiente a conductores y geometría, se obtienen de tablas de las líneas del SNT correspondientes a la L/T Zhoray-Milagro 230 kV doble circuito.

Para la simulación se obtienen los datos que se indican en la tabla siguiente.

Tabla C.4 Parámetros de los conductores

Conductor	1113 ASCR (a)	Conductor de guarda (b)	Unidad
Material	Aluminio-Acero	Acero	Texto
Tipo	Bluejay	HS7	Texto
Resistencia DC	0.051	4.2324	Ohms/km
Diámetro Externo	31.98	9.15	Mm
Radio Equivalente RMG	12.6492	4	Mm
Capacidad nominal	1.081		kA
Flecha	18	4.5	M
No. Conductores por fase	1	1	Numérico

(a) Corresponde al conductor 1113 ASCR Bluejay

(b) Conductor de acero de grado H.S de 7 hilos

(c) Capacidad de corriente determinada a: Temperatura del conductor 75°,
Temperatura ambiente 25°

Los parámetros de la línea de transmisión Zhoray-Milagro son:



Tabla C.5 Parámetros de la Línea Zhoray-Milagro 230 kV

Parámetro	Valor	Unidad
Voltaje	230	kV
Frecuencia	60	Hz
Resistividad del Terreno (Rho)	100	Ohm*m
No. Circuitos	2	Texto
No. Hilos Guarda	2	Texto
Limite Operativo	860	A
Limite por Emergencia	1110	A
Longitud	121.07	Km
Modelo	PI	Texto
Estructura	SL2 Z2	Texto
R1 + jX1	6.968 + j56.128	Ohms
B1	432.97	microOhms
Ro + jXo	34.071 + j185.89	Ohms
Bo	268.53	microOhms

(a) SL2-ZONA 2" corresponde a una típica estructura de suspensión utilizada sobre los 1000 msnm

Las impedancias de la línea de transmisión se obtienen, mediante simulación en ATP [31] [32] y su rutina LINE CONSTANS para la modelización de una línea aérea de transporte. Se trata de obtener el modelo de la línea a partir de sus datos de diseño y según la geometría de la estructura. Para una configuración de la torre tipo SL" Zona 2, se tienen los siguientes resultados:

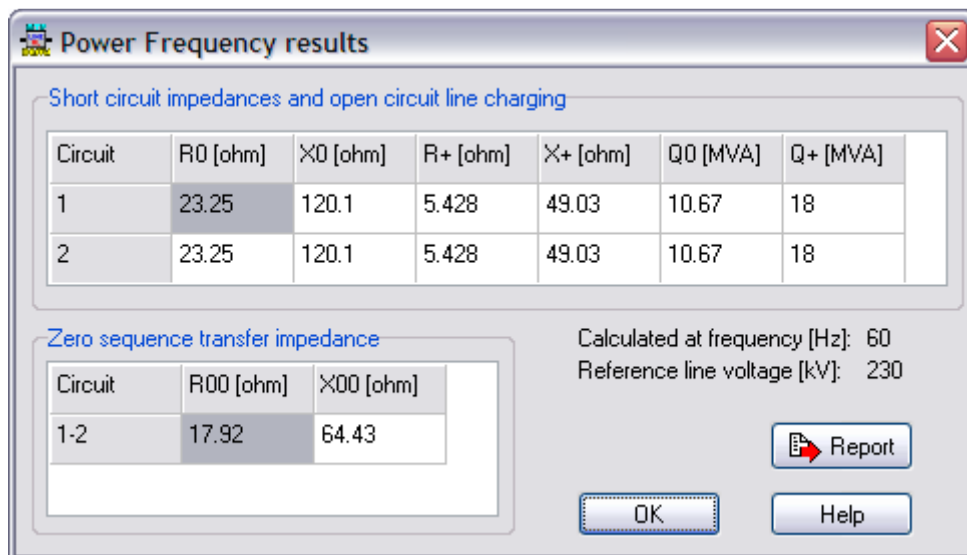


Figura C.2 Resultados para una L/T de 100 Km.



D. SISTEMAS NEURODIFUSOS

Los sistemas neuro-difusos forman parte de una nueva tecnología de computación llamada computación flexible (soft-computing), la cual tiene su origen en la teoría de la Inteligencia Artificial. La computación flexible engloba un conjunto de técnicas que tienen en común la robustez en el manejo de la información imprecisa e incierta que existe en los problemas relacionados con el mundo real (por ejemplo: reconocimiento de formas, clasificación, toma de decisiones, etc.). En algunos casos, las técnicas de computación flexible pueden ser combinadas para aprovechar sus ventajas individuales; algunas de estas técnicas son:

- Las Redes Neuronales.
- Los Algoritmos Evolutivos o Algoritmos Genéticos.
- La Teoría del Caos.
- La Teoría del Aprendizaje.
- El Razonamiento Aproximado.

En los siguientes apartados obtenidos de las referencias [33], [34], [35], [36] explican brevemente las técnicas de Redes Neuronales, Lógica Difusa y la combinación de ambas.

D.1 REDES NEURONALES

Las Redes Neuronales Artificiales (RNAs) son la implementación en hardware y/o software de modelos matemáticos idealizados de las neuronas biológicas. Las neuronas artificiales son interconectadas unas a otras y son distribuidas en capas de tal forma que emulan en forma simple la estructura neuronal de un cerebro. Cada modelo de neurona es capaz de realizar algún tipo de procesamiento a partir de estímulos de entrada y ofrecer una respuesta, por lo que las RNA en conjunto funcionan como redes de computación paralelas y distribuidas similares a los sistemas cerebrales biológicos. Sin embargo, a diferencia de las computadoras convencionales, las cuales son programadas para realizar tareas específicas, las redes neuronales artificiales, tal como los sistemas cerebrales biológicos, deben ser entrenadas.

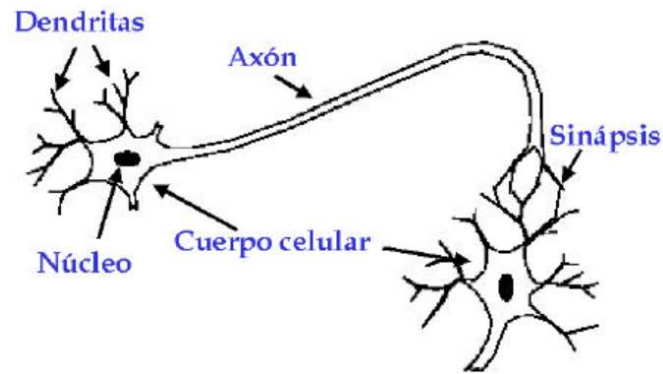


Figura D.1 Neurona Biológica

Componentes de una Red Neuronal

Aunque existen diferentes tipos de Redes Neuronales Artificiales todos ellos tienen casi los mismos componentes elementales. Como en el sistema nervioso biológico, una red neuronal artificial está constituida por neuronas que están unidas entre sí a través de conexiones, a las cuales se les asignan valores numéricos o pesos que representan el conocimiento de la Red Neuronal. Al cambiar los valores de los pesos se consigue imitar el cambio en la estructura de las conexiones sinápticas que ocurre durante el proceso de aprendizaje en la red neuronal biológica.

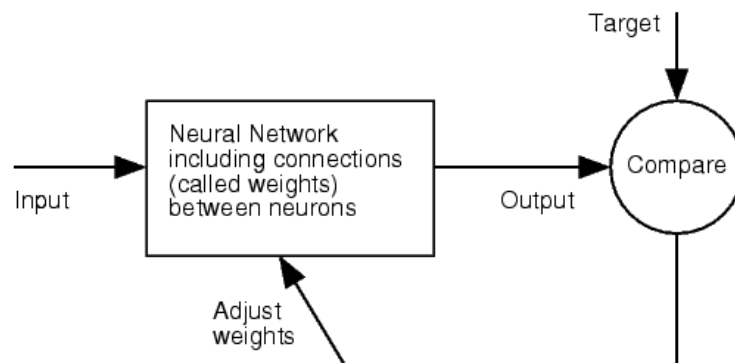


Figura D.2 Red Neuronal Artificial

La información que conforma un conjunto de entradas $X_j(t)$ es enviada a la neurona a través de sus conexiones con pesos sinápticos W_{ij} , donde el subíndice (i) representa a la neurona (i). Esta entrada es procesada por una función de propagación por ejemplo: $h_i(t) = (W_{ij} \cdot X_j)$ El resultado es comparado con un valor umbral θ por la función de activación $y_i(t) = f_i(h_i(t))$ que representa simultáneamente la salida de la neurona y su estado de activación. Sólo si la entrada excede el valor umbral, la neurona se activará, en caso contrario se inhibirá.

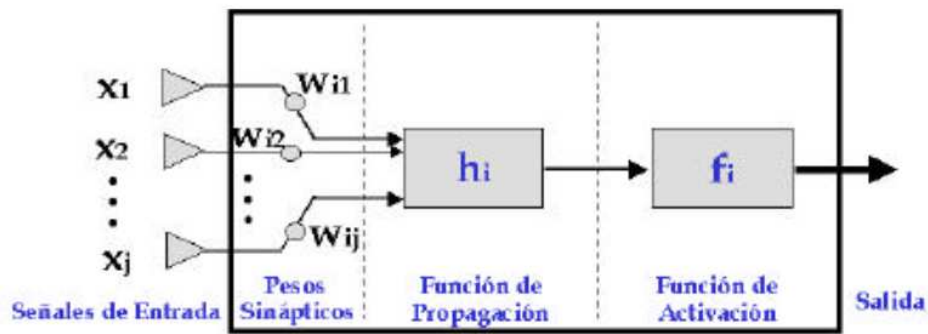


Figura D.3 Componentes de una Neurona Artificial

En una RNA las neuronas suelen estar agrupadas en capas. Se conoce como capa o nivel a un conjunto de neuronas cuyas entradas provienen de la misma fuente, y cuyas salidas tienen el mismo destino. Usualmente cada neurona de una capa está conectada a todas las neuronas de las capas anterior y posterior (excepto en la capa de entrada y en la capa de salida). Las Redes Neuronales permiten resolver problemas que no pueden ser solucionados usando algoritmos convencionales. Tales son usualmente problemas de clasificación u optimización. Los diferentes dominios en los que las redes neuronales son utilizadas, incluyen:

- Asociación de patrones.
- Clasificación de patrones.
- Procesamiento de imágenes
- Reconocimiento de voz
- Problemas de optimización.
- Simulación.

Tipos de Redes Neuronales

Existen diferentes tipos de redes neuronales y cada uno tiene características especiales, por lo que cada tipo de problema tiene su propio tipo de red neuronal para solucionarlo. Las redes neuronales pueden ser clasificadas según el tipo de aprendizaje, el tipo de aplicación y la arquitectura de la conexión. La siguiente tabla, presenta ésta clasificación.



Tabla D.1 Tipos de Redes Neuronales

Clasificación por el tipo de Aprendizaje	<ul style="list-style-type: none">- Redes Neuronales con Aprendizaje Supervisado.- Redes Neuronales con Aprendizaje no Supervisado.- Redes Neuronales con Aprendizaje Híbrido.- Redes Neuronales con Aprendizaje Reforzado.- Redes Neuronales con Aprendizaje Competitivo
Clasificación por el tipo de aplicación	<ul style="list-style-type: none">- Redes Neuronales Aproximadoras de Funciones.- Redes Neuronales Asociativas o Memorias Asociativas.- Redes Neuronales Clasificadoras.
Clasificación por la arquitectura de la conexión	<ul style="list-style-type: none">- Redes Neuronales Monocapa.- Redes Neuronales Multicapa.- Redes Neuronales Realimentadas.

Arquitectura de Redes Neuronales Artificiales

Diferentes tipos de interconexión implican diferentes comportamientos de la red. Por ejemplo, las redes que tienen flujo de datos unidireccional (feedforward) son estáticas, es decir, producen sólo un grupo de valores de salida en lugar de una secuencia de valores de salida para una entrada dada, además sus salidas no dependen de los valores anteriores de la red. Por otro lado las redes neuronales recurrentes o realimentadas son sistemas dinámicos. Según la arquitectura de la conexión las redes neuronales se pueden clasificar, entre otras, como: Red Neuronal Monocapa, Red Neuronal Multicapa y Red Neuronal Realimentada.

Red Neuronal Monocapa: Las redes monocapa están formadas sólo por una capa de neuronas, y suelen utilizarse frecuentemente en tareas relacionadas con la regeneración de información incompleta o distorsionada que se presenta a la red.

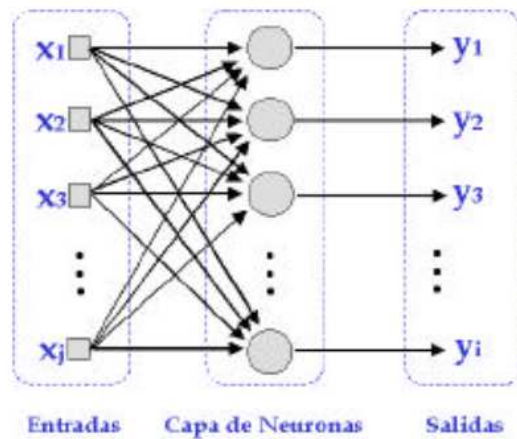


Figura D.4 Red Neuronal Monocapa

Red Neuronal Multicapa: Son las estructuras más comunes; además de la capas de entrada y salida, poseen un número de capas intermedias u ocultas que mejoran su desempeño.




Figura D.5 Red Neuronal Multicapa

Red Neuronal Realimentada: Se caracteriza porque sus salidas pueden ser utilizadas como entradas. La estabilidad de la red es un importante factor a considerar en este tipo de arquitectura.




