

Algoritmo Neuro-Difuso para la Detección y Clasificación de Fallas en Líneas de Transmisión Eléctrica Usando ANFIS

Fuzzy Neural Algorithm for Faults Detection and Classification in Electric Transmission Lines Using ANFIS

Jhon A. Calderón, MSc (c)¹, Germán Zapata M. MSc² y Demetrio A. Ovalle C. PhD³.

1. ISA: Interconexión Eléctrica S.A., Especialista de Operación – Dirección Gestión Red
2. GAUNAL: Grupo de Automática de la Universidad Nacional de Colombia, Escuela de Ingeniería Eléctrica, Facultad de Minas, Universidad Nacional de Colombia sede Medellín
3. GIDIA: Grupo de Investigación y Desarrollo en Inteligencia Artificial, Escuela de Ingeniería de Sistemas, Facultad de Minas, Universidad Nacional de Colombia sede Medellín
jacalderon@isa.com.co, gdzapata@unal.edu.co, dovalle@unal.edu.co

Recibido para revisión 26 de Marzo de 2007, aceptado 15 de Junio de 2007, versión final 21 de junio de 2007

Resumen— La detección y clasificación de las fallas en líneas de transmisión es de vital importancia. En un sistema eléctrico de potencia se presenta una gran diversidad de fallas que van desde fallas de baja impedancia (LIFs) a fallas de alta impedancia (HIFs). Estas últimas revisten una especial dificultad para ser detectadas por los relés de distancia convencionales y cuando no son detectadas se suelen presentar consecuencias desastrosas para el sistema. De lo anterior se desprende entonces, que aun cuando las HIFs son menos comunes que las LIFs, resulta fundamental garantizar que cualquier dispositivo de protección sea capaz de detectar satisfactoriamente ambos tipos de fallas.

En este artículo se presenta un algoritmo para la detección y clasificación de fallas para ambos tipos de fallas LIFs y HIFs usando ANFIS (Adaptive Network-based Fuzzy Inference System). Las entradas al ANFIS se basan solamente en los valores RMS (Root-Mean-Square) 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 incluyendo (LIFs y HIFs) dentro de un tiempo de medio ciclo.

Palabras Clave— Algoritmos Neuro-difusos, Detección y Clasificación de fallas: LIFs, HIFs, ANFIS (Adaptive Network-based Fuzzy Inference System).

Abstract— The detection and classification of faults in electric transmission lines is an essential task to be performed. Within an electric power system a diversity of faults which come from

low impedance faults (LIFs) to high impedance faults (HIFs) are exhibited. Last faults are more difficult to be detected due to the use of conventional distance relays. In addition, when they are not detected irreversible consequences are presented into the system. From above, it is inferred that taking into account that HIFs are less frequent than LIFs it appears essential to guaranty that any protection device must be able to satisfactorily detect both kind of electric faults.

The aim of this paper is to present an algorithm to detect and classify both kind of faults LIFs and HIFs using ANFIS (Adaptive Network-based Fuzzy Inference System). The inputs for ANFIS are based on RMS (Root-Mean-Square) values from 3-phase and zero-sequence current. The obtained results show that an ANFIS model can detect and classify faults in a precise way including (LIFs y HIFs) in between a half cycle time.

Keywords— Fuzzy Neural Algorithm, Faults Detection and Classification: LIFs, HIFs, ANFIS (Adaptive Network-based Fuzzy Inference System).

I. INTRODUCCIÓN

Debido al incremento de la complejidad de los sistemas de potencia y a las exigencias cada vez más estrictas impuestas por los marcos regulatorios que rigen su operación, los relés analógicos convencionales se ven limitados para responder adecuadamente ante estos requerimientos exigidos. Como consecuencia de todo este proceso de transformación se

ha acelerado en la última década la tecnología de relés digitales multifuncionales (que incorporan diversas funciones de protección y control dentro del mismo relé: distancia, sobrecorriente, falla interruptor, recierre entre otras) que utilizan las bondades del procesamiento digital de señales (DSP) para mejorar el desempeño de los sistemas de protección en velocidad y precisión [1][2]. No obstante, a pesar del gran avance que se ha tenido al respecto, se continúan presentando dificultades para la adecuada detección y clasificación de cierto tipo de fallas. Ello ha dado origen a un amplio campo de investigación en la búsqueda de algoritmos cada vez mas elaborados para intentar dar solución a estas dificultades.

