

Modelo Neuro Difuso para la Extracción de Características en Fallas Eléctricas dentro de Líneas de Transmisión

Neural Fuzzy Model for Features Extraction in Electric Fault within Transmission Lines

Julián Moreno, MSc.¹, Jhon A. Calderón, MSc.², Germán Zapata, PhD.¹

1.Universidad Nacional de Colombia - Sede Medellín

2.Interconexión Eléctrica S.A.

jmoreno1@unalmed.edu.co, jacalderon@isa.com.co, gzapata@unalmed.edu.co

Recibido para revisión 28 de Noviembre de 2007, aceptado 14 de Febrero de 2008, versión final 28 de Febrero de 2008

Resumen—El diagnóstico automático de fallas en sistemas eléctricos así como la extracción de sus características son unas tareas complejas, no solo por la cantidad de información involucrada que puede provenir de diversas fuentes como SOE, SCADA y registradores, si no también por la variabilidad presente en las fallas y por la cantidad y complejidad de características que deben analizarse. En este artículo se propone el uso de un modelo que comprende una red neuronal tipo *feed forward* cuya salida en vez de ser un valor crisp corresponde a valores de pertenencia de conjuntos difusos. Esto para la extracción de características de interés a partir de registros de osciloperturbografía provenientes de registradores de falla. La efectividad es probada para una amplia variedad de casos de entrenamiento y validación, los cuales son obtenidos por medio de un modelo de ATP.

Palabras Clave—Sistemas Inteligentes, Diagnóstico Automático de Fallas, Redes Neuronales, Lógica Difusa.

Abstract—The fault diagnostics in power systems as well as their features extraction are complex tasks, not only because of the amount of information which can come from different sources as SOE, SCADA and recorders, but also because of the variability of such faults and because of the quantity and complexity of the features that must be analyzed. In this paper we propose a model that includes a feed forward neural network whose output is not a crisp value but a fuzzy set membership value. This for interesting features extraction using osciloperturbography records. The model's fitness is tested for a wide variety of training and validation cases which are obtained with an ATP model.

Keywords—Intelligent Systems, Automatic Fault Diagnostics, Neural Networks, Fuzzy Logic.

I. INTRODUCCIÓN

Debido a la importancia que para un país tiene garantizar el correcto funcionamiento de las redes eléctricas, las empresas encargadas de la transmisión y distribución deben cumplir con una normatividad exigente respecto a estándares operativos y están constantemente bajo escrutinio por las entidades correspondientes. Para lidiar con estas exigencias, estas empresas cuentan con esquemas de protección que se encuentran instalados en las subestaciones y que deben actuar sobre los respectivos equipos de interrupción para aclarar fallas cuando éstas se presenten (en este contexto "aclarar la falla" se refiere a eliminarla abriendo la línea). Lo anterior produce un impacto sobre el sistema que debe ser analizado por los centros de control no solo con el fin de definir pautas adecuadas para su restablecimiento, si no también para determinar el estado de los activos y diagnosticar el funcionamiento de los equipos involucrados [1].

Para detectar este tipo de eventualidades y realizar los análisis respectivos, las empresas encargadas de la transmisión y distribución de electricidad disponen además de diversas herramientas que brindan información tanto analógica como digital. Entre estas fuentes se encuentra el SOE (Sequence of Events) que consiste en una bitácora de las señales producidas por los sistemas de protección; el SCADA que puede interpretarse como una base de datos donde se almacenan los estados de todos los equipos; los DFR (Digital Fault Records) que producen los registros en los que se reportan las corrientes, tensiones, y otras medidas de interés en una línea específica; entre otros [2].

De esta manera, al producirse una falla (y en especial una que involucre varias líneas) se produce una avalancha de información de estas fuentes hacia los centros de control donde los analistas tienen un tiempo determinado para tomar acciones que aseguren el correcto funcionamiento del sistema y para generar un reporte preliminar sobre la falla ocurrida.

Sin embargo, un aspecto fundamental a la hora de afrontar este problema es que ningún registro nuevo es igual a otro que haya ocurrido en el pasado, lo que hace que la clasificación de las fallas sea una tarea compleja, con el agravante que esto es tan solo una parte del diagnóstico que deben realizar los analistas, el cual debe complementarse con información de sus características como direccionalidad, causa probable, evolución del evento, operación de los sistemas de protección, localización, impedancia de la falla, impedancia de las fuentes, etc..

