

AGRUPAMIENTO DIFUSO EN EL MONITOREO TÉRMICO DE LÍNEAS DE TRANSPORTE DE ENERGÍA ELÉCTRICA

Henry O. Sarmiento M¹, Jorge A. Gómez², Nelson Gómez³, Jaime A. Valencia V⁴.

¹Grupo de Investigación en Instrumentación, Control Automático y Robótica (ICARO). Politécnico Colombiano Jaime Isaza Cadavid, carrera 48 Número 7-151. Medellín, Colombia.

²Grupo de Física Básica y Aplicada. Politécnico Colombiano Jaime Isaza Cadavid, Medellín, Colombia

³Grupo de Investigación en Automatización y Electrónica. Instituto Tecnológico Metropolitano, Medellín, Colombia

⁴Grupo de manejo Eficiente de la Energía (GIMEL). Universidad de Antioquia, Medellín, Colombia

RESUMEN

Este trabajo presenta una propuesta para el monitoreo de temperatura en líneas de transporte de energía eléctrica utilizando inteligencia artificial. Con este monitoreo el operador puede conocer el estado real de las líneas y ejecutar tareas de supervisión y control para mejorar confiabilidad, seguridad y calidad del servicio. La metodología propuesta, en la etapa de entrenamiento, tiene sensores y dispositivos con tecnología óptica para hacer registro y almacenamiento de datos de temperatura. Con el histórico de datos se entrena un clasificador difuso, y las clases obtenidas son asociadas por un experto a estados de operación normal o de falla. En la etapa en línea, el clasificador procesa cada nueva muestra asignando un estado de operación, y con esta información el operador puede determinar las acciones a realizar. La metodología es probada sobre un tramo de línea emulada en un laboratorio de alta tensión.

Palabras claves: Inteligencia Artificial, Agrupamiento Difuso, Monitoreo de temperatura, Sistema Eléctrico de Potencia.

Recibido: 30 de noviembre de 2011. Aceptado: 24 de febrero de 2012

Received: November 30th, 2011. Accepted: February 24th, 2012

FUZZY CLUSTERING IN THE THERMAL MONITORING OF ELECTRIC TRANSMISSION LINES

ABSTRACT

This paper presents a proposal for monitoring temperature in electric power transmission lines by using artificial intelligence. With a temperature monitoring system, the operator can know the current state of the line and carry out control actions to improve reliability, safety and quality of the service. The proposed methodology in the training stage uses optical sensors and devices for recording and storing temperature data. With the historical data, a fuzzy classifier is trained and, the obtained classes are associated with states of normal or failure operation by an expert. In the on line stage, the classifier processes each new sample and assigns an operation state, and then with this information the operator determines the right action on the electric system. The methodology is tested on a section of emulated transmission line in a high voltage laboratory.

Keywords: Artificial intelligence, fuzzy clustering, temperature monitoring, electrical power system.

1. INTRODUCCIÓN

La condición térmica de operación de un cable por el cual se transporta energía eléctrica, determina de manera significativa la cargabilidad de la misma, lo que convierte al monitoreo de esta variable en un punto clave en el buen desempeño de un sistema eléctrico [1]. Fuentes de calor cercanas a las líneas, cambios climáticos, fallas que no producen la salida del sistema por sobre corrientes o sobre voltajes, entre otros factores, afectan el comportamiento térmico de los cables generando de esta forma condiciones de despacho ineficientes, deterioro del sistema y en algunos casos la salida de las líneas. El monitoreo térmico de los cables de transmisión de energía eléctrica [2], se ha desarrollado usualmente a través de la medición cuasi-distribuida de temperatura [3], pero aún no se reportan soluciones, donde se incluya el agrupamiento difuso como herramienta complementaria de éstos sistemas.

En este trabajo, se presenta una propuesta de monitoreo en líneas de transmisión de energía utilizando agrupamiento difuso como herramienta de inteligencia artificial. El sistema de monitoreo inteligente de las señales de temperatura, permite determinar los estados funcionales de la línea. Estos estados funcionales son la descripción del comportamiento que la línea presenta en un momento determinado, es decir, estado normal, estado de falla, etc. [4]. Los estados funcionales, dan al operario del sistema información útil que le facilita realizar acciones pertinentes para optimizar los recursos disponibles en el proceso de transporte eficiente de energía eléctrica.