Figura D.6 Red Neuronal Realimentada

El Proceso de Aprendizaje

Como ya se mencionó, biológicamente se suele aceptar que la información memorizada en el cerebro está más relacionada con los valores sinápticos de las conexiones entre las neuronas que con las neuronas mismas, es decir, el conocimiento se encuentra en las sinapsis y todo proceso de aprendizaje consiste en la creación, modificación y destrucción de estas conexiones entre las neuronas. De forma similar el aprendizaje en las RNA consiste en determinar un conjunto de pesos sinápticos que permita a la red realizar correctamente el tipo de procesamiento deseado, esto se logra a través del entrenamiento de la red. Una vez que la red neuronal ha sido correctamente entrenada será capaz de determinar la salida deseada para las entradas que se le presenten.

Tipos de Aprendizaje

Los tipos de aprendizaje son los métodos utilizados para entrenar las RNAs, algunos de ellos son: el aprendizaje supervisado y el aprendizaje competitivo.

Aprendizaje Supervisado: En este caso un agente supervisor externo presenta a la red un conjunto de patrones característicos de entrada junto con la salida que se desea obtener e iterativamente la red ajusta sus pesos hasta que su salida tiende a ser la deseada; para realizar esta tarea la red utiliza información acerca del error que comete en cada paso de entrenamiento.

Aprendizaje Competitivo: En el aprendizaje competitivo las neuronas de salida compiten entre ellas para alcanzar el estado de activación. Como resultado sólo una unidad de salida estará activa en algún momento dado. Este procedimiento es conocido como WTA (Winner-Take-all).



Algoritmos de Aprendizaje

El tipo de algoritmo de aprendizaje depende esencialmente del tipo de aplicación de la red, así como de su topología. A continuación se describen los algoritmos de Corrección de Error y de Retro-propagación del Error.

Algoritmo de Corrección de Error

En el aprendizaje supervisado, se le da a la red una asociación de salidas-entradas. Durante el proceso de aprendizaje, la salida 'y' generada por la red puede no ser igual a la salida deseada 'd'. El aprendizaje por corrección de error consiste pues, en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores obtenidos de la red y los valores deseados, es decir, en función del error obtenido en la salida. Un algoritmo simple de aprendizaje por corrección de error podría ser el siguiente.

$$W_{ij} = W_{ij} + \alpha \cdot x_j (d_i - y_i)$$

(D.1)

Donde d_i es la salida deseada, y_i es la salida real de la neurona 'i' obtenida una iteración antes, x_j es una entrada j-ésima a la neurona 'i' y α es la tasa de aprendizaje de la red o constante de velocidad de aprendizaje de la red, el resultado W_{ij} de este cálculo es el nuevo valor que será asignado al peso en la siguiente iteración. El principio esencial de los algoritmos de corrección del error es usar la señal de error ($d-y$) para modificar los pesos en las conexiones y reducir gradualmente el error.

Algoritmo de Aprendizaje de Retro-propagación del Error

El algoritmo de aprendizaje que usa una Red Neuronal Multicapa es la Retro-propagación del Error. La importancia de este algoritmo radica en su capacidad de modificar los pesos de las neuronas de las capas intermedias de la red durante el entrenamiento.

La idea central de la retro-propagación del error es calcular los errores para las unidades de las capas ocultas a partir de los errores en las unidades de salida, para luego propagarlos capa tras capa hacia atrás hasta llegar a la capa de entrada, modificando los pesos de las neuronas en cada paso. El algoritmo debe ajustar los parámetros de la red para calcular el gradiente de error y minimizar el error medio cuadrático entre la salida deseada y la salida de la red.

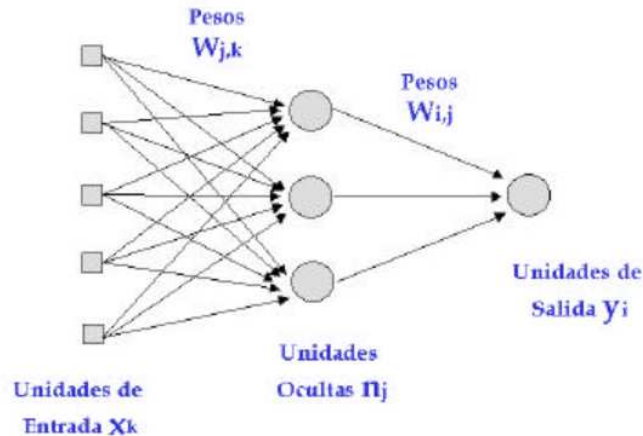


Figura D.7 Red Neuronal Multicapa

Existen dos diferencias con respecto al algoritmo de corrección de error visto anteriormente: en vez de un valor de entrada se utiliza la activación de la unidad oculta n_j como se muestra en la figura anterior, y la ecuación contiene un término para el gradiente de la función de activación. Si E_i es el error ($d_i - y_i$) del nodo de salida, donde d_i es la salida deseada e y_i es la salida real, entonces la ecuación de actualización de los pesos del vínculo entre la unidad 'j' y la unidad 'i' es:

$$W_{ij} = W_{ij} + \alpha \cdot n_j \cdot E_i \cdot f'(ent_i) \quad (D.2)$$

En donde f' es la derivada de la función de activación h con entrada ent_i . Si se define el nuevo término de error Δ_i como:

$$\Delta_i = E_i \cdot f'(ent_i) \quad (D.3)$$

La ecuación de actualización de los pesos se convierte entonces en:

$$W_{ij} = W_{ij} + \alpha \cdot n_j \cdot \Delta_i \quad (D.4)$$

Para actualizar las conexiones entre las unidades de entrada y las ocultas, hay que definir una cantidad análoga al término de error de los nodos de salida. Es en este momento cuando se realiza la propagación inversa del error. La idea es que el nodo oculto 'j' es responsable de una parte del error Δ_i en cada uno de los nodos de salida con los que se conecta. Por lo tanto, los valores son Δ_i divididos de acuerdo con la intensidad de la conexión entre el nodo oculto y el nodo de salida, y se propagan hacia atrás para proporcionar los valores Δ_j del estado oculto. La regla de propagación de los valores Δ es la siguiente:



$$\Delta_j = f'(ent_j) \cdot \sum_i W_{ij} \cdot \Delta_i \quad (D.5)$$

Ahora bien, la regla de actualización de pesos correspondiente a los pesos que están entre las entradas y el nivel oculto es casi idéntica a la regla de actualización del nivel de salida:

$$W_{jk} = W_{jk} + \alpha \cdot x_k \cdot \Delta_j \quad (D.6)$$

D.2 SISTEMAS DIFUSOS

La teoría sobre conjuntos difusos y sistemas de lógica difusa fue obtenida principalmente de las referencias [35], [36].

Los fundamentos de los sistemas difusos se encuentran en la lógica difusa. La lógica difusa o borrosa es una técnica de computación flexible que le permite a un computador clasificar información del mundo real en una escala infinita acotada por los valores falso y verdadero; tiene por objetivo proporcionar un soporte matemático formal al razonamiento basado en el lenguaje natural, el cual se caracteriza por tratarse de un razonamiento de tipo aproximado que hace uso de proposiciones que expresan información de carácter impreciso.

Algunas características de la lógica difusa que la hacen de tanto interés son:

- Es fácil de entender, los conceptos matemáticos son bastante sencillos.
- Es flexible, su escalamiento es sencillo.
- Es tolerante a datos imprecisos.
- Puede modelar funciones no-lineales de complejidad arbitraria.
- Puede ser construida sobre la información de la experiencia de los operarios que manejan el sistema que se desea automatizar.
- Puede ser complementaria a las técnicas de control convencionales.
- Está basada en el lenguaje utilizado por los humanos.

La lógica difusa debe ser distinguida de la incertidumbre en el sentido en que la lógica difusa describe la ambigüedad de un evento, mientras que la incertidumbre la ocurrencia de un evento. Específicamente, el concepto incerteza se refiere a la incerteza estocástica, que se caracteriza por referirse a eventos bien definidos, por ejemplo,

La probabilidad de que el motor falle es de 80%

La lógica difusa trata con incertezas lingüísticas del tipo:

El motor falla constantemente

Ambas sentencias son muy similares, sin embargo, existe una significativa diferencia en cuanto a la forma de expresar la probabilidad. Mientras en el caso de incerteza estocástica, la probabilidad es expresada en un sentido matemático, en una incerteza lingüística la probabilidad es percibida correctamente sin que haya sido cuantificada.

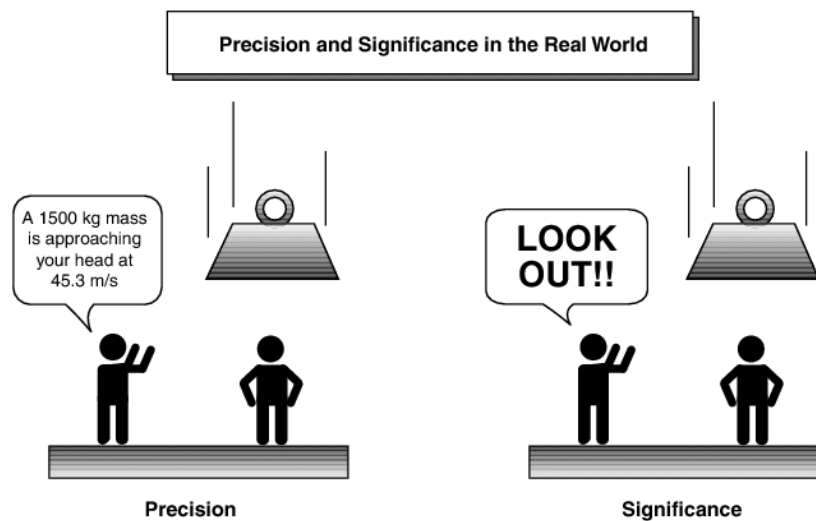


Figura D.8 Incertezas estocástica y lingüística

A continuación se explican algunos conceptos que son de gran utilidad para el estudio de la lógica difusa y la teoría de los conjuntos difusos:

Universo de Discurso: El universo de discurso denotado por U contiene todos los elementos que pueden ser tomados bajo consideración para asignar valores a las variables del sistema difuso. Los conjuntos difusos toman sus elementos del universo de discurso, por ejemplo el conjunto de gente joven podría tener a todos los seres humanos del mundo como su universo.

Función de Pertenencia: Todos los elementos dentro del universo de discurso U son miembros de algún conjunto difuso en cierto grado. La función de pertenencia es la curva que define con que grado cada elemento está incluido en el conjunto difuso. Para la definición de las funciones de pertenencia se utilizan formas estándar como la función triangular, trapezoidal, gaussiana, campana generalizada, exponencial, singleton.

Variables Lingüísticas: Las variables lingüísticas son elementos fundamentales de cualquier sistema de lógica difusa. En ellas se combinan

múltiples categorías subjetivas que describen el mismo concepto, así, para el caso de la variable *altura* existirán las categorías: *bajo*, *mediano*, *alto* y *muy alto*, que son llamadas términos lingüísticos y representan los posibles valores de una variable lingüística. En un lenguaje más formal, una variable lingüística se caracteriza básicamente por tres parámetros (x , $T(x)$, U) donde x es el nombre de la variable, $T(x)$ es el conjunto de términos lingüísticos de x , y U es el universo de discurso.

Grado de Pertenencia: Es el grado con el cual una entrada bien definida es compatible con una Función de Pertenencia, puede tomar valores entre 0 y 1. Por ejemplo, el Grado de Pertenencia de x al conjunto difuso *alto* (A) es representado por la función $\mu_A(x)$, donde x es un valor numérico de altura dentro del universo U ($x \in U$). El rango de μ es cualquier valor entre 0 y 1, según represente algún valor entre ningún o total grado de pertenencia al conjunto difuso.

Término: Es una categoría subjetiva de una variable lingüística, y consecuentemente, es el nombre descriptivo usado para identificar una función de pertenencia. Tal como las variables algebraicas toman valores numéricos, las variables lingüísticas toman como valores términos lingüísticos.

Entradas bien definidas (Entradas Crisp): Son los diferentes valores discretos de la variable del sistema, por ejemplo las alturas medidas de un grupo de personas: 1.60m, 1.75m, 1.80m, etc. En oposición al concepto de difuso, lo crisp, definido, nítido o preciso no representa ninguna incerteza o imprecisión.

Rango/Dominio: Es el intervalo sobre el cual se define una Función de Pertenencia. Por ejemplo, una función de pertenencia Alto podría tener un dominio de 1.60 a 1.9 m y su rango sería de 0.3 m.




Figura D.9 Conceptos de Lógica Difusa

Conjuntos Difusos

En teoría clásica de conjuntos, un conjunto tiene unos límites nítidos definidos (límites crisp). Por ejemplo, el conjunto A de los números más grandes que 8 se representa como:

$$A = \{ x/x > 8 \}$$

Sin embargo, según la teoría de los Conjuntos Difusos las vaguedades inherentes a los conceptos manejados por el ser humano, la transición desde “pertenecer a un conjunto” hasta “no pertenecer a un conjunto” es gradual. Así, un conjunto difuso (un conjunto sin un límite definido), contiene elementos sólo con un cierto grado de pertenencia.