Como un apoyo a estas labores que son llevadas a cabo de manera empírica por los analistas de los centros de control, en este artículo se propone una herramienta para la extracción automática de algunas de estas características empleando únicamente la información de los registros de osciloperturbografía, y más específicamente los valores de las corrientes y voltajes para las tres fases medidas durante el evento.

El resto de este documento está organizado de la siguiente manera: En la siguiente sección se describe el modelo utilizado para obtener los datos de entrada con registros de osciloperturbografía, así como el preprocesamiento que debe llevarse a cabo sobre estos datos. En la sección III se explica la arquitectura del modelo propuesto para llevar a cabo la extracción de características de falla, y en la sección IV se muestran los resultados obtenidos mediante su entrenamiento y validación. Finalmente en la sección V se exponen algunas de las conclusiones obtenidas con este trabajo.

II. REGISTROS DE ENTRENAMIENTO

Con el fin de obtener una cantidad considerable de datos que correspondan a fallas de diversas características se diseñó un modelo en ATP (Alternative Transient Program) [3] para representar una línea de transmisión entre dos subestaciones. Como puede observarse en la Fig. 1 este modelo consta básicamente de dos fuentes con sus respectivos equivalentes de Thévenin que representan los aportes de cortocircuito, una línea de transmisión típica y resistencias para representar las impedancias de falla de cada una de las fases.

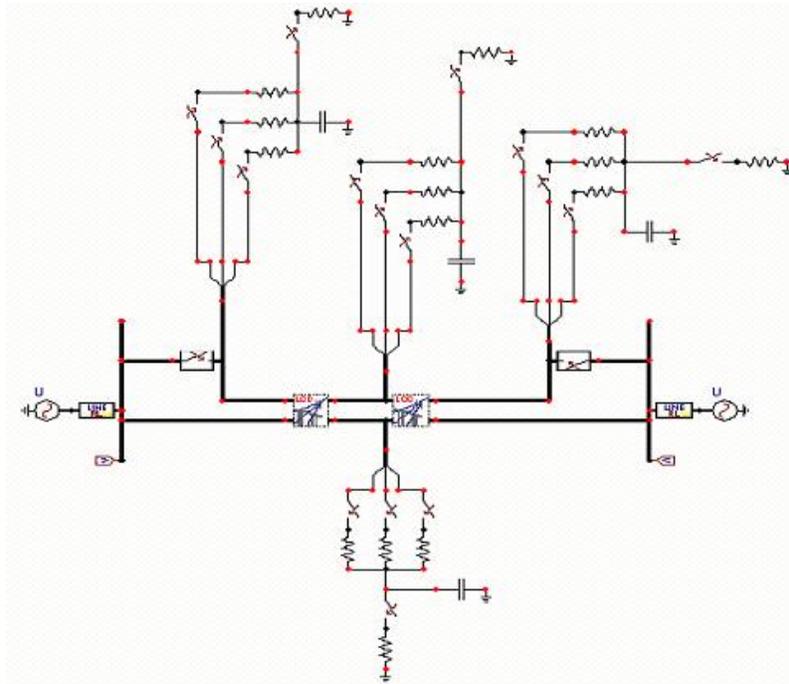


Fig. 1. Modelo ATP

Con el fin de llevar a cabo la exploración exhaustiva de casos en ATP se realizó un análisis de sensibilidad considerando un conjunto representativo de condiciones eléctricas esperadas en sistemas eléctricos de potencia realizando un análisis de sensibilidad con los siguientes parámetros: impedancia fuente tanto del extremo emisor como del extremo receptor, condiciones

de carga de la línea de transmisión en estado estacionario, longitud de la línea de transmisión, localización e impedancia de la falla. Por último se consideraron los tipos de falla típicos 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).

Como resultado este análisis de sensibilidad se generaron cerca de 10000 registros sintéticos que corresponden a la combinación de los posibles valores considerados para los 6 parámetros mencionados. Una vez obtenidos los registros, estos fueron preprocesados aplicando primero un filtrado analógico, luego un filtrado digital y finalmente un escalonamiento. El filtro analógico escogido fue el filtro análogo pasabajos del tipo Butterworth de orden 2 con frecuencia de corte de 360 Hz [4,5], el cual es adecuado para mitigar el efecto de aliasing en el muestreo de un registro de osciloperturbografía ya que presenta las menores oscilaciones y sobreimpulsos lo que implica un menor tiempo de retardo en la respuesta final del filtro. Por su parte el filtro digital elegido fue el de Fourier [6,7] siendo 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. Para el escalonamiento se adoptó un factor de escala de 1000 para los valores de corriente y de $230000/\sqrt{3}$ para los valores de voltajes.