Una descripción del esquema de monitoreo basado en el análisis de datos y generalidades de los métodos de agrupamiento difuso son presentadas en la sección 2. En la sección 3, se describe el sistema de monitoreo térmico en una línea de transporte de energía eléctrica, que se emula en un laboratorio de alta tensión. Resultados de agrupamiento aplicados a las bases de datos disponibles tanto para entrenamiento como para prueba son obtenidos y analizados en la sección 4. Finalmente, la sección 5 incluye las conclusiones y trabajos futuros.

2. MONITOREO DE PROCESOS BASADO EN DATOS

El esquema de monitoreo de procesos basado en datos, es presentado en la Fig. 1. En la etapa de entrenamiento (fuera de línea), la información del proceso obtenida mediante el sensado de variables físicas es almacenada en un histórico de datos. Esta información del proceso es utilizada, para que mediante algún método de inteligencia computacional se pueda obtener un clasificador. Este clasificador permite ubicar cada muestreo de señal o conjunto de variables en una clase. Estas clases, al ser analizadas por el experto en el proceso, son asociadas a estados funcionales.

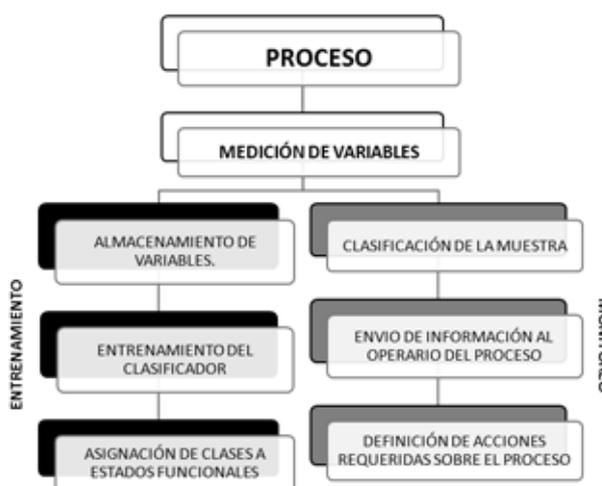


Fig. 1. Diagrama General de Sistema de Monitoreo Basado en Datos.

En la etapa de monitoreo (en línea) cada nueva muestra es procesada por el clasificador. De acuerdo con la clasificación obtenida es asociada a la muestra un estado funcional. Esta información, es la que finalmente se presenta al operador del proceso para que ejecute las acciones que se requieran. De esta forma, es posible identificar en cada instante de tiempo, cómo se encuentra el proceso, y disponer de información útil para las tareas de supervisión y diagnóstico.

Uno de los métodos utilizados en la supervisión y monitoreo de procesos, es el de agrupamiento (*clustering*) difuso [4, 5 y 6]. El agrupamiento difuso, a diferencia del agrupamiento concreto, permite conocer no solo a que clase o estado funcional corresponde la muestra, sino que además, cuantifica el grado de pertenencia de una muestra a cada

clase o estado. Esta información puede resultar muy útil para determinar la evolución que ha tenido el proceso y los estados que puede alcanzar en un momento determinado.

2.1 Agrupamiento Difuso

El clustering o agrupamiento es la tarea de agrupar datos a partir de una medida de similitud (e.g. distancia) [7,8]. Estos métodos permiten clasificar y correlacionar datos en el espacio (ver Fig. 2). La clasificación puede manejarse en forma supervisada y no supervisada. Un aprendizaje es supervisado, cuando se realiza un reconocimiento de patrones, es decir, se conoce la salida esperada de la clasificación. Un aprendizaje es no supervisado, cuando se construyen clases desconociendo la salida esperada del agrupamiento. En el caso de aprendizaje no supervisado se habla de clustering.