Muchos investigadores han estudiado la aplicación de redes neuronales para tratar de solucionar varios de los problemas relacionados con la detección y clasificación de fallas en los sistemas eléctricos de potencia [3-18].

Jang y Sun introdujeron el sistema de inferencia difuso basado en redes adaptativas ANFIS (Adaptive Network-based Fuzzy Inference System). Este sistema hace uso de una regla de aprendizaje híbrida para optimizar los parámetros del sistema Sugeno de primer orden [19,20]. Está compuesto de cinco capas. Cada capa es el componente del sistema de inferencia difuso y desarrolla diferentes acciones.

Los parámetros de premisa y consecuentes se sintonizan apropiadamente utilizando el método de retropropagación (BP).

En la actualidad se encuentra en su fase inicial de desarrollo el proyecto de investigación ISA-Colciencias-Universidad Nacional de Colombia-Sede Medellín: "Herramientas informáticas para el diagnóstico automático de eventos en líneas de transmisión de energía eléctrica". Como parte de este proyecto se encuentran en evaluación diversos modelos para la detección y clasificación de fallas en sistemas eléctricos de potencia.

En este artículo se desarrolla un algoritmo de clasificación usando ANFIS y se aplica a un sistema eléctrico de potencia típico de 230 kV con línea de transmisión de doble circuito para validar su desempeño.

II. ALGORITMO DE CLASIFICACION DE FALLAS

A continuación se presentan algunas generalidades del modelo utilizado para el SEP (Sistema Eléctrico de Potencia) y del modelo ANFIS para luego describir en detalle las cinco capas que componen el algoritmo de clasificación.

A. Modelo del SEP para generación de los patrones de Entrenamiento, Validación y Chequeo

el fin de obtener los patrones de entrenamiento, validación y chequeo de las señales de corrientes de fase y de secuencia cero se utilizó la herramienta de simulación ATP (Alternative Transient Program) la cual ha sido validada a nivel mundial como una de las más adecuadas para analizar sistemas eléctricos de potencia [21,22].

En la Figura 1 se ilustra el sistema eléctrico utilizado para

la exploración sistemática de las condiciones de falla consideradas.

Con el fin de generar automáticamente el archivo de datos con los casos de ATP teniendo en cuenta la variabilidad de las condiciones del SEP se desarrolló un módulo en MATLAB que construye el formato ATP para el análisis de sensibilidad

Figura 1. Circuito Eléctrico Típico para analizar condiciones de falla en un SEP

B. Algoritmo de Clasificación de fallas.

En la Figura 2 se ilustra el algoritmo de clasificación de fallas propuesto en el presente artículo. Como se observa, se desarrolló utilizando ANFIS y las características de la falla (corrientes de fase RMS y corriente de secuencia cero).

El algoritmo se compone de tres pasos básicos:

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

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 la presencia de falla y su correspondiente tipo de falla (HIF ó LIF).

En la Figura 2 se muestra, además, la arquitectura adoptada para el modelo ANFIS, la cual consiste de cinco capas.

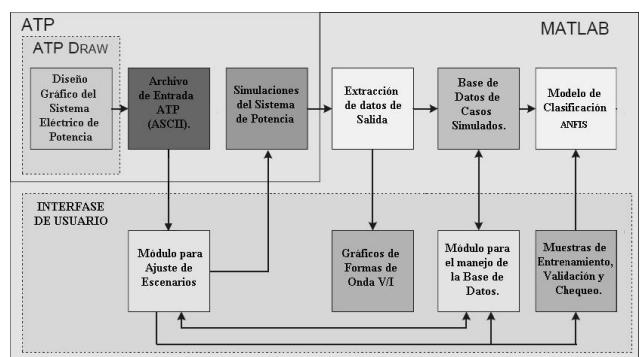


Figura 2. Herramientas de Software Integradas para la simulación del Sistema Eléctrico de Potencia mediante ATP y MATLAB

Se consideraron las siguientes tres reglas para la inferencia difusa de acuerdo con [1]:

Regla 1:

Si x es A_1 Entonces $f_1 = p_1x + r_1$.