III. MODELO HÍBRIDO

El modelo propuesto en este artículo puede considerarse como híbrido pues se compone de una red neuronal cuya entrada son las corrientes y tensiones de las fases A, B y C mas la

corriente de fase cero en valores RMS durante estado de falla (realizando previamente el preprocesamiento descrito en el numeral anterior) de un registro de osciloperturbografía, mientras que su salida es el grado de pertenencia de dicho registro a cada uno de los conjuntos difusos de una determinada característica de la falla. En este trabajo las características consideradas fueron la localización de la falla, su impedancia, la impedancia del nodo emisor, y la impedancia del nodo receptor. Otros trabajos en los que se emplean redes neuronales para el problema de fallas en redes eléctricas se pueden encontrar en [8].

Para cada una de estas cuatro características se definieron cinco conjuntos difusos que abarcan el universo del discurso considerado. Para la localización de la falla, su universo del discurso va de 0% (justo en el extremo donde se encuentra el registrador) hasta 100% (justo en el extremo opuesto), tal como se muestra en la Fig. 2. En este caso la unidad de medida es el porcentaje de la línea donde se ubica la falla, y los conjuntos definidos fueron: muy cercana, cercana, localización media, lejana y muy lejana. Así por ejemplo, para una línea de transmisión de 120 kms con una falla localizada a los 50 kms (aproximadamente en el 42%) se tendrían unos valores de pertenencia a los cinco conjuntos de 0, 0.18, 0.94, 0.01, 0.

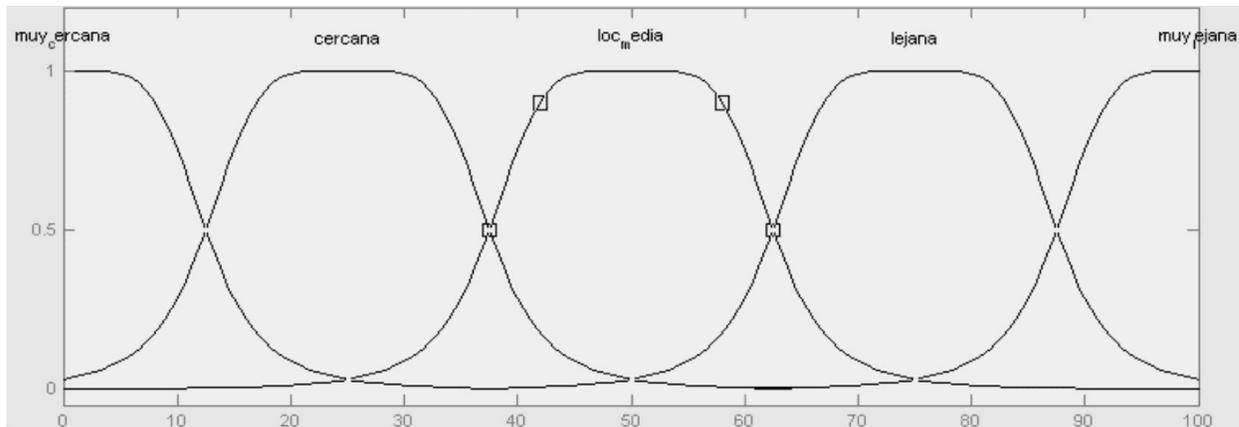


Fig. 2. Conjuntos difusos para la localización de falla

Para el caso de la impedancia de nodo (tanto emisor como receptor) los conjuntos definidos se muestran en la Fig. 3. En este caso se puede observar que, a diferencia de la localización de la falla en la que los conjuntos se definieron de manera homogénea, todos los conjuntos no tienen la misma forma y sus rangos no tienen la misma amplitud, buscando respetar la concentración de datos obtenidos con el modelo ATP y cuyos valores serían los que se esperarían en líneas típicas (al menos en el caso de las líneas estudiadas durante la realización de este trabajo). De esta manera, los conjuntos definidos a partir de los diagramas de frecuencia de los datos obtenidos fueron: sistema fuerte muy aterrizado, sistema fuerte aterrizado, sistema muy fuerte medianamente aterrizado, sistema débil aterrizado y sistema débil medianamente aterrizado. Así por ejemplo para una falla con una impedancia de nodo emisor de 210mhs se

tendrían unos valores de pertenencia a los cinco conjuntos de 0, 0, 0.07, 0.01, 0.24, 0.9.