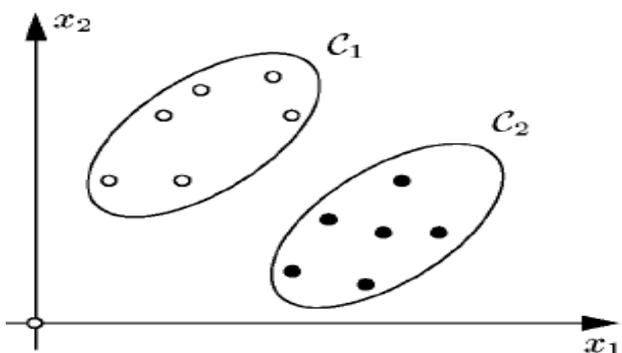


Fig. 2. Representación geométrica de dos clases en el espacio de datos.

Algunos de los métodos de clasificación utilizados en el diagnóstico de procesos son:

K-Means (el más simple) agrupa los datos en hiperesferas, y su entrenamiento depende del número de clases (K) y de los centroides iniciales [8]. Con base en un criterio de optimización el método permite agrupar los datos en función de la similitud entre ellos, en este caso la distancia mide la separación de un dato con respecto al centro de una clase.

El método Fuzzy C-Means (FCM) [7,9] busca minimizar la distancia Euclidiana d_{ij} ($d_{ij} = |x_i - c_j|$) entre los datos de una muestra x_i y los centros de las clases c_j . El valor u_{ij} en el rango $[0,1]$, es el grado de pertenencia asignado para cada muestra x_i con respecto a cada clase o cluster j . La función

de minimización J se define en función de la matriz de grados de pertenencia U y los centros c_j , ver (1).

$$J(U, c_j) = \sum_{i=1}^{\# \text{muestras}} \sum_{j=1}^{\# \text{clases}} (u_{ij}) (d_{ij})^2 \quad (1)$$

En el método GK- Means [7, 10] (una variante del FCM), la medida de distancia es la de Mahalanobis y permite hacer la agrupación de Clases en forma de hiperelipsoides.

El método LAMDA-Learning Algorithm Multivariable and Data Analysis- [11], permite realizar actualización de Clases. LAMDA puede trabajar con datos cuantitativos y cualitativos, característica que lo diferencia de los anteriores métodos mencionados. En este método se estima el grado de adaptación de cada dato a cada cluster o clase. Esta adaptación se tiene en el sentido posibilista. El método analiza el Grado de Adecuación Marginal (MAD) de cada descriptor x_j a cada cluster y , luego, a partir de una ponderación de T-Norma y S-Norma, se obtiene el grado de adecuación de cada dato x (conjunto de descriptores en un tiempo de muestreo) a cada cluster denominado Grado de Adecuación Global (GAD). Para la adecuación de las clases se emplea la Clase No Informativa (NIC), la cual establece automáticamente un umbral mínimo a superar para determinar la pertenencia de un elemento a una clase.

3. SISTEMA DE MONITOREO TÉRMICO CON SENSORES ÓPTICOS EN LÍNEAS DE TRANSMISION.

El sistema de monitoreo piloto, tiene el objetivo medir y reportar las temperaturas que se presentan en un conductor -durante su funcionamiento normal o anormal- en un sistema eléctrico de transmisión de energía. Los datos experimentales de temperatura fueron obtenidos a través de elementos, dispositivos y equipos con tecnología óptica basada en Redes de Bragg.

Una red de Bragg en fibra óptica (FBG) es una fibra óptica en la cual el índice de refracción del núcleo se modifica de forma periódica en la dirección de propagación de la luz. Esta característica hace que la FBG sea un dispositivo altamente selectivo que refleja una longitud de onda específica conocida como longitud de onda de Bragg. En las FBG existe

una relación o respuesta lineal de corrimiento espectral con los cambios de temperatura. Además, las FBG presentan reducido tamaño y peso, inmunidad electromagnética, y la posibilidad de multiplexación y de sensado remoto. Estas características facilitan la configuración de un sensado cuasi-distribuido de temperatura en líneas de transmisión eléctrica [12].