Regla 2:

Si x es A_2 Entonces $f_2 = p_2x + r_2$.

Regla 3:

Si x es A_3 Entonces $f_3 = p_3x + r_3$.

Las diferentes capas se pueden describir de la siguiente forma:

Capa 1. Fuzzificación (pertenencia): se seleccionó una función Bell generalizada luego de efectuarse un análisis de sensibilidad de agrupamiento sustractivo (mediante la función subclust de MATLAB) del cual se pudo determinar que la función Bell se adapta adecuadamente al universo de entrada considerado.

En MATLAB la función de pertenencia Bell generalizada se especifica de la siguiente manera:

$GBELLMF(X, [A, B, C]) = 1./((1+ABS((X-C)/A))^{(2*B)})$;

Los parámetros A, B y C determinan la forma y posición de la función de pertenencia.

X representa los valores RMS de las corrientes de fase y corriente de secuencia cero para el algoritmo propuesto, y, las funciones de pertenencia utilizadas en ANFIS se ilustran en la Figura 3 y Figura 4.

Figura 3. Función de pertenencia utilizada para la entrada de corriente de fase.

Figura 4. Función de pertenencia utilizada para la entrada de corriente de secuencia cero.

Figura 5. Diagrama del algoritmo de clasificación y de la arquitectura ANFIS utilizada.

Capa 2. Conjunción: Cada nodo en esta capa multiplica las señales que entran cuando se trata de entradas múltiples. Sin embargo, dado que solamente se está considerando una sola entrada para el algoritmo propuesto entonces no se requiere realizar la multiplicación.

$$O_2, i = O_1, i \quad i = 1, 2, 3.$$

Capa 3. Normalización: Esta arquitectura tiene tres reglas. Cada nodo en esta capa calcula la relación del peso de encendido de la i -ésima regla a la suma de todos los pesos de encendido de las reglas:

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

Donde O_3 es la salida de la capa 3 y $\{p_i, r_i\}$ es el conjunto de parámetros.

Capa 5. Agregación: El único nodo de esta capa calcula la salida total como la suma de todas las señales que entran a este nodo.

El algoritmo desarrollado consiste de cuatro ANFIS para las corrientes de fase ‘a’, ‘b’, ‘c’ y corriente de secuencia cero, respectivamente. Las entradas a la 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).

Tabla 1. Definición de Las Salidas de Las Anfis de acuerdo con el tipo de falla

Tipo de Falla	SALIDA ANFIS			
	Ia	Ib	Ic	Io
SLGa	2	0	0	2
SLGb	0	2	0	2
SLGc	0	0	2	2
DLGab	2	2	0	2
DLGbc	0	2	2	2
DLGca	2	0	2	2
LLab	2	2	0	0
LLbc	0	2	2	0
LLca	2	0	2	0
3oGabc	2	2	2	0
HIFa	1	0	0	1
HIFb	0	1	0	1
HIFc	0	0	1	1
Sin talla	0	0	0	0

III. SIMULACIONES Y RESULTADOS

En la presente sección se describirá la metodología utilizada para el entrenamiento, validación y chequeo del modelo ANFIS para clasificación de fallas y se presentarán algunos de los resultados obtenidos de las simulaciones realizadas.

El desempeño del algoritmo analizado se prueba con valores de un sistema de transmisión típico de 230 kV considerando varios escenarios de condiciones de falla.

Con el fin de llevar a cabo la exploración exhaustiva de casos en ATP se debe realizar un análisis de sensibilidad que permita recorrer un conjunto representativo de condiciones eléctricas esperadas en cualquier SEP del mundo. Para ello, se lleva a cabo la siguiente exploración sistemática de posibilidades:

A. Variabilidad del valor de la impedancia fuente tanto del extremo emisor como del extremo receptor.

En este punto, se consideraron dos condiciones extremas: un sistema fuerte (nivel de cortocircuito del orden de 50 kA) y un sistema débil (inferiores a 1 kA).

B. Variabilidad de las condiciones de carga de la 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 este caso de estudio se consideró una condición de carga mínima (inferior a los 10 grados).

C. Variabilidad de la longitud de la línea de transmisión.

Para el presente caso de estudio se consideró una sola longitud de línea de 100 km.