Para el caso de la impedancia de falla, los conjuntos difusos definidos no se muestran en este artículo, pero la metodología para obtenerlos fue similar que para la impedancia de nodo.

Una vez definidos los conjuntos difusos se procedió a definir la arquitectura para las cuatro redes neuronales (una por cada característica), la cual se muestra en la Fig. 4. Se trata de una red tipo feed forward back propagation con siete neuronas en la capa de entrada que corresponden a las corrientes y tensiones de tres fases A, B y C mas la corriente de fase cero y cinco neuronas en la capa de salida que corresponden a los grados de pertenencia de los cinco conjuntos difusos de cada característica. Para la capa oculta se realizó un análisis de prueba

y error y se determinó que un número apropiado de neuronas en esta capa para todos los casos es doce. La función de

activación elegida para la capa oculta fue la sigmoidea tangente y la de la capa de salida la función lineal.

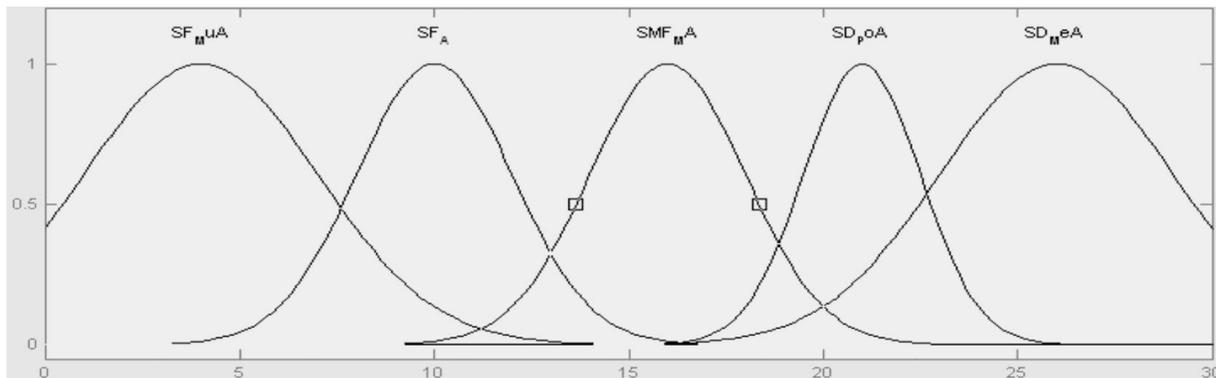


Fig. 3. Conjuntos difusos para la impedancia de fuente

Para el entrenamiento de la red se probaron distintos algoritmos típicos en la literatura como los basados en el gradiente descendente del error [9,10] y el de regularización bayesiana [11], siendo este último el que presentó mejores resultados.