A diferencia de los conjuntos clásicos que pueden ser caracterizadas ya sea por sus funciones de pertenencia, una descripción de sus elementos o un listado de sus elementos, los conjuntos difusos sólo pueden ser caracterizados por sus funciones de pertenencia; la única condición que una función de pertenencia debe satisfacer es que debe variar entre 0 y 1. La función en sí misma puede ser una curva arbitraria cuya forma la podemos definir como una función que sea agradable desde el punto de vista de simplicidad, conveniencia, velocidad y eficiencia. Una forma particular para la función de pertenencia puede ser determinada sólo en el contexto de una aplicación particular pero resulta que muchas aplicaciones no son muy sensibles a las variaciones en la forma de sus funciones de pertenencia; en tales casos, es conveniente usar una forma simple, tal como la forma triangular. En la siguiente figura se presenta algunas funciones de pertenencia frecuentemente utilizadas:






Figura D.10 Funciones de Pertenencia. (a) Tipo Triangular. (b) Tipo Trapezoidal. (C) Tipo Gaussiana. (d) Tipo Campana Generalizada

A los conjuntos difusos se les pueden aplicar determinados operadores, o bien puede realizarse operaciones entre ellos de la misma forma como se hace con los conjuntos crisp o clásicos. En general las funciones que definen las operaciones entre conjuntos difusos son arbitrarias en un grado sorprendente, lo que significa que uno puede crear sus propios operadores. Los operadores que califican como intersecciones difusas y uniones difusas son referidos como **Tnormas** y **T-conormas** respectivamente.

Por ejemplo, sean A y B dos conjuntos difusos en U con funciones de pertenencia μ_A y μ_B respectivamente, es usual definir la *T-norma min*, la *T-conorma max*, y el complemento de la siguiente manera:

T – norma min:

$$A \text{ Y } B = \mu_A(u) \min \mu_B(u)$$

T – conorma max:

$$A \text{ O } B = \mu_A(u) \max \mu_B(u)$$

Complemento de A:

$$\mu_{\bar{A}} = 1 - \mu_A(u)$$

Como lo demostró Zimmerman, los pares de T-normas y T-conormas satisfacen las propiedades conmutativas, asociativas y distributivas de los conjuntos clásicos así como las leyes de Morgan.

La bibliografía sobre lógica difusa contiene abundante información en cuanto a la Teoría de los Conjuntos Difusos, donde se abordan temas como relación y composición difusa como extensión de sus contrapartes clásicas.

Lógica Difusa

Los Sistemas Lógicos Difusos son sistemas basados en reglas, las cuales son expresadas como implicaciones lógicas, es decir, en forma de sentencias SI-ENTONCES. La implicación refleja la relación que guarda un hecho derivado de otro y pertenece a una rama de las matemáticas conocida como lógica.

La lógica, en su variante proposicional, tiene su elemento base en la proposición o “hecho”. Una proposición es una sentencia que involucra términos definidos y debe ser apropiadamente llamada “verdadera” o “falsa”, es decir hay hechos que se cumplen o no. Sin embargo, haciendo una extensión de la teoría de conjuntos difusos, se puede decir que hay hechos que no son necesariamente ciertos o falsos, sino que tienen un cierto grado de verdad. Por ejemplo, “hoy hace calor” podría ser una oración válida en grado 0.6; así, lo que existe en el mundo no es



un hecho, sino el grado de verdad de un hecho, y los seres humanos tiene un grado de certeza del hecho que puede variar entre 0 y 1 (falso y verdadero).

Concretamente, se puede decir que una lógica consta de lo siguiente:

Un sistema formal para describir lo que está sucediendo en un momento determinado, y que consta de:

- La sintaxis del lenguaje, que explica como construir oraciones
- La semántica del lenguaje, a través de la cual cada oración expresa algo relacionado con el mundo.

Una Teoría de demostración, que agrupe un conjunto de reglas para deducir las implicaciones de un conjunto de oraciones, y que especifique los pasos de razonamiento confiables.

Con el objetivo de mostrar la relación existente entre lógica proposicional y la lógica difusa, se presentan los conceptos referentes a sintaxis, semántica e inferencia relacionados a cada una de ellas.

Sintaxis

La sintaxis de la lógica proposicional está conformada por las constantes lógicas V (verdadero) y F (falso), los símbolos de las proposiciones tales como p y q, y los operadores lógicos conjunción (\wedge), disyunción (\vee), negación (\sim), equivalencia (\leftrightarrow) e implicación (\rightarrow). En lógica difusa, sin embargo, en vez de las constantes lógicas V y F se utilizan grados de verdad (grados de pertenencia a los conjuntos difusos) y los operadores lógicos son la negación difusa, las T-normas y las T-conormas.

Tabla D.2 Sintaxis de la Lógica Proposicional y de la Lógica Difusa

Elemento de Sintaxis	Lógica Clásica	Lógica Difusa
Constantes Lógicas	Verdadero (V) Falso (F)	Grado de verdad que varía entre 0 y 1
Símbolos de Proposiciones	p, q, r, etc.	p, q, r, etc.
Operadores Lógicos	Conjunción Disyunción Negación Implicación Equivalencia	T - normas T - conormas Negación difusa

Semántica

Al igual que en lógica proposicional, en lógica difusa, la semántica se define especificando la interpretación de los símbolos de proposición y de las constantes y especificando el significado de los conectores lógicos; a continuación se presenta una tabla de los valores semánticos de los elementos de la lógica difusa y de la lógica proposicional.



Tabla D.3 Semántica de la Lógica Proposicional y de la Lógica Difusa

Elemento	Significado Semántico	
	Lógica proposicional	Lógica difusa
$p, q, r, \text{ etc}$	Un hecho. Ejm: Lima es una ciudad grande	Un grado de verdad. Ejm: Lima es una ciudad grande en un grado 0.6
Constantes lógicas	Verdadero: El hecho de la verdad Falso: No existe en el mundo	Certeza en cierto grado de verdad
Operadores lógicos	$\wedge, \vee, \neg, \text{ etc.}$	$\wedge, \vee, \neg, \text{ etc.}$

Inferencia

La inferencia lógica es un proceso mediante el cual se implanta la relación de implicación que existe entre oraciones; es decir, si se cuenta con determinadas premisas y una posible conclusión, se puede averiguar si la conclusión es verdadera. Para ello, en lógica proposicional se construye una tabla de verdad para la oración Premisas \rightarrow conclusión y se procede a verificarla.

El procedimiento que permite cerciorarse de la confiabilidad de una inferencia mediante tablas de verdad, podría emplearse a clases enteras de inferencias pues existen ciertos patrones que se presentan una y otra vez, lo que permite establecer a simple vista su confiabilidad. De esta manera se aprehende el patrón respectivo en algo que se conoce como regla de inferencia. Una vez establecida la regla, se le puede emplear para hacer más inferencias sin pasar por el tedioso procedimiento de la construcción de tablas de verdad. Se considera confiable una regla de inferencia si la conclusión es verdadera en todos aquellos casos en los que las premisas también son válidas. Algunas reglas de inferencia muy conocidas son: el Modus Ponens, el Modus Tolens, la Resolución, y la O-Introducción.

Si se desea aplicar la lógica proposicional a la ingeniería, la regla de inferencia que se ha de utilizar es el Modus Ponens, ya que satisface la Ley de Causa y Consecuencia.

Así:

Premisa 1 (Hecho): "x es A"

Premisa 2 (Conocimiento): "Si x es A, entonces y es B"

Conclusión: "y es B"

En lógica difusa se utiliza el Modus Ponens Generalizado, una extensión del Modus Ponens:



Premisa 1 (Hecho): "u es A"

Premisa 2 (Conocimiento): "Si u es A, entonces v es B"

Consecuencia: "v es B"

Al comparar el Modus Ponens y el Modus Ponens Generalizado para determinar sus principales diferencias, en este último A^* no es necesariamente igual al antecedente A y B^* no es necesariamente igual al consecuente B. En lógica proposicional una regla será disparada sólo si la primera premisa es exactamente igual al antecedente de esa regla, y el resultado de tal activación es el consecuente real de la regla; en lógica difusa sin embargo, una regla es activada mientras no haya un grado cero de similitud entre la premisa y el antecedente de la regla, y el resultado de tal activación es un consecuente que tiene un grado de similitud diferente de cero con respecto al consecuente de la regla. Este proceder puede ser entendido como razonamiento aproximado.

D.3 SISTEMAS LÓGICOS DIFUSOS

En general, un Sistema Lógico Difuso (SLD) es un mapeo no-lineal de un vector de datos de entrada con una salida escalar, es decir mapea números con números. La teoría de los conjuntos difusos y la lógica difusa establecen las especificaciones de este mapeo no-lineal único, en cuanto es capaz de manejar datos numéricos y conceptos lingüísticos simultáneamente. Los SLD han sido aplicados exitosamente en campos tales como el control automático, clasificación de datos, análisis de decisiones, sistemas expertos y visión por computadora.

Etapas de un Sistema Lógico Difuso

Un SLD consta de tres etapas:

- Fusificación
- Reglas de Evaluación
- Defusificación

El esquema se muestra en la figura D.11

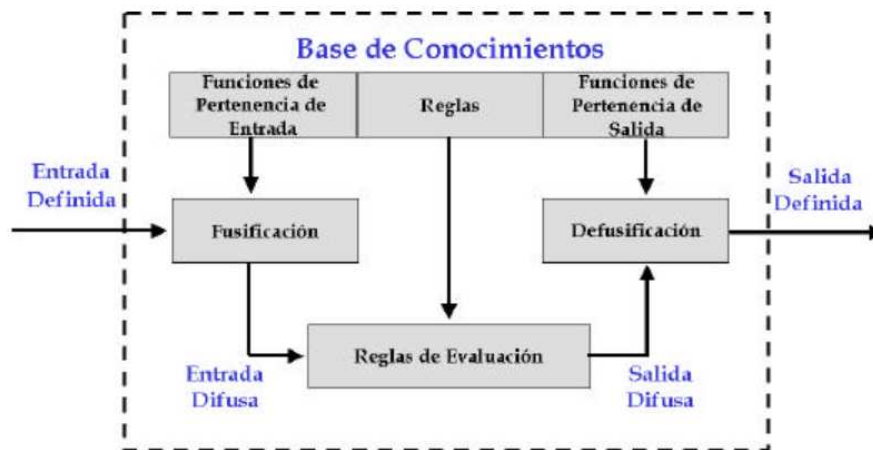


Figura D.11 Sistema Lógico Difuso

Fusificación

Los elementos fundamentales en esta etapa son las Funciones de Pertenencia de Entrada. La variable del proceso (entrada definida, no-difusa o crisp) intersecta las Funciones de Pertenencia generando las entradas difusas. Mediante este procedimiento, el fusificador establece una relación entre los puntos de entrada no difusos y sus correspondientes conjuntos difusos en el universo de discurso U .

Reglas de Evaluación

Las Reglas son sentencias SI-ENTONCES que describen las condiciones (antecedentes) y las acciones (consecuentes) que deben existir para tomar una decisión. La sintaxis de las reglas es la siguiente:

SI Antecedente 1 Y Antecedente 2 . . . ENTONCES Consecuente 1 Y . . .

El antecedente de una regla puede tener muchas partes, en tal caso todas las partes del antecedente son calculadas simultáneamente y transformadas en un número utilizando los operadores lógicos descritos en la sección precedente. El consecuente de una regla puede también tener partes múltiples y todos los consecuentes son afectados de la misma manera por el antecedente.

En el caso de lógica proposicional, evaluar las reglas SI-ENTONCES es sencillo. Si la premisa es verdadera, la conclusión es verdadera, por el contrario, se genera un problema cuando el antecedente es difuso, pues no se sabe como se verá afectado el consecuente. Sin embargo, de acuerdo a la teoría en lógica difusa, si el antecedente es verdadero en cierto grado, entonces el consecuente es verdadero en cierto grado.

Así, las reglas difusas permiten expresar el conocimiento que se tiene acerca de la relación entre los antecedentes y los consecuentes en un cierto grado



de verdad. Para expresar este conocimiento de forma completa normalmente se precisa de varias reglas, con pesos asociados, que se agrupan formando una base o bloque de reglas.

Mediante la inferencia los sistemas difusos interpretan las reglas de tipo IF-THEN contenidas en su base de conocimientos, con el fin de obtener los valores de salida a partir de los valores que tienen las variables lingüísticas de entrada al sistema. Una vez que las entradas crisp han sido convertidas a variables de valores lingüísticos (fusificación), se utiliza la inferencia difusa para identificar las reglas de tipo SI-ENTONCES que se aplican a la situación actual y se calculan los valores lingüísticos de salida.

La inferencia es un cálculo que consiste en tres pasos: agregación de las variables lingüísticas de entrada, composición o implicación y agregación del resultado.

Agregación de las variables lingüísticas de entrada

Es el primer paso que se sigue para realizar una inferencia difusa, la agregación determina el grado en el que se cumple la parte SI de la regla. Si la regla contiene varias premisas, estas suelen estar relacionadas por operadores lógicos difusos como T-normas y T-conormas.

Composición

Es el segundo paso que se lleva a cabo para realizar la inferencia, y es conocida también como implicación difusa. Mediante la composición se comprueba la validez de la conclusión de una regla al relacionar el grado con que se cumple el antecedente de la regla, con el peso de la misma.

Agregación del Resultado

Ya que las decisiones están basadas en la prueba de todas las reglas que forman un sistema de inferencia difuso los consecuentes de las reglas deben ser combinados de alguna manera para tomar una decisión. La agregación es el proceso a través del cual los conjuntos difusos que representan las salidas de las reglas son combinados en un único conjunto difuso.

Defusificación

La salida del proceso de inferencia es hasta ahora un conjunto difuso que indica la posibilidad de realizar una acción de control. Sin embargo, las aplicaciones de los sistemas difusos no pueden interpretar los valores lingüísticos obtenidos, por lo que funciones de pertenencia de salida son utilizadas para retransformar los valores difusos nuevamente en valores definidos o crisp mediante la defusificación.