El tramo de línea de transmisión de energía (sistema de prueba) con los herrajes y aisladores correspondientes, fue instalado en el interior del laboratorio de Alta Tensión de la Facultad de Ingeniería de la Universidad de Antioquia. El conductor ASCR 1/0 de aproximadamente 8 metros, fue conectado a un transformador que se alimentó por una fuente eléctrica variable, para tener control del voltaje aplicado. El circuito que formó el arrollamiento secundario del transformador y el conductor, permitió la circulación de un valor ajustable de corriente. Sobre el conductor se instalaron 3 redes de Bragg grabadas sobre la misma fibra óptica, una red en el centro del conductor y con respecto a esta red central una a cada lado con una separación de aproximadamente 2 metros. Las longitudes de onda (a 25°C) correspondientes a los sensores 1, 2 y 3 respectivamente fueron: 1554.11nm, 1556.14nm, y 1558.18nm. En uno de los extremos de la fibra fue instalado un interrogador de Redes de Bragg basado en un láser sintonizable. Ver esquema en Fig. 3.

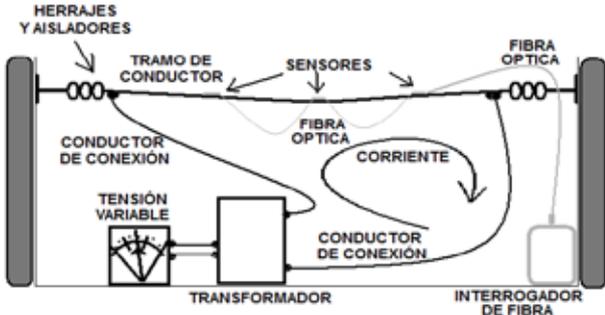


Fig. 3. Esquema del sistema de monitoreo

El conductor fue sometido a calentamiento mediante aumento controlado de la corriente y mediante una fuente externa. Para esta última se utilizó un quemador de gas propano que se puso directamente sobre el conductor. Los perfiles térmicos asociados a éstas perturbaciones se presentan en las figuras 4 y 5. Las graficas en el eje Y muestran los valores de variación de longitud de onda (la lectura que se recibe del interrogador

de fibra. La temperatura real se encuentra en función del valor de la variación de la longitud de onda de acuerdo con la ecuación (2).

$$T(^{\circ}\text{Celsius})=102.629*(LW)+30 \quad (2)$$

Donde LW es el valor de variación de longitud de onda. En el trabajo las temperaturas oscilaron entre 30° (temperatura ambiente) y 110° Celsius.

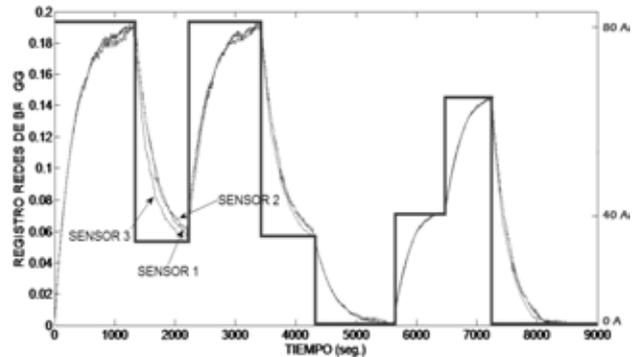


Fig. 4. Registro FBG por variación de corriente en la línea.

La Fig. 4, muestra el registro de la temperatura tanto en incremento como en decremento por variaciones de la corriente que circula por el conductor. Las variaciones de corriente alterna toman valores de corriente alterna entre 0 y 80 A. Los tiempos en los cuales se varió la corriente corresponden a los puntos donde ya se puede observar una tendencia de estabilidad en la señal de temperatura. Además, como era de esperarse, la temperatura no se comporta de forma lineal con la corriente. Esta dinámica en el proceso -las variaciones de temperatura con igual tendencia y valores similares- es catalogada en el agrupamiento como comportamiento normal del conductor.