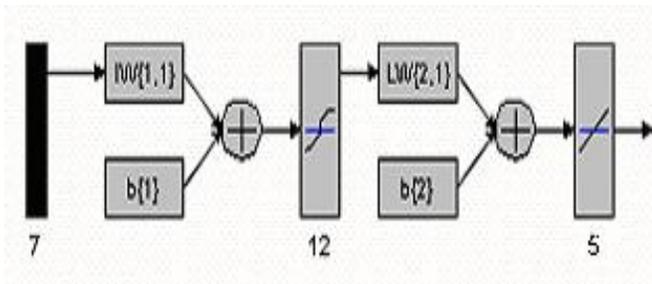


Fig. 4. Arquitectura de la red neuronal

Una vez definidas las redes se procedió a calcular sus parámetros mediante un proceso iterativo en el cual se crearon redes con parámetros iniciales (matrices de pesos) diferentes y se calibraron hasta que el algoritmo de entrenamiento se detuviera. De esta manera al final del proceso se obtuvieron las mejores redes de N calibraciones. El pseudocódigo junto con código de MATLAB del algoritmo implementado para calibrar cada una de las cuatro redes se presenta a continuación. Cabe señalar que el valor de N utilizado fue de 50, pero no se almacenaron los resultados de cada uno, sólo de la mejor.

```
Leer P y T //patrones entrada-salida
preprocesaados

Fuzzyficar T

Dividir P y T en Pe, Pv, Pc, Te, Tv, Tc //
conjuntos de patrones entrada-salida para
entrenamiento, validación y chequeo

val.P = Pv
val.T = Tv
test.P = Pc
test.T = Tc

Para i de 1 a N
```

```
net = newff(minmax(Pe),[12 5],{'tansig'
'purelin'},'trainbr')
trained_net =
train(net,Pe,Te,[],[],val,test)

Salida_entrenamiento = sim(trained_net,Pe)
Salida_validacion = sim(trained_net,Pv)
Salida_chequeo = sim(trained_net,Pc)

error_entrenamiento = ||Salida_entrenamiento-
Te||
error_validacion = ||Salida_validacion-Tv||
error_chequeo = ||Salida_chequeo-Tc||

error_total = error_entrenamiento* +
error_validacion* + error_chequeo* $\alpha$ ;

Si (error_total <  $\beta$  menor_error_total)
menor_error_total = error_total;
mejor_red = trained_net;
```

Los conjuntos de entrenamiento, validación y chequeo se obtuvieron a partir de los cerca de 10000 casos generados con el modelo descrito en el numeral II siguiendo el siguiente criterio: 4 de cada 5 casos (80%) se utilizaron para el entrenamiento, mientras que el 20% restante se repartió de manera intercalada para la validación y el chequeo.

La función *Fuzzyficar* se encarga de convertir los valores crisp de los patrones de salida en valores de pertenencia de los conjuntos difusos correspondientes.

Los parámetros α , β , γ sirven para ponderar los tres errores medios de manera que se le pueda dar prioridad al ajuste de la red (cercano a uno y β , γ cercanos a cero) o a la generalización (α cercano a cero y $\beta + \gamma$ cercanos a uno). Para las corridas realizadas en este trabajo se utilizaron valores de 0.2, 0.4 y 0.4 respectivamente.

IV. RESULTADOS OBTENIDOS

La evolución del entrenamiento de la red para el caso de la localización de la falla y la impedancia del nodo emisor se presentan en las Fig. 5 y 6, mientras que los errores obtenidos luego de calibrar las cuatro redes se muestran en la Tabla 1.

El error difuso al que hace referencia esta tabla es medido de la misma manera que en el algoritmo descrito en el numeral anterior, es decir, como la distancia media entre los valores de pertenencia de las salidas de la red y las salidas de entrenamiento como se muestra a continuación (recordando que tales salidas se componen por los cinco valores de pertenencia).

$$\text{error_difuso_Loc} = \text{mean}(\text{mean}(\text{abs}(\text{Salida_Loc} - \text{conjuntos_difusos.mLoc})))$$

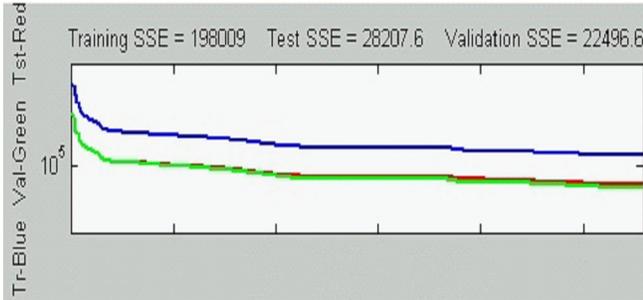


Fig. 5. Resultados de entrenamiento red localización de falla

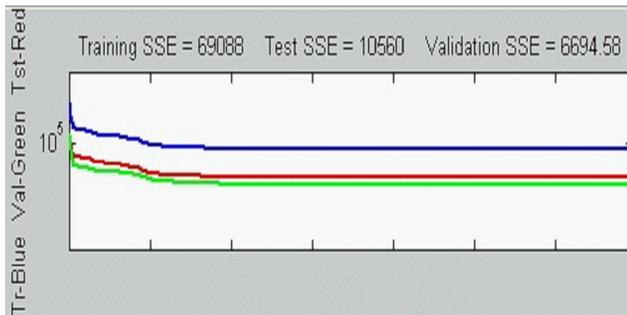


Fig. 6. Resultados de entrenamiento red impedancia nodo emisor

Este error significa por ejemplo que si la salida de la red para un registro determinado indica que la localización de la falla es en mayor medida "cercana" (entendiendo este concepto dentro del contexto de los conjuntos difusos), lo más probable es que en la realidad así lo sea, pero teniendo en cuenta una desviación promedio de 0.1048 en ese valor de pertenencia.