Algunos métodos de defusificación existentes son:

- Procedimiento Máximo
- Media Ponderada
- Singleton
- Centro de Masa



- Centro de Área

D.4 SISTEMAS NEURO-DIFUSOS

La Lógica Difusa y las Redes Neuronales tienen propiedades computacionales particulares que las hacen adecuadas para ciertos problemas particulares y no para otros. Por ejemplo, mientras las redes neuronales ofrecen ventajas como el aprendizaje, adaptación, tolerancia a fallas, paralelismo y generalización, no son buenas para explicar como han alcanzado sus decisiones. En cambio los sistemas difusos, los cuales razonan con información imprecisa a través de un mecanismo de inferencia bajo incertidumbre lingüística, son buenos explicando sus decisiones pero no pueden adquirir automáticamente las reglas que usan para tomarlas.

Tabla D.4 Lógica Difusa Y Redes Neuronales

Lógica Difusa	Redes Neuronales
Permite utilizar el conocimiento disponible para optimizar el sistema directamente.	No existe un método sencillo que permita modificar u optimizar la red, ya que esta se comporta como una "caja negra"
Permite describir el comportamiento de un sistema a partir de sentencias "si – entonces"	La selección del modelo apropiado de red y el algoritmo de entrenamiento requiere de mucha experiencia
Permite utilizar el conocimiento de un experto	Permite hallar soluciones a partir de un conjunto de datos
El conocimiento es estático	Son capaces de aprender y auto-adaptarse
Existen muchas aplicaciones comerciales	Su aplicación es mayormente académica
Permiten encontrar soluciones sencillas con menor tiempo de diseño	Requieren un enorme esfuerzo computacional

Los sistemas Neuro-Difusos combinan la capacidad de aprendizaje de las RNAs con el poder de interpretación lingüística de los sistemas de inferencia difusos, obteniéndose los siguientes resultados:

- Aplicabilidad de los algoritmos de aprendizaje desarrollados para redes neuronales.
- Posibilidad de promover la integración de conocimiento (implícito que puede ser adquirido a través del aprendizaje y explícito que puede ser explicado y entendido).
- La posibilidad de extraer conocimiento para una base de reglas difusas a partir de un conjunto de datos.

Existen sistemas de desarrollo que han logrado unir la Lógica Difusa con las Redes Neuronales, por ejemplo se tiene:

ANFIS

ANFIS (Adaptive Neuro Fuzzy Inference System) es un método que permite sintonizar o crear la base de reglas de un sistema difuso, utilizando el algoritmo de entrenamiento de retropropagación a partir de la recopilación de datos de un proceso. Su arquitectura es funcionalmente equivalente a una base de reglas tipo Sugeno.

FSOM

FSOM (Fuzzy Self-Organizing Maps) consiste en un sistema difuso optimizado a partir de la técnica de los mapas auto-organizados de Kohonen.

NEFCLASS

El algoritmo NEFCLASS está basado en la estructura del perceptrón multicapa cuyos pesos son modelados por conjuntos difusos. Así, se preserva la estructura de una red neuronal, pero se permite la interpretación del sistema resultante por el sistema difuso asociado, es decir, la RNA deja de ser una “caja negra”.

Aprendizaje en un sistema neuro-difuso

El sistema neuro-difuso consiste de un sistema difuso tradicional (ver figura D.13) excepto que cada etapa, puede ser representada por una capa de neuronas a las que se puede proveer capacidades de aprendizaje de Redes Neuronales para optimizar el conocimiento del sistema como muestra la figura D.12.



Figura D.12 Diagrama de bloques de un sistema neuro-difuso

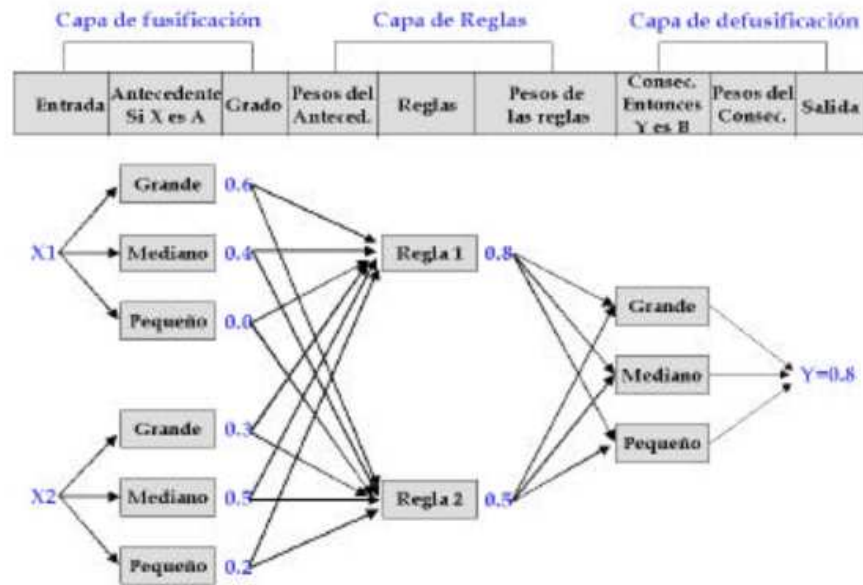


Figura D.13 Estructura de un sistema neuro-difuso

En la figura D.13 cada pequeño rectángulo representa una neurona.

En la capa de fusificación, cada función de pertenencia de entrada del antecedente de una regla difusa representa una neurona. Los parámetros de estas neuronas, como los vértices de las funciones de pertenencia, pueden ser entrenados para determinar la forma final y la ubicación de las funciones de pertenencia.

En la figura D.13 el grado de pertenencia que indica la certeza de “ X_1 es grande” es 0.6, “ X_1 es mediano” es 0.4, y “ X_1 es pequeño” es 0.0. Las salidas de estas neuronas funciones de pertenencia son conectadas a la capa de reglas difusas como lo especifican las reglas difusas y a través de enlaces con pesos que representan el proceso de agregación de las variable lingüísticas de entrada.

La capa de reglas difusas representa la base de reglas difusas; cada neurona representa una regla difusa de tipo SI-ENTONCES. Las salidas de las neuronas están conectadas a la capa de defusificación a través de enlaces con pesos; los pesos de estos enlaces representan la significancia relativa de las reglas asociadas con las neuronas. Sus valores pueden ser asignados de acuerdo al conocimiento a priori o inicializados como 1.0 y luego entrenados para reflejar su importancia real para las funciones de pertenencia de salida contenidas en la capa de defusificación.

La función de la capa de defusificación es la evaluación de las reglas; en este cada consecuente “Entonces Y es B” como función de pertenencia de salida representa una neurona; la certeza de cada consecuente es calculada, y es considerada como lo bien que se ajustan las reglas que tienen el mismo



consecuente (proceso de agregación del resultado). Los pesos de cada enlace de salida de estas neuronas representan los centros de área de cada función de pertenencia del consecuente y son entrenables, la salida final es entonces calculada usando algún método de defusificación.

Para realizar el entrenamiento de los sistemas neuro-difusos la estructura de la figura D.13 puede ser configurada con valores iniciales obtenidos del conocimiento a priori, y luego, sintonizados utilizando un algoritmo de entrenamiento tal como Retro-propagación del Error, de la siguiente manera:

Paso 1: Presentar una muestra de entrada, y computar la salida correspondiente

Paso 2: Computar el error entre la salida y el valor objetivo

Paso 3: Se ajustan los pesos de conexión y las funciones de pertenencia

Paso 4: Si el error es mayor que la tolerancia, volver al paso 2, si no es así, el entrenamiento ha sido finalizado.

D.5 ANFIS: ADAPTIVE-NETWORK-BASED FUZZY INFERENCE SYSTEM

Las arquitecturas y reglas de aprendizaje para redes adaptivas se describieron en el apartado anterior. Funcionalmente, casi no se imponen restricciones a las funciones de nodo de una red adaptiva excepto el requerimiento de que esas funciones sean diferenciables por partes. Estructuralmente, la única limitación de la configuración de la red es que debería ser del tipo unidireccional (en Inglés feedforward), si es que no se quiere usar modelos más complejos. Debido a estas mínimas restricciones, las redes adaptivas se pueden emplear directamente en una variedad de aplicaciones de modelación, toma de decisiones, procesamiento de señales, y control.

En esta sección se describe la arquitectura ANFIS (Sistemas de inferencia difusa basados en redes adaptivas). Se estudia como descomponer el conjunto de parámetros para facilitar la regla de entrenamiento híbrido para las arquitecturas ANFIS representando los modelos difusos Sugeno y Tsukamoto.

Arquitectura de los sistemas ANFIS [36]

Por simplicidad, se asume que el sistema de inferencia difusa bajo consideración tiene dos entradas (x, y) y una salida (f). Para un modelo difuso tipo Sugeno, un conjunto común de reglas con dos reglas difusas SI-ENTONCES es el siguiente:

Regla 1: Si x es A_1 y y es B_1 , entonces: $f_1 = p_1x + q_1y + r_1$

Regla 2: Si x es A_2 y y es B_2 , entonces: $f_2 = p_2x + q_2y + r_2$




Figura D.14 (a) Un Fuzzy tipo Sugeno con dos entradas de primer orden modelado con dos reglas. (b) Arquitectura Equivalente ANFIS

Esta figura ilustra el mecanismo de razonamiento para el modelo Sugeno con la correspondiente arquitectura ANFIS donde los nodos de la misma capa tienen funciones similares, como se describe a continuación: (la salida del nodo i en la capa l es: $O_{l,i}$)

Capa 1. Cada nodo i en esta capa es un nodo adaptable con una función de nodo

$$O_{1,i} = u_{A_i}(x) ; \quad i = 1, 2 \dots o$$

$$O_{1,i} = u_{B_{i-2}}(y) ; \quad i = 3, 4 \dots$$

(D.7)

Donde x (o y) es la entrada al nodo i y A_i (o B_{i-2}) es una etiqueta lingüística (tal como pequeño, grande, etc) asociada a ese nodo. En otras palabras, las salidas de esta capa son los valores de la función de pertenencia de la PREMISA parte. $O_{1,i}$ es el grado de pertenencia de un conjunto difuso A ($=A_1, A_2, B_1$ o B_2) y especifica el grado al cual la entrada dada x (o y) satisface el cuantificador A . Las funciones de pertenencia para A_i o B_i puede ser cualquier función de pertenencia parametrizada, presentada en apartados anteriores. Se escoge $u_{A_i}(x)$ como la función de pertenencia tipo Campana Generalizada con máximo valor igual a 1 y mínimo valor igual a 0:



$$u_{Ai}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (\text{D.8})$$

O, la función gaussiana:

$$u_{Ai}(x) = \exp \left\{ - \left(\frac{x - c_i}{a_i} \right)^2 \right\} \quad (\text{D.9})$$

donde (a_i, b_i, c_i) es el conjunto de parámetros. Cuando los valores de estos parámetros cambian, la forma de la función varía, pudiendo exhibir varias formas de funciones de pertenencia para el conjunto difuso A, B . Los parámetros en esta capa se conocen como **parámetros premisa**.

Capa 2. Cada nodo en esta capa es un nodo fijo etiquetado como Π , cuya salida es el producto de todas las señales de entrada:

$$O_{2,i} = w_i = u_{Ai}(x)u_{Bi}(y) ; \quad i = 1,2 \quad (\text{D.10})$$

Cada nodo en esta capa representa el peso de encendido de una regla. En general, cualquier otro operador Norma T que realiza la operación difusa AND se puede usar como la función de nodo en esta capa.

Capa 3. Cada nodo en esta capa es un nodo fijo etiquetado como N . El nodo i -ésimo calcula la relación entre el peso de encendido de la i -ésima regla con la suma de los pesos encendidos de todas las reglas:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} ; \quad i = 1,2 \quad (\text{D.11})$$

Por conveniencia, las salidas de esta capa se llaman **pesos de encendido normalizados**.

Capa 4. Cada nodo i en esta capa es un nodo adaptable con una función de nodo:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (\text{D.12})$$

Donde \bar{w}_i es la salida de la capa 3 y (p_i, q_i, r_i) es el conjunto de parámetros de este nodo. Los parámetros en esta capa se denotan como **parámetros consecuentes**.



Capa 5. El nodo simple en esta capa es un nodo fijo etiquetado como Σ , el cual calcula la salida general como la suma de todas las señales de entrada:

$$O_{5,1} = f = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (\text{D.13})$$

De este modo, la red adaptable es funcionalmente equivalente a un modelo difuso tipo Sugeno.

Algoritmo de entrenamiento híbrido

De la arquitectura de los sistemas ANFIS mostrada en la Fig. D.14 se observa que cuando los valores de los parámetros premisa son fijos, la salida general se puede expresar como una combinación lineal de los parámetros consecuentes. Simbólicamente, la salida en la figura se puede reescribir como:

$$\begin{aligned} f &= \bar{w}_1 f_1 + \bar{w}_2 f_2 \\ f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ f &= (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2 \end{aligned} \quad (\text{D.14})$$

La cual es lineal en los parámetros consecuentes $p_1, q_1, r_1, p_2, q_2, r_2$ y \cdot . De esta observación, se tiene:

S = conjunto total de parámetros

S₁ = conjunto de parámetros (no lineales) premisa o antecedentes,

S₂ = conjunto de parámetros (lineales) consecuentes

En resumen, este algoritmo de aprendizaje fuera de línea, compuesto de un paso hacia delante y un paso hacia atrás en correspondencia con cada iteración de entrenamiento (época), combina el algoritmo de propagación hacia atrás del descenso según el gradiente con el algoritmo de estimación de mínimos cuadrados. En el paso hacia delante, luego de que se presenta el vector de entrada, las salidas de los nodos llegan hasta el nodo 4 y los parámetros de la parte consecuente del sistema difuso se calculan usando el método de los mínimos cuadrados. En este paso se mantienen fijos los parámetros de la parte antecedente del sistema difuso. En el paso hacia atrás, las señales de error se propagan hacia atrás y los parámetros de la parte antecedente se actualizan usando el algoritmo de descenso según el gradiente. En esta parte se mantienen fijos los parámetros de la parte consecuente del sistema difuso.