La Fig. 5, muestra el registro de temperaturas cuando el conductor por el cual circula corriente es sometido a fuentes externas de calor, en este caso llamas (soplete de propano). Las condiciones anormales se impusieron cerca a los puntos de sensado, aplicando la llama en los momentos en que existiera estabilidad de temperatura por corriente en el conductor. Los valores de la temperatura alcanzados fueron de 106°C, 82°C y 91°C en los sensores 3, 2 y 1 respectivamente. Los tiempos de inicio y extinción de llama son 1400 - 1750 s, 4500 - 4800 s, y 7400 - 7750s para los sensores 3, 2, y 1 respectivamente. El

comportamiento en la Fig. 5 donde las señales de los sensores se separan significativamente es asociado en el clasificador a un estado anormal o de fallo.

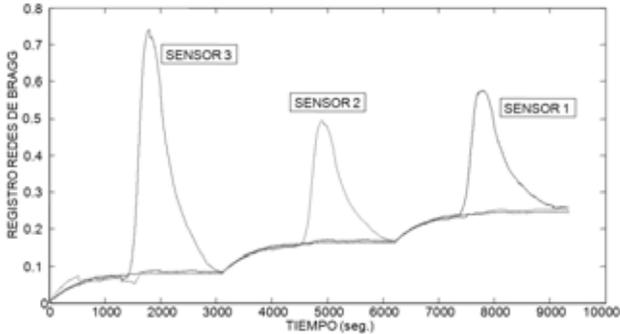


Fig. 5. Respuesta de sensores ante calentamientos puntuales en el conductor.

3.1 Agrupamiento difuso con LAMDA

En nuestro trabajo, la metodología LAMDA fue seleccionada para obtener el clasificador. Esta metodología ha sido aplicada al monitoreo de procesos industriales satisfactoriamente [4, 5, y 13]. La base de datos para entrenamiento consta de 9333 muestras (1 muestra/s ver Fig. 4), para las tres variables (3 redes de Bragg). La base de datos de prueba consta de 8600 muestras, ver Fig. 5.

Antes de proceder a aplicar el método de clustering, se realizó un pre-tratamiento de las señales. El pre-tratamiento en la etapa inicial consistió el filtraje de la señal para eliminar ruidos de alta frecuencia, y el sub-muestreo debido a la gran cantidad de datos (selección de 1 dato cada 10 registros). La etapa final del pre-tratamiento fue la eliminación de la tendencia uniforme de crecimiento de la temperatura en los tres sensores por la circulación de la misma corriente, el valor absoluto de la diferencia entre señales fue la acción tomada ($|S1-S2|$, $|S1-S3|$ y $|S2-S3|$). Las señales resultantes del pre-tratamiento para la base de datos de entrenamiento, se observan en la Fig. 6.

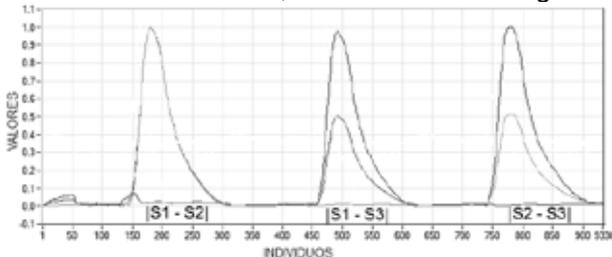


Fig. 6. Base de datos de entrenamiento con pretratamiento y normalización

Aplicando la metodología LAMDA con un entrenamiento no supervisado, se pudo obtener un primer resultado de clases con el software SALSA [14], ver Fig. 7. El entrenamiento se obtuvo con una función de distribución binomial (Lamda1), conectivo difuso MinMax, un grado de exigencia de 0.68, y dos iteraciones.

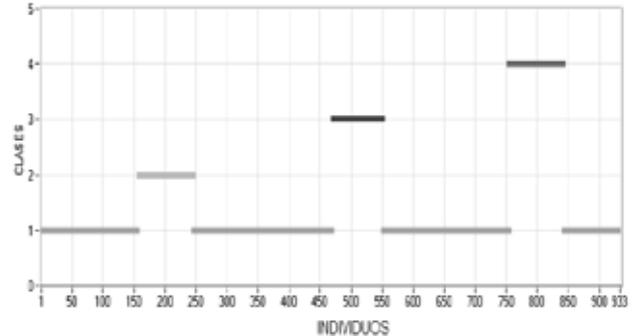


Fig. 7. Resultados de Entrenamiento con clasificación no supervisada

La asignación de clases a estados funcionales se muestra en la tabla 1.