TABLA I
ERRORES FINALES OBTENIDOS

	Error difuso	Error crisp
Localización falla	0.1048	0.1777
Impedancia falla	0.1039	0.1655
Impedancia emisor	0.1586	0.1213
Impudencia receptor	0.2125	0.1592

Por su parte el error crisp se refiere al error medio porcentual entre las salidas crisp de la red y las salidas crisp de entrenamiento como se muestra a continuación.

$$\text{error_crisp_Loc} = \text{mean}(\text{abs}(\text{Salida_Loc_Crisp} - \text{Loc}) / \text{Loc})$$

Este error significa por ejemplo, que el modelo implementado tiene un error promedio de 17.77% en la estimación de la localización de la falla y de 12.13% en la estimación de la impedancia del nodo emisor. Por último, los gráficos completos de las salidas de la red versus las salidas reales para el caso de la localización de la falla y la impedancia del nodo emisor se presentan en las Fig. 7 y 8.

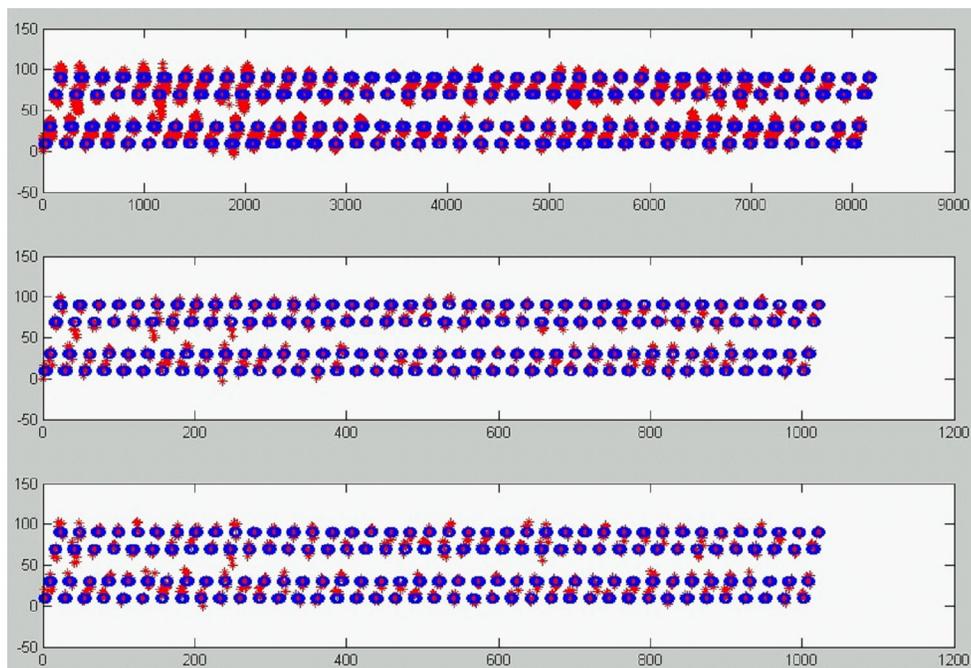


Fig. 7. Targets vs. Salida del modelo red localización de falla

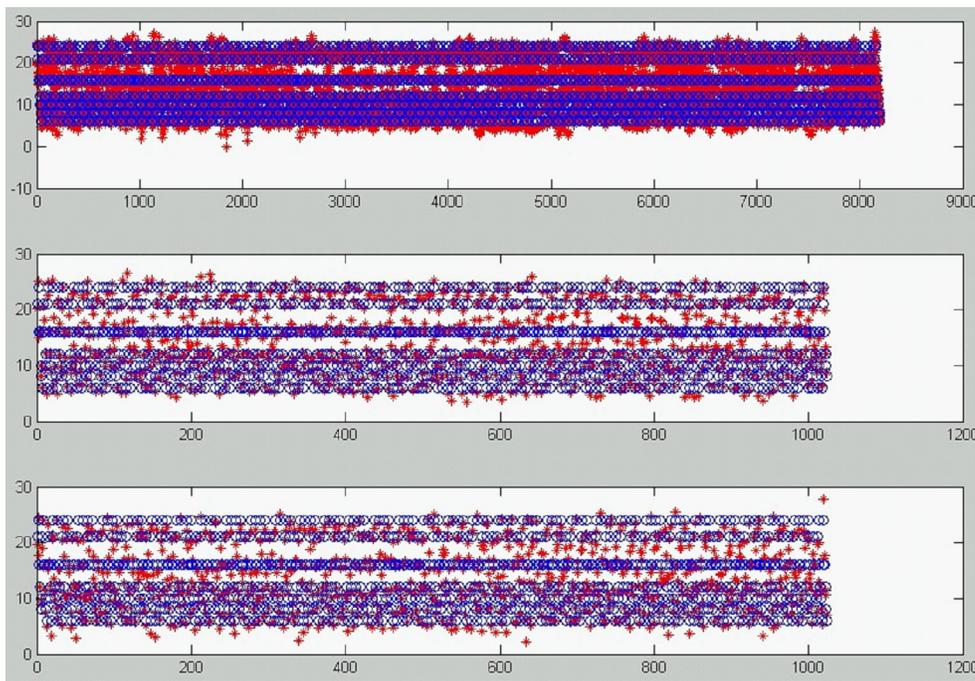


Fig. 8. Targets vs. Salida del modelo red impedancia nodo emisor

Estos últimos dos gráficos se componen de tres partes. En la parte superior se muestran los patrones de entrenamiento, en la del medio los de validación y en la inferior los de chequeo. En los tres casos los círculos en azul representan los valores reales, mientras que las cruces en rojo representan las salidas de la red.

V. CONCLUSIONES

El modelo propuesto en este artículo para la extracción de características en fallas eléctricas dentro de líneas de transmisión consiste en una red neuronal tipo *feed forward* cuya entrada son las corrientes y tensiones de las fases A, B y C mas la corriente de fase cero en valores RMS durante estado de falla, mientras que la salida, y he aquí el enfoque novedoso de esta propuesta, son grados de pertenencia para los conjuntos difusos de la característica correspondiente.