Tabla D.5 Dos pasos en el procedimiento de aprendizaje híbrido para el ANFIS

	Forward Pass	Backward Pass
Parámetros Premisa	Fijo	Gradiente Descendiente
Parámetros Consecuentes	Estimación por Mínimos Cuadrados	Fijo
Señales	Salidas de los nodos	Señales de error

En consecuencia el enfoque híbrido converge mucho más rápido, ya que reduce la dimensión del espacio de búsqueda del original método BP (BackPropagation)

D.6 AGRUPAMIENTO DE DATOS (CLUSTERING)

La tecnología neuro-difusa provee un método poderoso para convertir datos experimentales en reglas difusas. Sin embargo, en muchos casos, los datos de entrenamiento deben ser agrupados previamente, esto es necesario por dos razones:

- Eliminar los datos redundantes para alcanzar la convergencia rápidamente.
- Resolver conflictos en los datos en casos en que el conjunto de ellos sea inconsistente.

El agrupamiento o clustering es una clasificación de datos en grupos (clusters) de acuerdo a un cierto criterio de similitud; por lo general, esto se logra maximizando la similitud intra-grupal y minimizando la similitud extra-grupal. La similitud de los datos está especificada por la precisión (accuracy) de cada variable.

Con el fin de ilustrar la función de un algoritmo de agrupamiento (clustering) de datos, se presenta la Figura B.15 en la que se grafican los valores de datos en el caso de una entrada y una única salida ya que es mucho más fácil identificar clusters en espacios de datos de dos dimensiones que en espacios dimensionales más grandes.

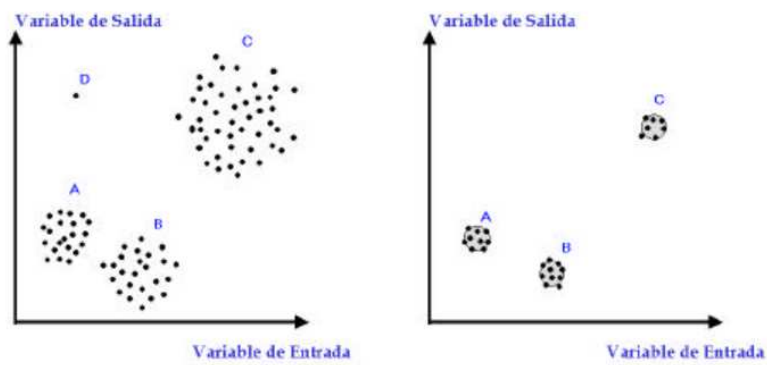


Figura D.15 Clusterización o agrupamiento de datos

Como se muestra en la figura D.15, la mayor parte de los datos se agrupan con otros en tres 'manchas'; estas manchas, son los clusters o grupos. Un dato en particular del cluster puede remplazar al grupo para disminuir el número de datos; este es llamado dato característico o representativo del grupo; así, como resultado se obtiene un conjunto de valores característicos, que representan al conjunto de datos inicial.

E. PROCESO DE ENTRENAMIENTO ANFIS

Obtención de Datos:

El proceso de obtención se realiza como sigue:

- Con el modelo del SEP creado, mediante ATP se simulan escenarios de diferentes tipos de fallas con el propósito de obtener la base de datos de entrada para el ANFIS.

Por ejemplo en el registro1 se tiene una falla de baja impedancia en la fase A con tierra y al 25% de la longitud de la línea. El registro simulado muestra:

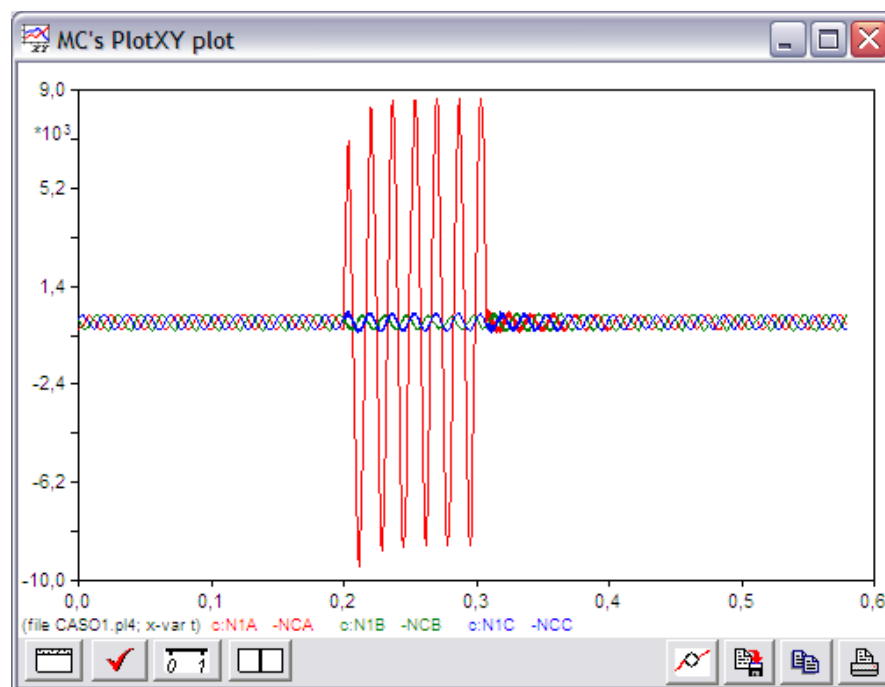


Figura E.1 Corrientes obtenidas para una falla tipo Fase A-T

- Estas simulaciones son recuperados en formato COMTRADE, que contienen la información de la falla en los archivos CFG y DAT

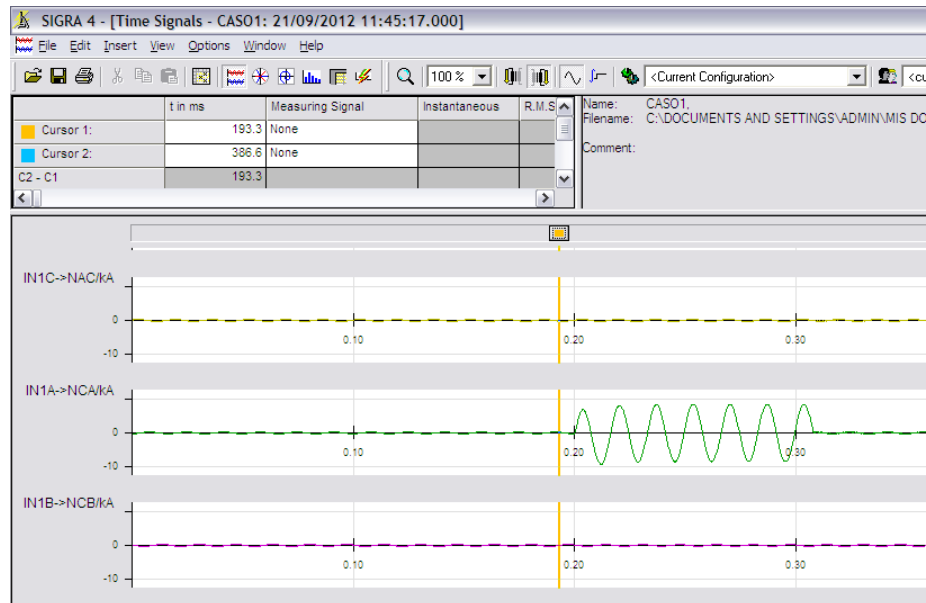


Figura E.2 COMTRADE del Registro: Falla Fase A-T visto en SIGRA

- c. Usando MATLAB, se recuperan los datos desde el archivo COMTRADE, para ser procesados

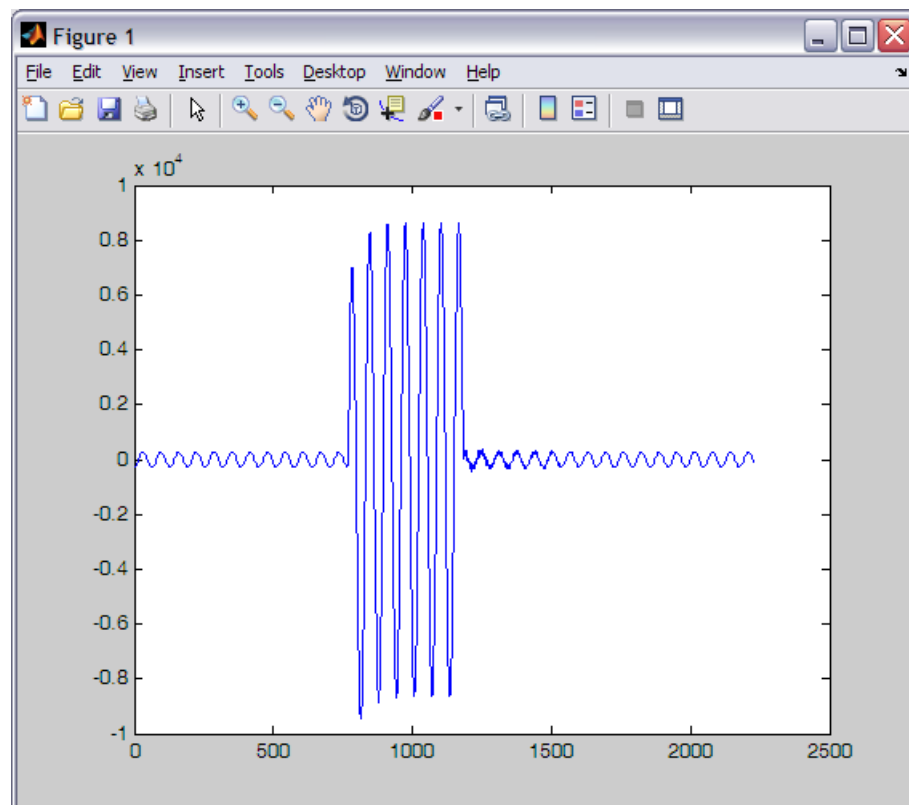


Figura E.3 Falla Fase A-T, visto en MATLAB

- d. Se realiza el procesamiento de la señal, para obtener el registro en valores RMS [28]

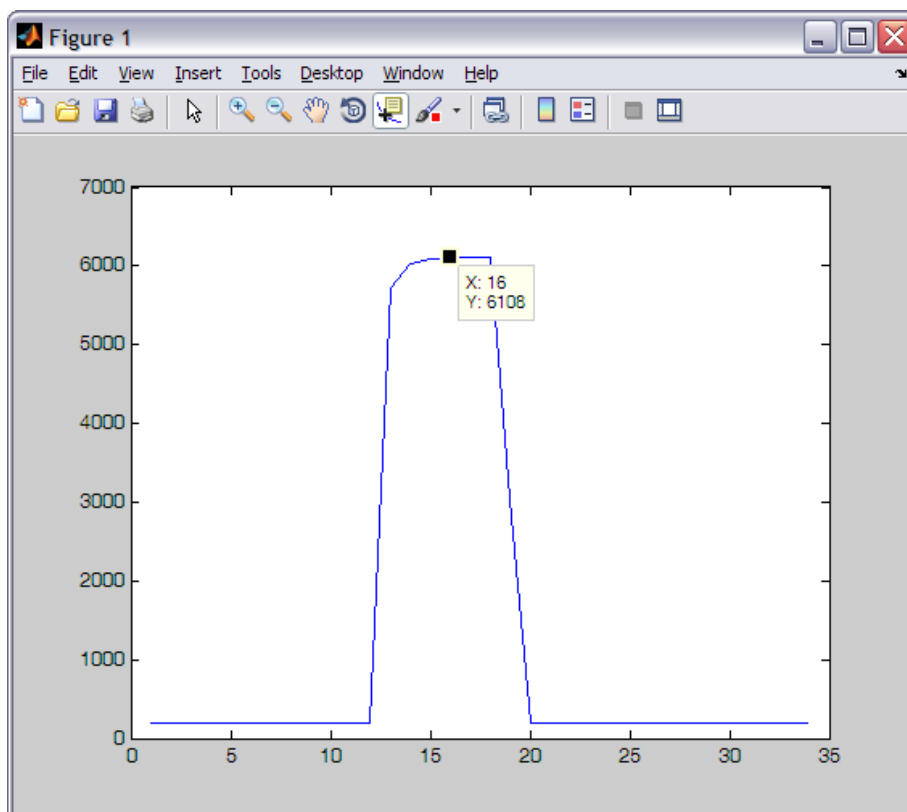


Figura E.4 Valores RMS de la corriente de la fase A con falla a Tierra

Como se observa en la figura anterior, para este registro, el valor representativo se encuentra en la muestra 16 con un valor RMS de 6108 A, este valor, se toma como dato para la matriz de entrenamiento y validación del ANFIS, que es el primer caso de estudio preliminar.

En el segundo caso de estudio, se realiza el análisis con las muestras completas del registro, es decir se toman las 34 muestras del registro.