D. Variabilidad de la localización de la falla.

Se consideraron cinco tipos de ubicación de la falla de acuerdo con el grado de cercanía al extremo emisor: Muy cercanas (ubicación de la falla por debajo del 10% de la longitud de la línea), Cercanas (fallas ubicadas entre el 10% y el 30% de la línea), Medianamente cercanas (fallas ubicadas entre el 30% y el 50% de la longitud de la línea), Lejanas (fallas ubicadas entre el 50% y el 80% de la longitud de la línea) y Muy lejanas (fallas ubicadas mas allá del 80% de la longitud de la línea).

E. Variabilidad de la impedancia de la falla.

Se consideraron tres tipos de valores para representar la impedancia de falla: Falla de alta impedancia (valor de impedancia de falla entre 50 ohmios y 100 ohmios), mediana impedancia (valor de impedancia de falla entre los 10 ohmios y los 30 ohmios) y baja impedancia (valores de impedancia de falla inferiores a los 10 ohmios).

F. Variabilidad del tipo de falla.

Se consideraron los tipos de falla típicos en los sistemas de transmisión de energía a nivel mundial, a saber: 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).

Teniendo en cuenta la sensibilidad anterior, mediante la interfaz MATLAB-ATP descrita en el numeral II se simularon 508 patrones para entrenamiento y 246 patrones para validación y chequeo. Estos casos de validación y chequeo se simularon como condiciones intermedias de los patrones de entrenamiento con el fin de verificar que no haya sobreentrenamiento (etapa de validación) y la capacidad de generalización del modelo (etapa de chequeo).

El procedimiento de entrenamiento, validación y chequeo del modelo se llevó a cabo mediante la GUI disponible en MATLAB para el análisis de sistemas ANFIS.

En la Figura 6 se ilustra una gráfica del número de iteraciones (EPOCHS) vs el Error de entrenamiento para las 508 muestras de entrenamiento de la corriente de la fase A. Para las demás fases se obtiene un resultado similar. Para el presente caso de estudio, se logra un error de entrenamiento de 0.031847 justo antes de las 250 iteraciones.

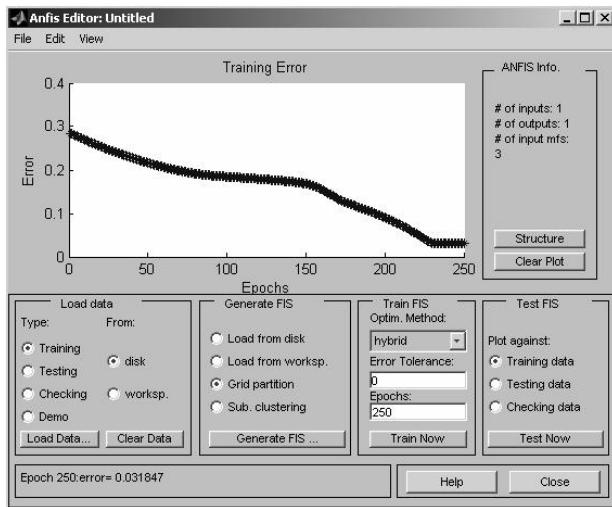


Figura 6. EPOCHS vs error de entrenamiento para las 508 muestras de la corriente de la fase A.

En la Figura 7 se observa que el error de las muestras de validación decrece paulatinamente a medida que decrece el error de entrenamiento lo cual muestra que el modelo ANFIS es capaz de capturar valores intermedios con buena precisión.

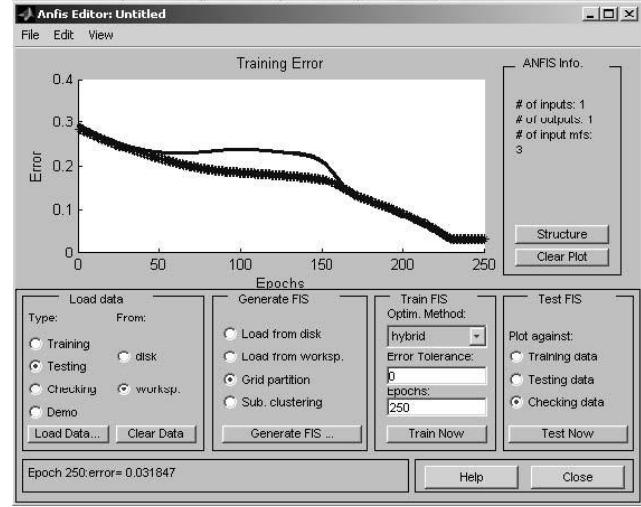


Figura 8. EPOCHS vs error de entrenamiento para las muestras de chequeo de la corriente de la fase A.