Si bien de los resultados puede observarse que los errores medios porcentuales obtenidos al defuzzyficar las salidas son superiores a 10% (específicamente entre el 12 y el 18%) para las cuatro características analizadas, el modelo propuesto demostró tener potencial dentro de la problemática estudiada en la medida que puede brindar un buen análisis preliminar que sirva de punto inicial para los analistas de los centros de control. Por esta razón, y como trabajo futuro, es necesario continuar trabajando en el tema con el fin de alcanzar una herramienta más robusta y precisa, explorando otros algoritmos de entrenamiento de la red y aumentando considerablemente el número de patrones de entrenamiento.

Como una conclusión adicional cabe señalar que en procesos como el descrito en este trabajo en el que se necesita calibrar modelos cuya complejidad computacional es relativamente alta

y consumen bastantes recursos de memoria y tiempo de procesamiento, se recomienda llevar a cabo un proceso iterativo que determine los mejores parámetros obtenidos para un número considerable de intentos para no sacrificar precisión a costas del rendimiento.

RECONOCIMIENTOS

Este trabajo presenta los resultados de la investigación realizada por la Universidad Nacional de Colombia - Sede Medellín e Interconexión Eléctrica S.A. - ISA, como parte del desarrollo del proyecto de investigación "Herramientas informáticas para el diagnóstico automático de eventos en líneas de transmisión de energía eléctrica" cofinanciado por Colciencias.

REFERENCIAS

- [1] J. Calderon. "Modelo adaptativo de inteligencia artificial para diagnóstico automático de fallas a partir de registros de osciloperturbografía". Tesis de Maestría. Universidad Nacional. 2007.
- [2] L. Llano. "Diagnóstico automático de eventos en tiempo real en un sistema de transporte de energía a través del SOE y SCADA usando técnicas de inteligencia artificial". Tesis de Maestría. Universidad Nacional. 2007.
- [3] Canadian/American Emtp User Group. Alternative Transients Program (ATP) - Rule Book. 1992.
- [4] A. Albardar. "Procesamiento de señales analógicas y digitales", Segunda Edición, Ed. Thomson Learning, México D.F, 2002.
- [5] I. Díaz, J. Altuve y E. Vásquez. "Estudio comparativo de filtros analógicos pasabajos para relevadores digitales de distancia". VIII Reunión de Verano de Potencia del IEEE Sección México, Acapulco, Gro., Julio de 1995.
- [6] S. Mitra. "Digital Signal Processing. A Computer-Based Approach". Second Edition, Mc. Graw Hill, New York, 1998.