Entrenamiento y Verificación del ANFIS:

En este proceso, se realizan los siguientes pasos:

Paso1: Cargamos la matriz de datos para entrenamiento y verificación

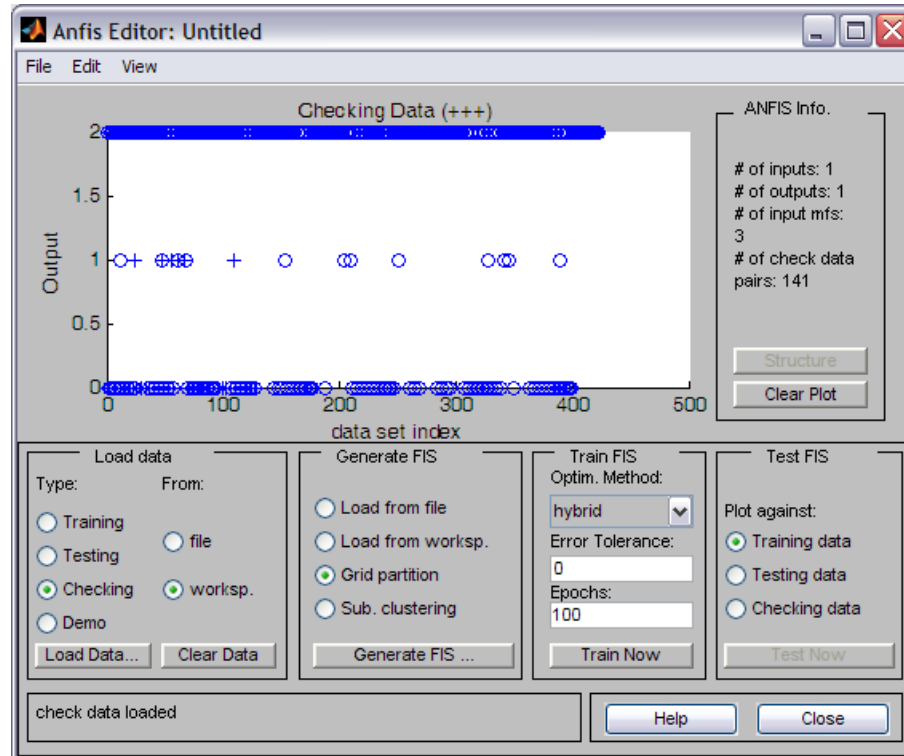


Figura E.5 Conjunto de Datos para entrenamiento (+) y verificación (o) del ANFIS

Paso2: Estructura FIS inicial. En MATLAB la función `genfis1/genfis2` genera una función de pertenencia inicial. La estructura del FIS inicial se define según el número y tipo de funciones de pertenencia (MF) a ingresar. A continuación se muestran algunos resultados:

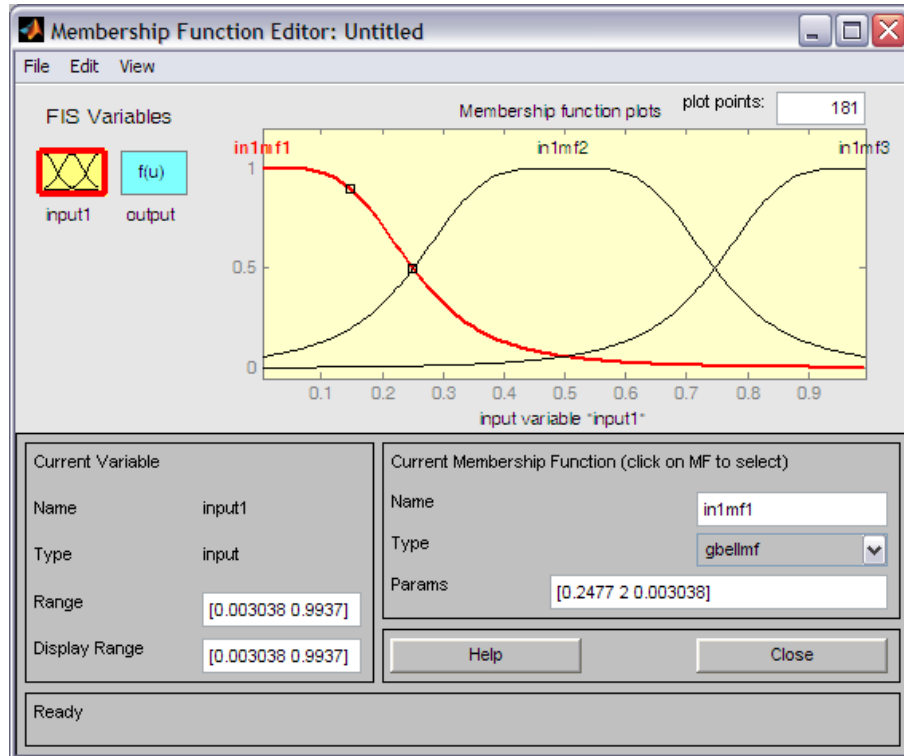


Figura E.6 Funciones de pertenencia iniciales creados con genfis1: 3MF, tipo gbell

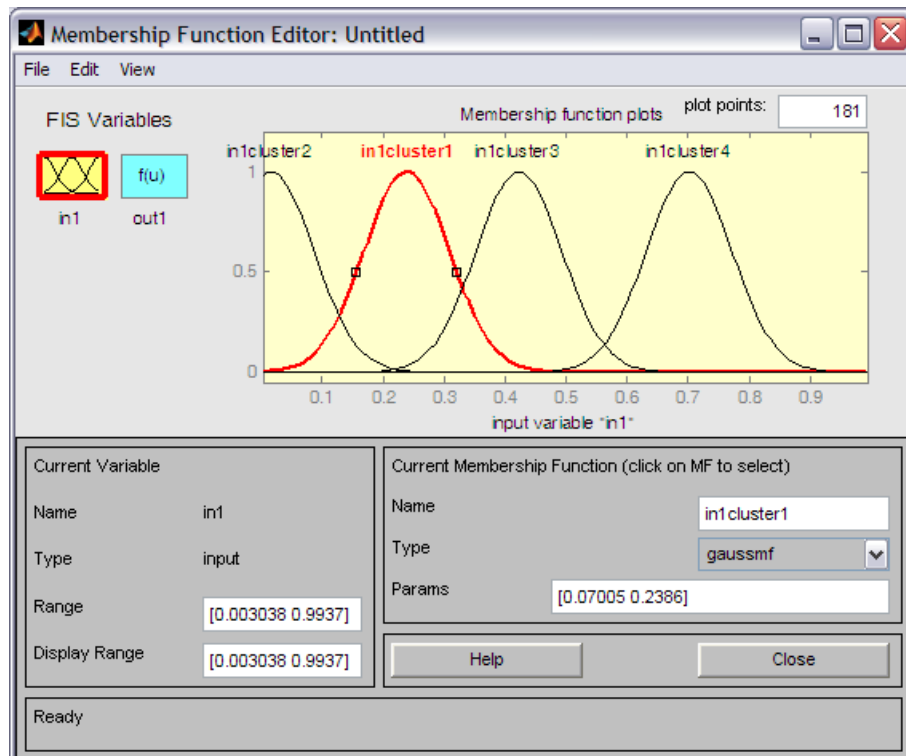


Figura E.7 Funciones de pertenencia iniciales creados con genfis2: 4MF, tipo gbell,
ra=0.2

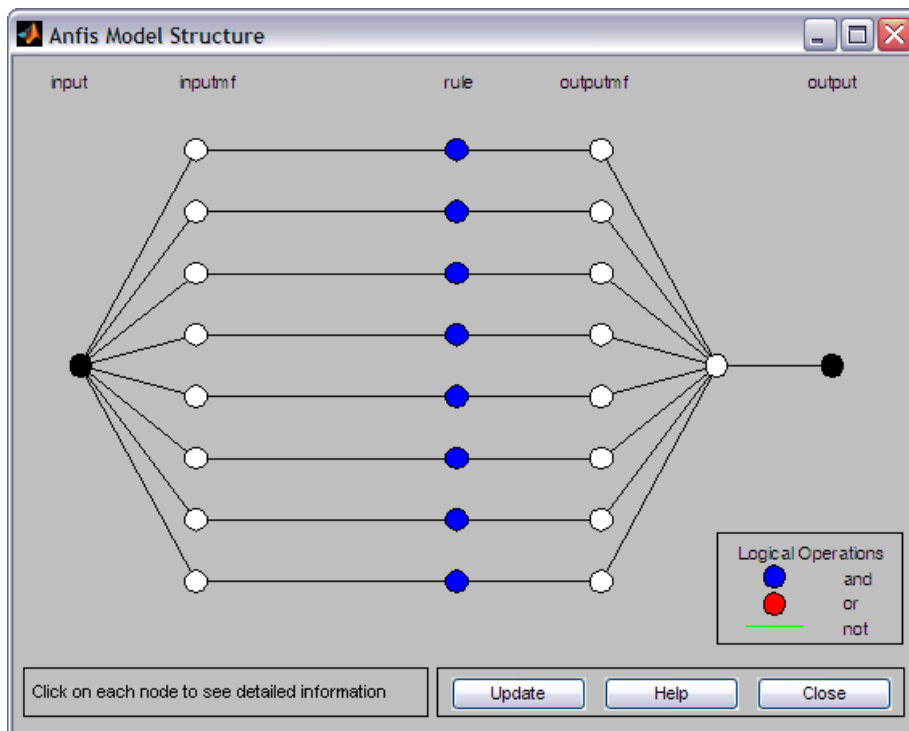


Figura E.8 Estructura FIS, para 8MF, tipo gbell, una entrada

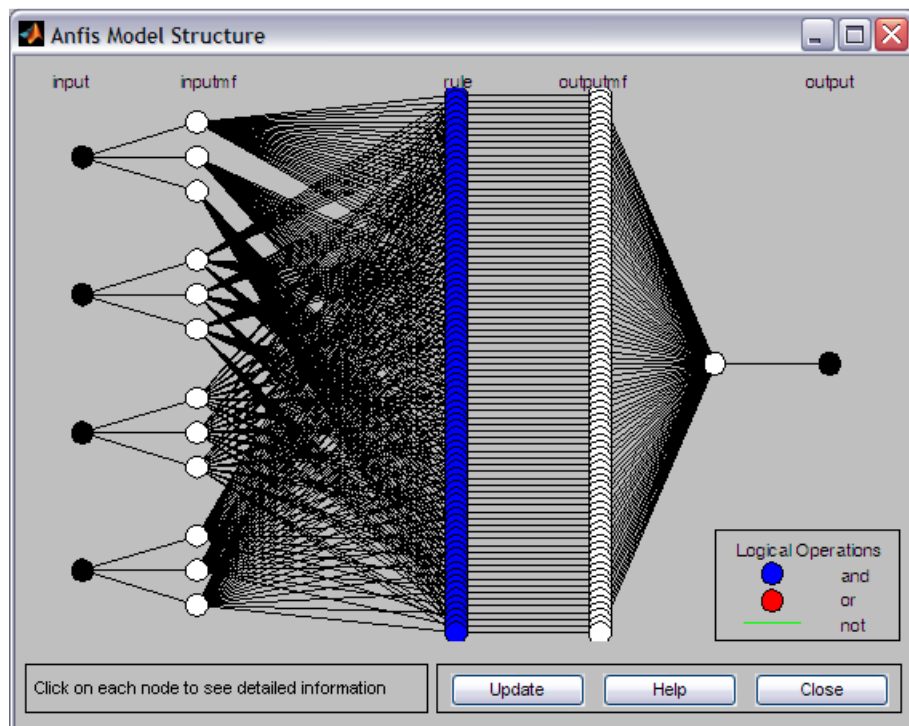


Figura E.9 Estructura FIS para 3MF, tipo gbell, 4 entradas

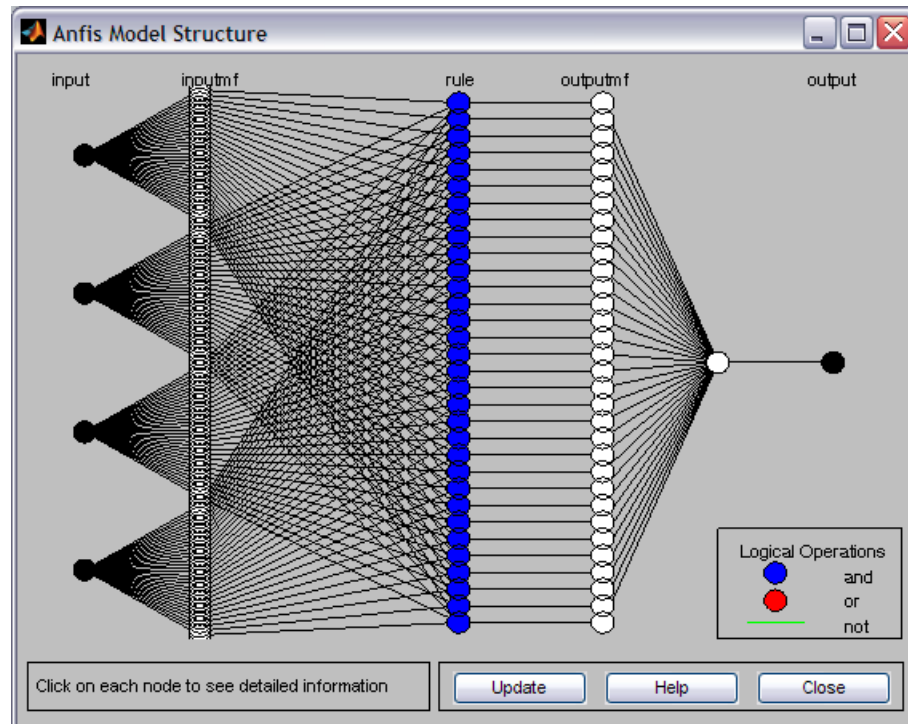


Figura E.10 Estructura FIS para 32MF, $ra=0.2$ y 4 entradas

Paso3: Se inicia el entrenamiento. Debido a que se realiza también la opción de comprobación (con los datos de verificación), el FIS final a los que decide el ANFIS como óptimo, es el asociado con la comprobación de errores mínimos causados, este se almacena en fismat2. Las gráficas siguientes muestran las funciones de pertenencia ajustados, para diferentes ANFIS generados, para el caso de la corriente de la fase A:

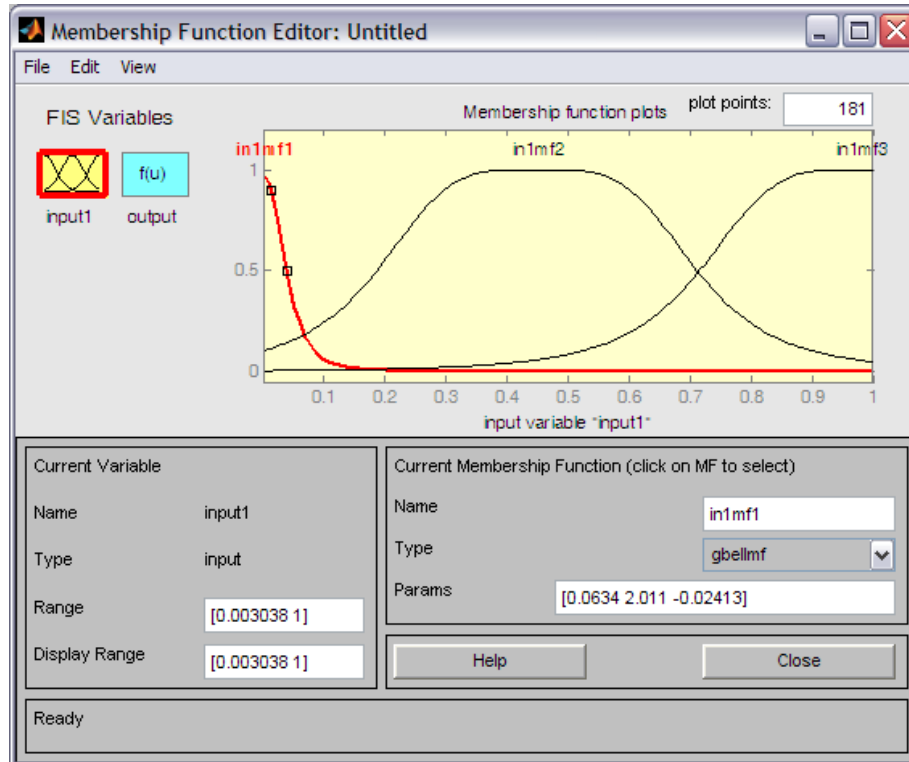


Figura E.11 Funciones de Pertenencia ajustado a la salida del ANFIS: método GP

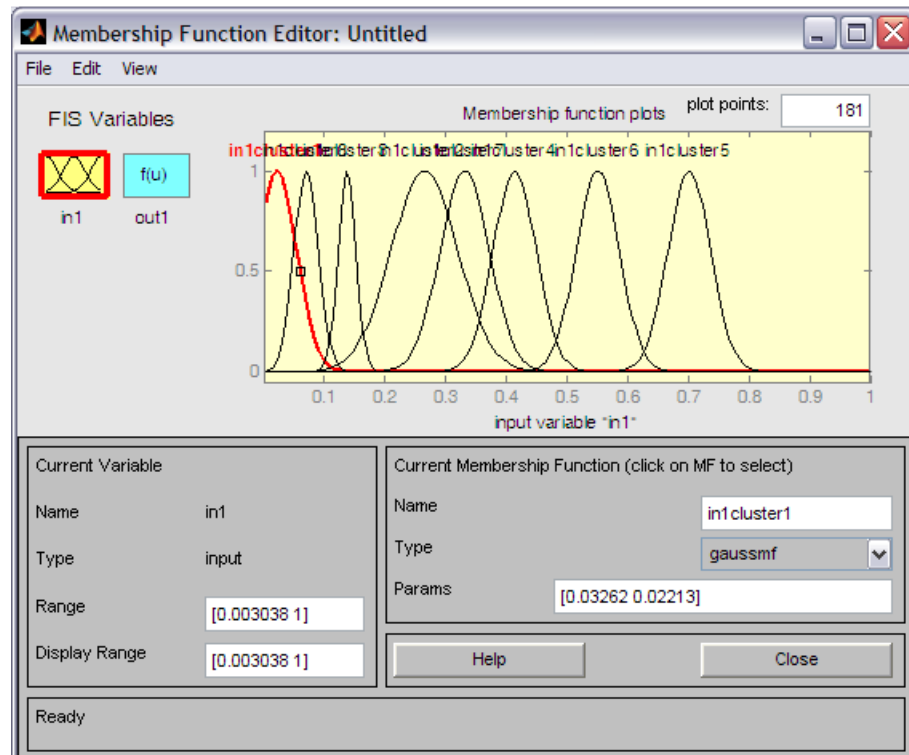


Figura E.12 Funciones de pertenencia ajustado a la salida del ANFIS: método SC



Paso4: Análisis del error RMSE (Root Mean Squared Error) obtenido, tanto para los datos de entrenamiento como para los de verificación. Se analizan varios ANFIS, de manera de obtener un error deseado mínimo. Las siguientes graficas muestran dos casos:

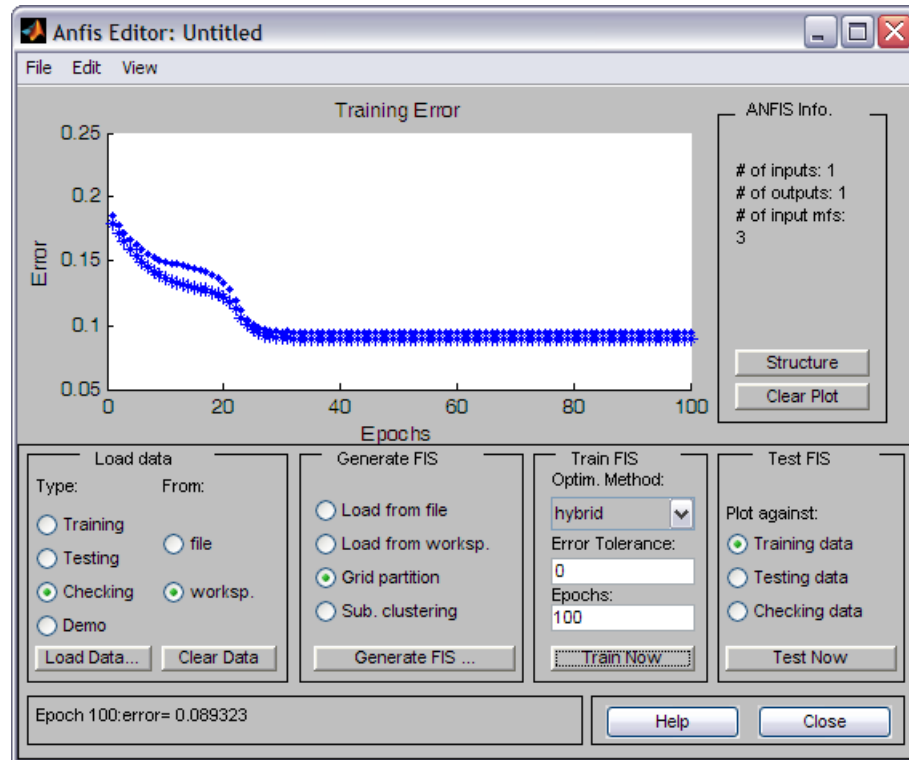


Figura E.13 Epochs Vs. Error de entrenamiento: GD. 3MF, gbell

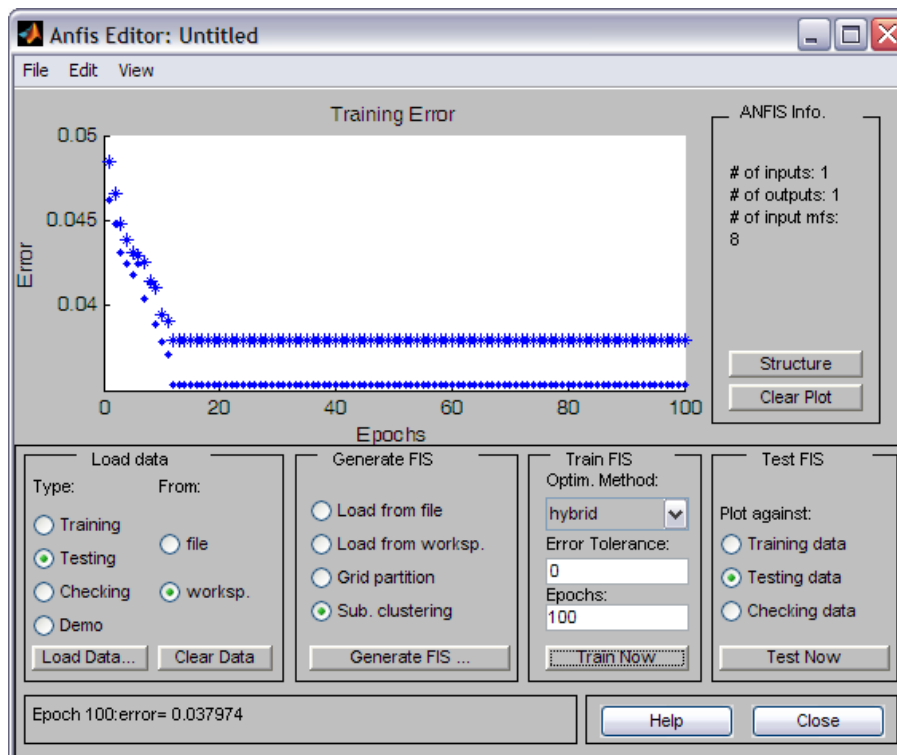


Figura E.14 Epochs Vs. Error de entrenamiento: SC. 8MF, ra=0.1

Paso5: finalmente se obtiene la salida FIS, para los datos de entrenamiento y verificación. Las figuras siguientes muestran la comparación entre la salida real en azul y la estimada por el ANFIS en rojo, para el conjunto de datos de entrenamiento y verificación: Métodos Grid partition (GP) y Sub. Clustering (SC)