Tabla 1. Asignación de Clases a Estados Funcionales

Clase	Estado
C1	Operación Normal
C2	Calentamiento anormal cerca al sensor 3
C3	Calentamiento anormal cerca al sensor 2
C4	Calentamiento anormal cerca al sensor 1

De los resultados anteriores, se puede concluir que el clasificador entrenado constituye una herramienta útil en el monitoreo del proceso, porque permite identificar los instantes en los cuales el conductor esta por fuera de límites normales de temperatura.

Con las clases definidas, se evaluó el sistema de monitoreo con la base de prueba. Los resultados del pretratamiento para la base de prueba, se observan en la Fig. 8, donde se omitió el submuestreo.

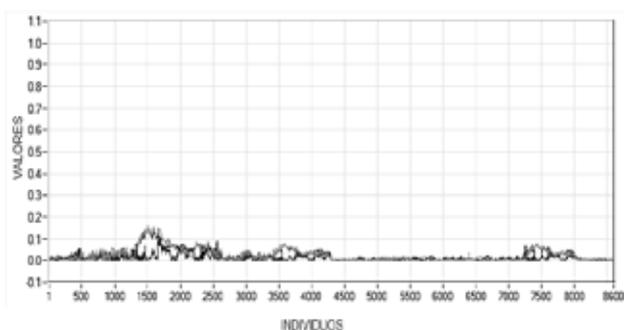


Fig. 8. Resultados de pretratamiento a base de datos de prueba.

Los resultados del reconocimiento de acuerdo al clasificador ya entrenado se observan en la figura 9.

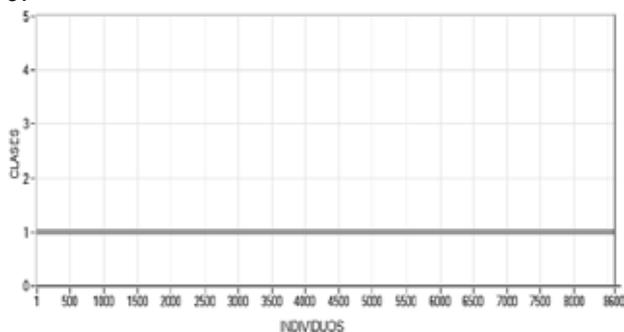


Fig. 9. Resultados de reconocimiento con el predictor entrenado para la base de prueba

De acuerdo con lo esperado solo se reconoce la clase 1 de operación normal, ya que esta base de datos solo contiene información de calentamiento y enfriamiento del conductor ante incrementos o decrementos en la intensidad de corriente, sin incluir calentamientos anormales.

4. CONCLUSIÓN

La metodología aplicada permite determinar los estados funcionales que representan el comportamiento térmico de una línea de transporte de energía. Una etapa determinante en el esquema de supervisión fue el pre-tratamiento de las señales, lo que permitió la obtención de una buena clasificación. El trabajo con tecnología óptica permitió realizar un muy buen sensado y registro de las señales térmicas, lo que facilitó el entrenamiento del sistema. Con la metodología propuesta, se demuestra a nivel de laboratorio, una estrategia que permite entregar información confiable al operador de un sistema eléctrico de

potencia, lo que le permitirá tener criterios precisos de maniobra para la optimización de los recursos involucrados.

Se plantea como trabajo futuro, la posibilidad de identificar estados funcionales que permitan conocer al operador los momentos en que la fuente externa de calor permanece activa, esta información adicional le permitiría, al operar, tener más argumentos para la toma de decisiones.

También como continuación del trabajo, la etapa a seguir es la implementación del sistema de monitoreo sobre un tramo de línea real en campo.

La adición de un número considerable de sensores que permitan tener un perfil muy completo de temperatura permitiría hacer aun más evidente la robustez del monitoreo propuesto por la capacidad de análisis multivariable.