- [7] S. Mitra. "Digital Signal Processing Laboratory Using MATLAB" Mc. Graw Hill, New York, 1999.
- [8] Y. Song, Q. Xuan and A. Johns. "Comparison studies of five neural network based fault classifiers for complex transmission lines". Electrical Power and Energy Systems. Elsevier. 43. 1997, pp. 125-132
- [9] M. Hagan, H. Demuth and M. Beale. "Neural Network Design". Boston, MA: PWS Publishing, 1996.
- [10] N. Kasabov. "Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering". The MIT Press. 1998.
- [11] F. Foresee and M. Hagan. "Gauss-Newton approximation to Bayesian regularization," Proceedings of the 1997 International Joint Conference on Neural Networks, 1997, pp. 1930-1935.

Julián Moreno C. Es profesor auxiliar, Universidad Nacional de Colombia - Sede Medellín e Ingeniero de Sistemas e Informática (2004). Magíster en Ingeniería de Sistemas (2007). Integrante de GIDIA: Grupo de Investigación y Desarrollo en Inteligencia Artificial, Categoría A de Colciencias. El área de énfasis de su investigación es la Inteligencia Artificial aplicada a diversos problemas de la industria. Más específicamente ha trabajado en sistemas híbridos que integran Sistemas Expertos, Sistemas Neuro-Difusos, Sistemas Multi-Agente y otras herramientas para el apoyo a la toma de decisiones en áreas como los Mercados de Energía, la Detección de Fallas en Líneas de Transmisión, así como en diversas aplicaciones de simulación y pronóstico.

Jhon Albeiro Calderón S. Ingeniero Electricista de la Universidad Nacional de Colombia en el año 1988. Magíster en Ingeniería de Sistemas, Universidad Nacional de Colombia - Sede Medellín (2007). Entre 1989-1993 trabajó como Ingeniero de diseño en la firma consultora Ingeniería Especializada Blandón S.A. Desde 1993 se encuentra vinculado a Interconexión Eléctrica S.A. donde se ha desempeñado como Ingeniero del Centro Nacional de Despacho (CND), Analista Postoperativo, Ingeniero de Evaluación Integral de la inversión y Especialista de Operación. En varias ocasiones ha ejercido el rol de coordinador del Equipo Estudios de Operación en la Dirección Gestión Red de ISA.

Germán Zapata M. Profesor Asistente, Universidad Nacional de Colombia - Sede Medellín. Director de la Escuela de Ingeniería Eléctrica y Mecánica. Integrante de GAUNAL: Grupo de Automática de la Universidad Nacional de Colombia, Categoría A de Conciencias. Ingeniero Electricista de la Universidad Nacional de Colombia (1991). Especialista en Gerencia de la Calidad de la Universidad de Antioquia (1997). Magíster en Automática de la Universidad del Valle (2004).

Cisco Academy Training Center - National University of Colombia

[Presentation and history]

IT Essentials

IT Essentials I: PC Hardware and Software
IT Essentials II: Network Operating Systems

Cisco Certified Network Associate

CCNA 1: Network Fundamentals
CCNA 2: Routing Protocols and Concepts
CCNA 3: LAN Switching and Wireless
CCNA 4: Accessing the WAN

Cisco Certified Network Professional

CCNP Building Scalable Internetworks
CCNP Implementing Secure Converged Wide Area Networks
CCNP Building Multilayer Switched Networks
CCNP Optimizing Converged Networks

Network Security

Fundamentals of Wireless LANs

Telephony over IP

Voice over IP



Contact

Faculty of Minas. Carrera 80 65-223 BI M3-211
Web site: <http://cnap.unalmed.edu.co>
E-mail: catc@unalmed.edu.co
Phone: +574 4255268
Fax: +574 2341002
Medellin, Colombia