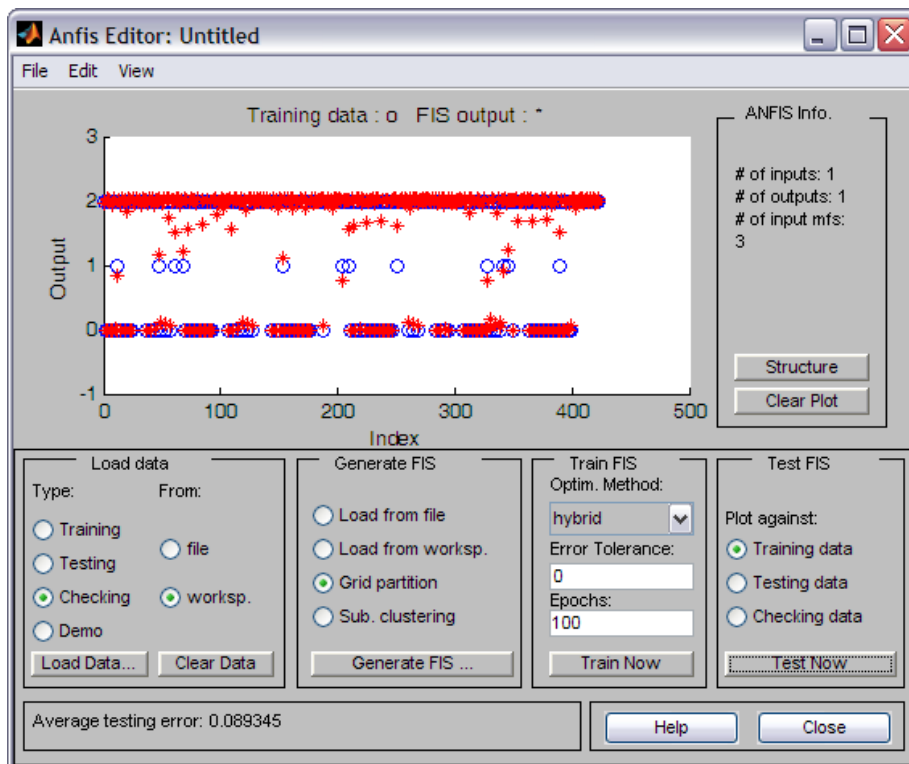


Figura E.15 Salida ANFIS para los datos de entrenamiento. Método GP

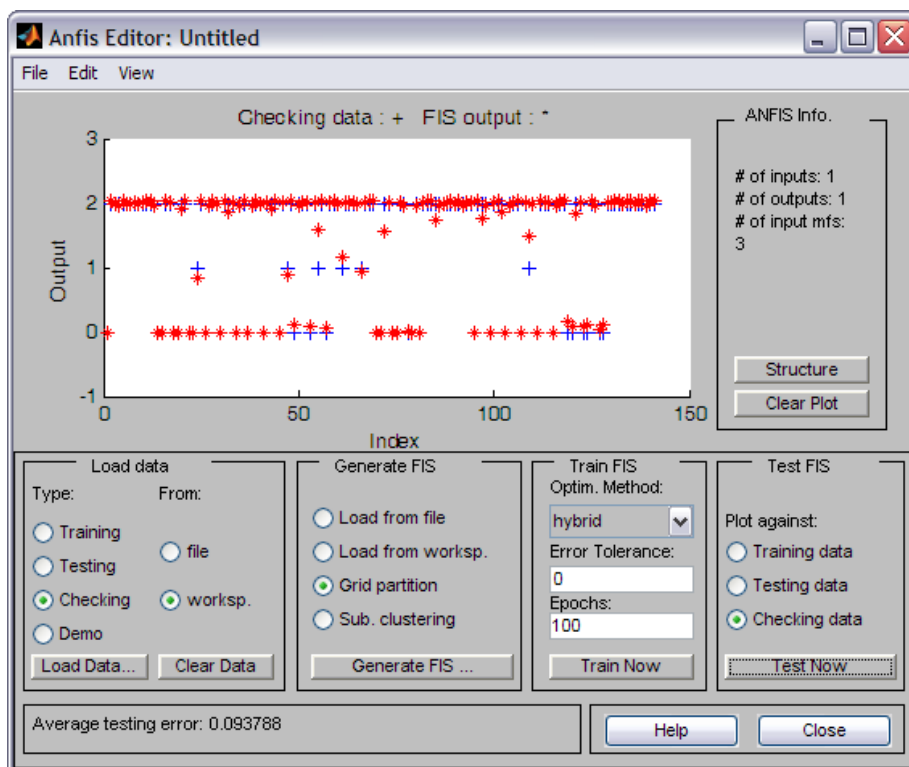


Figura E.16 Salida ANFIS para los datos de verificación. Método GP

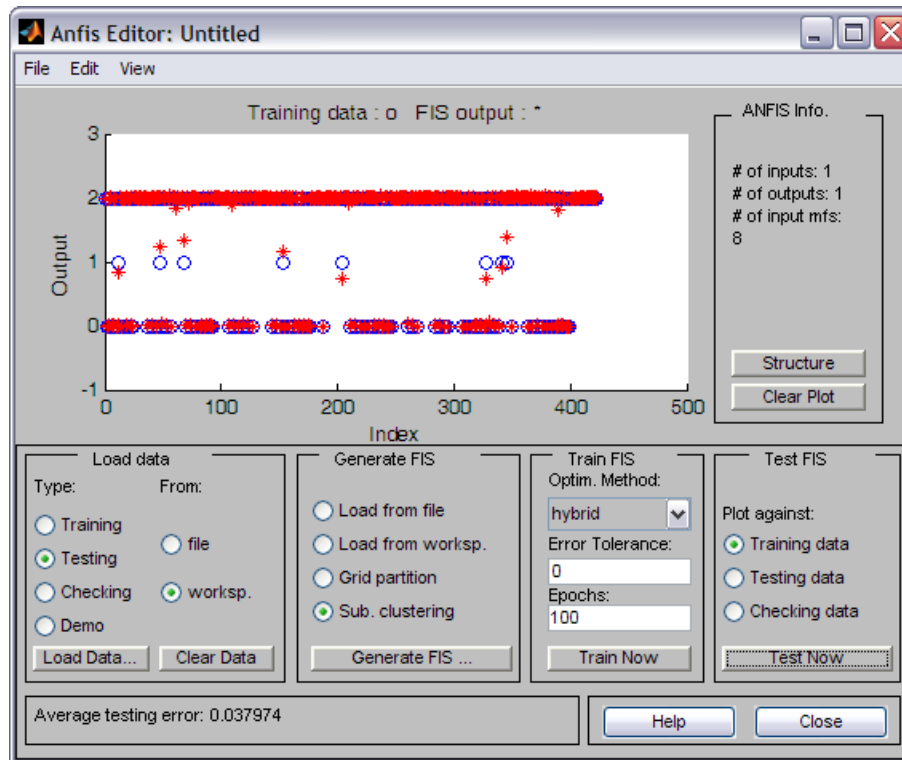


Figura E.17 Salida ANFIS para los datos de entrenamiento. Método SC

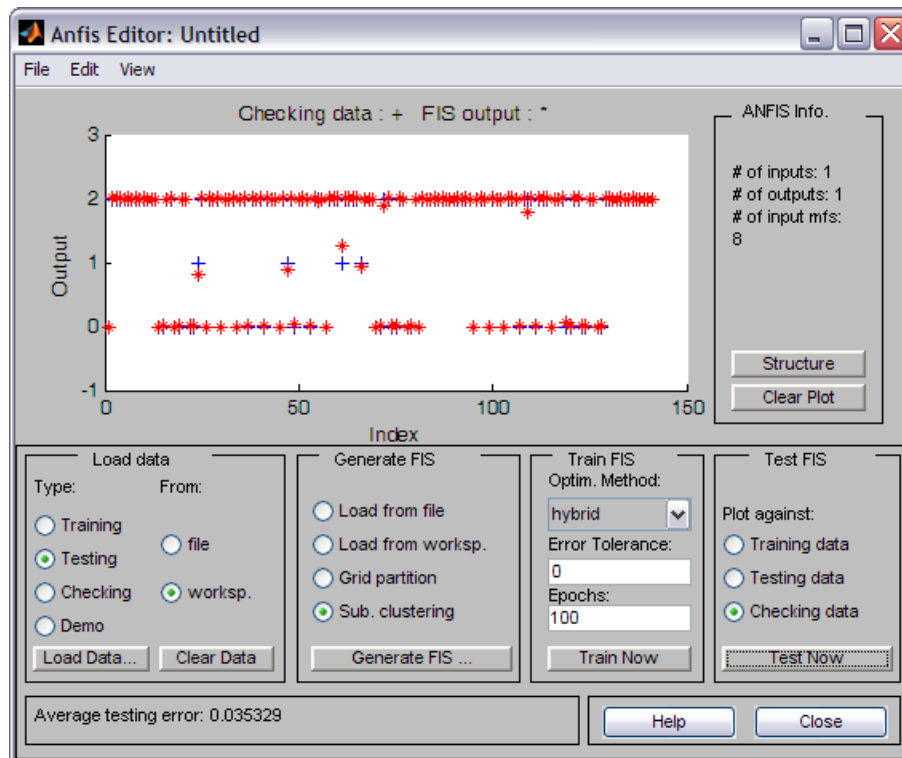


Figura E.18 Salida ANFIS para los datos de verificación. Método SC

Validación del modelo:

El proceso de validación se presenta a continuación.

Paso 1: Se cargan los datos para la validación:

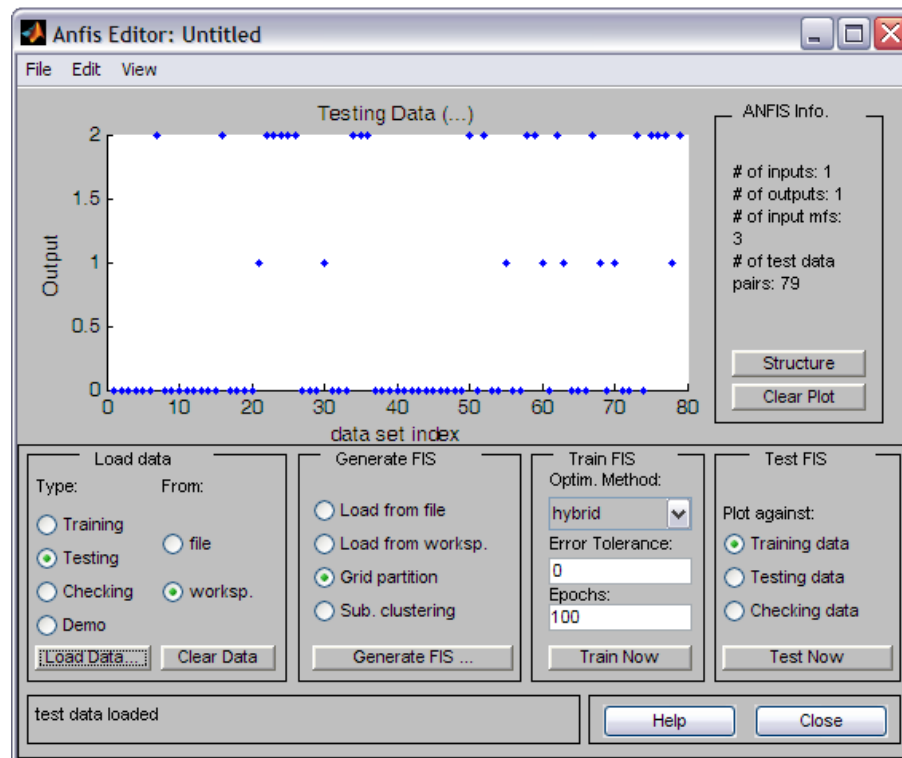


Figura E.19 Conjunto de datos para validación

Paso2: Con el mejor ANFIS obtenido en el proceso de entrenamiento, se procede a validar el modelo. Las graficas muestran las salidas del ANFIS, para el conjunto de datos de validación: En azul los datos de origen y en rojo, los datos estimados por el ANFIS

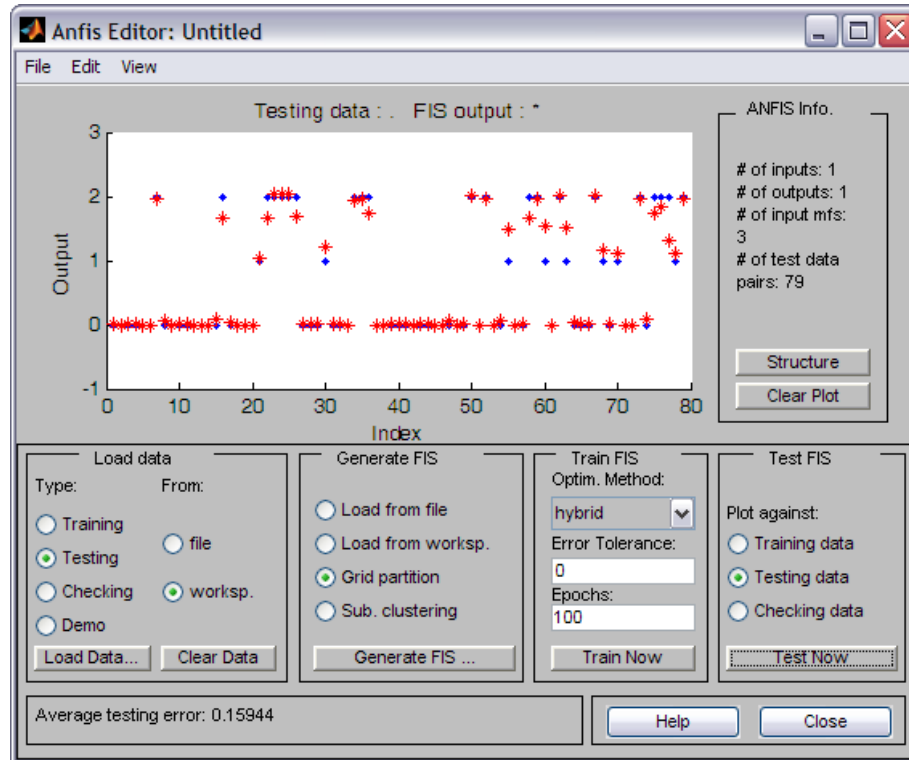


Figura E.20 Salida ANFIS para los datos de validación. Método GP

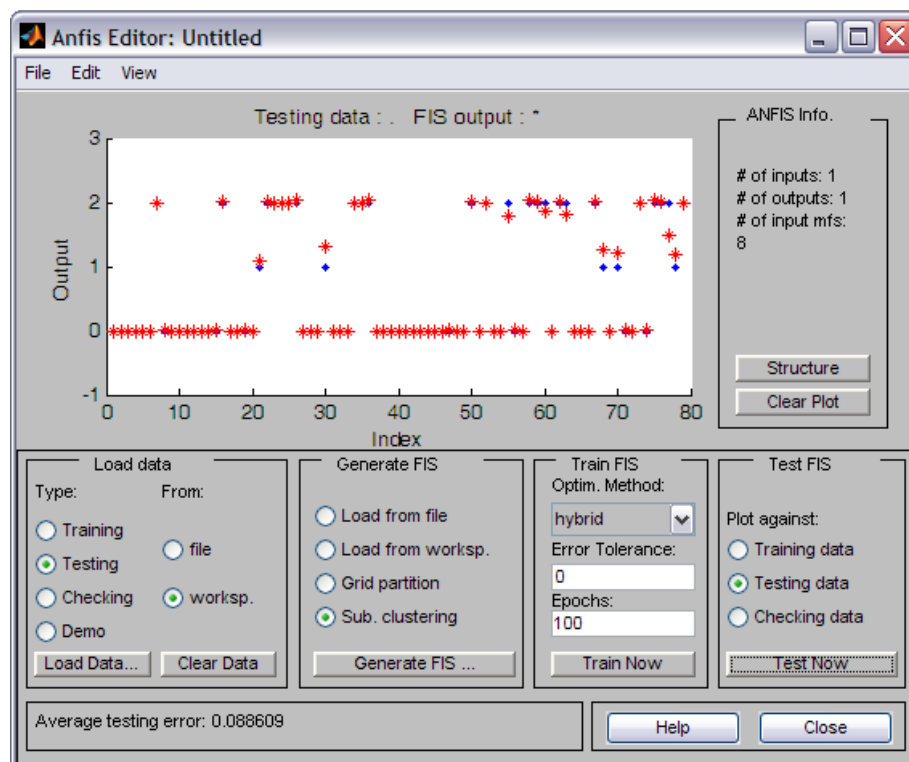


Figura E.21 Salida ANFIS para los datos de validación. Método SC