Sin embargo, del análisis de detalle realizado se pudieron identificar algunas falencias de este modelo especialmente cuando se varían ciertas condiciones del sistema eléctrico de potencia que hace que las muestras de entrada generadas no logren clasificarse adecuadamente con error bajo.

Figura 7. EPOCHS vs error de entrenamiento para las muestras validación de la corriente de la fase A.

En la Figura 8 ilustra un comportamiento similar para las muestras de chequeo.

En la Figura 9 se ilustra la salida del FIS vs las muestras de chequeo mostrando que éstas últimas son adecuadamente clasificadas por el modelo con un error bajo.

Finalmente en las Figura 10 y Figura 11 se muestran los resultados de las funciones de pertenencia de entrada luego de las fases de entrenamiento 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.

Figura 9. Muestras de chequeo vs salida del modelo FIS.

Para algunos casos detectados, se hizo necesario, entonces, depurar el conjunto de muestras de entrada de tal manera que se lograra el objetivo deseado. Por ejemplo, la falla trifásica aislada y la falla trifásica a tierra arrojaron resultados muy similares (valores de tensiones y corrientes resultantes muy parecidos). Para los algoritmos convencionales de protección distanciamiento esto no suele ser una gran dificultad ya que disponen de elementos funcionales específicos para separar las fallas a tierra de las fallas aisladas. Sin embargo, para los algoritmos de clasificación, tales como el ANFIS, la similitud entre los patrones de entrada suele ofrecer un alto nivel de dificultad debido a que el algoritmo no logra identificar y separar adecuadamente este tipo de situaciones,

lo cual finalmente lleva a generar altos errores de clasificación. Por este motivo, para este caso de estudio se optó por retirar las muestras de entrada correspondientes con la falla trifásica a tierra.

Figura 10. Función de pertenencia de la corriente de la fase A, posterior al entrenamiento y validación.

Figura 11. Función de pertenencia de la corriente de secuencia cero, posterior al entrenamiento y validación.

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 50 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).

IV. CONCLUSIONES

Se ha presentado un modelo para detección y clasificación de fallas en líneas de transmisión utilizando ANFIS. Los resultados obtenidos muestran que mediante este modelo se logra cubrir un amplio rango del universo de entrada de fallas en un sistema eléctrico de potencia manteniendo a su vez un error de clasificación bajo. Se verificó la metodología en un sistema típico de 230 kV de doble circuito considerando un amplio análisis de sensibilidad cubriendo una importante diversidad de situaciones. A pesar de haberse obtenido buenos resultados preliminares, el análisis de detalle realizado permitió identificar, sin embargo, diversas falencias de este modelo para adaptarse a ciertas condiciones críticas del sistema de potencia para las cuales el error de entrenamiento se hace alto y no puede lograrse una adecuada clasificación de ciertas fallas. La anterior falencia, es uno de los puntos neurálgicos que se ha logrado identificar durante la fase preliminar del proyecto ISA-Colciencias_Universidad Nacional de Colombia, Sede Medellín, es decir, la dificultad de los algoritmos convencionales para adaptarse a la variabilidad exigida por un sistema eléctrico de potencia real. Este tipo de resultado, comienza a proporcionar herramientas de análisis en la búsqueda de un Modelo Adaptativo de Inteligencia Artificial que permita abordar la dificultad asociada con la variabilidad de las condiciones eléctricas de cualquier sistema eléctrico de potencia del mundo.

V. TRABAJOS FUTUROS

Como parte del proyecto ISA-Colciencias-UNAL se encuentra en desarrollo un Modelo Adaptativo de Inteligencia Artificial [23] que considera condiciones críticas extremas de los sistemas eléctricos de potencia para el diagnóstico automático de fallas a partir de registros de osciloperturbografía y de esta manera afrontar las limitaciones encontradas.

AGRADECIMIENTOS

Este trabajo presenta los resultados de la investigación que realiza 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 trasmisión de energía eléctrica” cofinanciado por Colciencias.