5. AGRADECIMIENTOS

Este trabajo fue desarrollado gracias a la colaboración interdisciplinaria entre el Grupo ICARO y el Grupo de Física Básica y Aplicada, del Politécnico Jaime Colombiano Isaza Cadavid (Proyecto de Menor Cuantía radicado en la oficina de Investigación -2061100113), el Grupo de Automatización y Electrónica del Instituto Tecnológico Metropolitano (Proyecto P09244), y el Grupo GIMEL de la Universidad de Antioquia.

6. REFERENCIAS BIBLIOGRÁFICAS

- [1] Téllez, S.; Comportamiento de conductores eléctricos usados en líneas de transmisión ante esfuerzos electromecánicos y térmicos combinados [Tesis de Maestría]; Bogotá: Universidad Nacional. 2011.
- [2] Schell, F.; Simonits, D.; Long Distance Cable Temperature Monitoring System for the Olympic City 2008 Beijing. Disponible en: http://www.lios-support.com/LIOS_Long_Distance_Cable_Temperature_Monitoring_Beijing.pdf [consultado el 1 de noviembre de 2011]
- [3] Guillen, J.; Análisis De Resolución En Sensores Multiplexados Basados En Rejillas De Bragg Gemelas. [Tesis de Maestría]. Ensenada (Mexico),

Centro de Investigación Científica y de Educación Superior de Ensenada, 2004.

[4] Aguilar-Martín, J.; *Inteligencia Artificial para La Supervisión De Procesos Industriales*, Universidad de los Andes -ULA-, Mérida, Venezuela, 2007.

[5] Isaza, C., Diez-Lledo, E., Hernandez de Leon, H., Aguilar-Martin, J. and LeLann, M.V. Decision Method for Functional States Validation in a Drinking Water Plant, In IFAC, *10th Computer Application in Biotechnology*, IFAC-PapersOnline, Cancun-Mexico, 2007.

[6] Kemposky, T., Subias, A. and Aguilar-Martin, J.; Process Situation Assessment: From a Fuzzy partition to a finite State Machine, *Engineering Applications of Artificial Intelligence*, vol. 19, pp. 461–477, 2006.

[7] Ali, A., Karmakar, G. and Dooley, L.; Review on Fuzzy Clustering Algorithms, *IETECH Journal of Advanced Computations*, vol. 2 (no. 3), pp. 169–181, 2008.

[8] Marroquin, J., & Girosi, F.; Some extensions of the k-means algorithm for image segmentation and pattern recognition. (AI Memo 1390). Massachusetts Institute of Technology, Cambridge, MA, 1993.

[9] Dae-Jong Lee; Jong-Pil Lee; Pyeong-Shik Ji; Jae-Woon Park; Jae-Yoon Lim; , "Fault Diagnosis of Power Transformer Using SVM and FCM," *Electrical Insulation*, 2008. ISEI 2008. Conference Record of the 2008 IEEE International Symposium on, vol., no., pp.112-115, 9-12 June 2008.

[10] NingLv; Xiaoyang Yu; Junfeng Wu; , "A fault diagnosis model through G-K fuzzy clustering," *Systems, Man and Cybernetics*, 2004 IEEE International Conference on, vol.6, no., pp. 5114-5118 vol.6, 10-13 Oct. 2004.

[11] Aguilar-Martín, J. and Lopez De Mantaras, R.; The process of classification and learning the meaning of linguistic descriptors of concepts, *Approximate reasoning in decision analysis*, North H., pp. 165-175, 1982.

[12] Udd, E. and Spillman, W. B.; *Fiber Optic Sensors: An Introduction for Engineers and Scientists*, Second Edition, John Wiley & Sons, Inc., Hoboken, NJ, USA, 2011.

[13] Hedjazi, L., Kempowsky-Hamon, T., Despènes, L., Le Lann, M., Elgue, S. and Aguilar-Martin, J.; Sensor Placement and fault detection using an efficient fuzzy feature selection approach, In IEEE, *49th IEEE Conf. on Decision and Control (CDC)*, pp. 6827-6832, Atlanta. 2010.

[14] SALSA, Software.Learning Algorithm for Multivariable Data Analysis En: <http://homepages.laas.fr/tkempows/index.htm>. 2009.