REFERENCIAS

- [1] S.M. Yeoa, C.H. Kima, K.S. Honga, Y.B. Limb, R.K. Aggarwalc, A.T. Johnsc, M.S. Choid. “A novel algorithm for fault classification in transmission lines using a combined adaptive network and fuzzy inference system”. Electrical Power and Energy Systems 25 (2003) 747–758. Elsevier.
- [2] Kim CH, Lee MH, Aggarwal RK, Johns AT. “Educational use of EMTP MODELS for the study of a distance relaying algorithm for protecting transmission lines”. IEEE Trans Power Syst 2000;15(1): 9–15.

- [3] Dalstein T, Kulicke B. "Neural network approach to fault classification for high speed protective relaying". IEEE Trans Power Deliv 1995; 10(2):1002–11.
- [4] Wang H, Keerthipala WWL. "Fuzzy-neuro approach to fault classification for transmission line protection". IEEE Trans Power Deliv 1998;13(4):1093–104.
- [5] Keerthipala WWL, Wang H, Wai CT. "Experimental validation of a fuzzy-neuro based fault classifier for transmission line protection". International Conference Power Systems Transients, IPST '99, Budapest, Hungary; June 1999. p. 549–54.
- [6] Agrawal P. "An investigation into a method of detecting the fault induced high frequency voltage signals of EHV transmission lines for protection applications". IEEE Trans Power Deliv 1991;6(1): 119–26.
- [7] Gilbert DM, Morrison IF. "A statistical method for the detection of power system faults". Electr Power Energy Syst 1997;19(4): 269–75.
- [8] Djuric MB, Radojevic ZM, Terzija VV. "Numerical algorithm for arcing faults detection and fault distance calculation on overhead lines". Electr Mach Power Syst 1997;939–53.
- [9] Djuric MB, Radojevic ZM, Terzija VV. "Arcing faults detection on transmission lines using least error squares technique". ETEP 1998; 8(6):437–43.
- [10] Fitton DS, Dunn RW, Aggarwal RK, Johns AT, Bennett A. "Design and implementation of an adaptive single pole autoreclosure technique for transmission line using artificial neural networks". IEEE Trans Power Deliv 1996;11(2):748–55.
- [11] Aggarwal RK, Song YH, Johns AT. "Adaptive three-phase autoreclosure for double-circuit transmission system using neural networks". IEE Second International Conference on Advances Power System Control, Operation and Management, Hong Kong; Dec. 1993. p. 389–92.
- [12] Kim CH, Byun SH, Kim H, Kim ID, Aggarwal RK, Johns AT. "A novel approach to detecting arcing faults in transmission lines using wavelet transforms". International Conference on Electrical Engineering, ICEE '98, Kyongju, Korea; July 1998. p. 775–8.
- [13] [Sidhu, 2004]. "A Comprehensive Analysis of an Artificial Neural-Network-Based Fault Direction Discriminator". IEEE TRANSACTIONS ON POWER DELIVERY, VOL. 19, NO. 3, JULY 2004.
- [14] [Jiang, 2003]. "A New Protection Scheme for Fault Detection, Direction Discrimination, Classification, and Location in Transmission Lines". IEEE. 2003.
- [15] [Olesovicz, 2001]. "A Complete Scheme For Fault Detection, Classification and Location in Transmission Lines Using Neural Networks". IEE.
- [16] [Mazon, 2001]. "Fault Location System On Double Circuit Two Terminal Transmission Lines Based On Ann's".
- [17] [Salat, 2000]. "Fault Location in Transmission Line Using Self-Organizing Neural Network". IEEE.
- [18] Vasilic, Slakvo. (2004) "Fuzzy Neural Pattern Reconigton Algorithm for classification of the events in power system networks". Doctor Dissertation Submitted to the Office of Graduate Studies of Texas A&M University.
- [19] Hines JW. MATLAB supplement to fuzzy and neural approaches in engineering. New York: Wiley; 1997.
- [20] Jang JSR, Sun CT. Neuro-fuzzy modeling and control. Proc IEEE 1995;83(3):378–406.
- [21] Electromagnetic Transient Program (EMTP) - Rule Book, EPRI EL 6421-1, Electric Power Research Institute, Palo Alto, CA, June 1989.
- [22] Alternative Transients Program (ATP) - Rule Book, CanAm EMTP User Group, Portland, OR, Sep. 1992.
- [23] Calderón, Jhon Albeiro. "Modelo Adaptativo de IA para el diagnóstico automático de fallas a partir de registros de osciloperturbografía". Propuesta de Tesis de Maestría. UNAL – Sede Medellín. 2007.

Jhon A. Calderón. Ingeniero Electricista de la Universidad Nacional de Colombia (1988). 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 donde se ha desempeñado en varias ocasiones como coordinador del Equipo Estudios de Operación en la Dirección Gestión Red de ISA. Actualmente, es estudiante candidato a la Maestría en Ingeniería de Sistemas de la Universidad Nacional de Colombia – Sede Medellín (2007).

Germán Zapata M. Profesor Asistente de la Universidad Nacional de Colombia – Sede Medellín. Director de la Escuela de Ingeniería Eléctrica y Mecánica. Integrante del GAUNAL: Grupo de Automática de la Universidad

Nacional de Colombia, Categoría A de Colciencias. 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).

Demetrio A. Ovalle C. Profesor Asociado, Universidad Nacional de Colombia sede Medellín. Director de la Escuela de Ingeniería de Sistemas de la Universidad Nacional de Colombia – Sede Medellín. Director del GIDIA: Grupo de Investigación y Desarrollo en Inteligencia Artificial, Categoría A de Colciencias. Ingeniero de Sistemas y Computación, Universidad de los Andes, Bogotá, Colombia (1984). Magíster en Informática del Institut National Polytechnique de Grenoble, Francia (1987). Doctor en Informática de la Université Joseph Fourier, Francia (1991). El área de énfasis de su investigación es Inteligencia Artificial, más específicamente Sistemas Híbridos Inteligentes integrando Redes Neuronales, Sistemas de Lógica Difusa y Sistemas Multi-Agente aplicados a la Simulación de los Mercados de Energía y a la Detección de Fallas en Líneas de Transmisión. Otros tópicos de investigación que trabaja actualmente son: Inteligencia Artificial en Educación, Sistemas Tutoriales Inteligentes, Sistemas basados en CBR (Case-Based Reasoning) y Técnicas de Planificación Inteligente aplicadas a la Construcción de Sistemas de Composición de Servicios Web.

Universidad Nacional de Colombia Sede Medellín

Facultad de Minas



Misión

Ofrecer servicios de apoyo a la docencia en cuanto a la operación de los computadores y del software adecuado con miras al desarrollo integral de los futuros ingenieros.

Visión

Avanzamos en la búsqueda de convertir el Laboratorio de Sistemas e Informática en una dependencia ágil, moderna, facilitadora de procesos y cambios, atenta a las necesidades de otras dependencias de la Universidad, cuya labor apoyamos y articulamos. Serviremos con dinamismo, amabilidad y efectividad a todos los integrantes de la comunidad universitaria y a la sociedad en general. Uniremos esfuerzos para construir un ambiente de trabajo cada vez más positivo que propicie la participación, la creatividad y el desarrollo profesional de los integrantes del equipo de trabajo. Propendemos por un Laboratorio como instrumento gestor y generador de proyectos de investigación sustentado en un equipo interdisciplinario de trabajo en torno a la informática aplicada a la ingeniería.

Cursos

- Lenguajes de Programación: Diseño de Páginas Web en ASP.NET con VB.NET, Programación Web PHP y MYSQL, MS-Visual Basic Básico y Avanzado, Java
- Generales: Latex, ARCGIS, MS-Office (Word, Excel y PowerPoint), Excel Financiero, Excel Avanzado, Mantenimiento de Hardware y Software Niveles I y II, MS-Access Básico, MS-Project Básico (Programación y Gerencia de Proyectos), AUTOCAD 2D Básico y 3D, Matlab, Moodle de Apoyo a los Procesos de Enseñanza y Aprendizaje.

Para mayor información, por favor comunicarse a los teléfonos: 4255313, 4255312, 4255355. Calle 59A No. 63 – 020 Medellín (Colombia), Bloque M7, quinto piso.

Email: labsis@unalmed.edu.co

<http://xue.unalmed.edu.co/cursos>

