



Fault detection and diagnosis through artificial intelligence techniques, a state of art

Luini Leonardo Hurtado-Cortés ^a, Edwin Villarreal-López ^b & Luís Villarreal-López ^c

^a Facultad Tecnológica, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia. llhurtadoc@udistrital.edu.co

^b Facultad de Ciencias Básicas e Ingeniería, Universidad de San Buenaventura, Bogotá, Colombia. edvillal@gmail.com

^c Facultad de Ingeniería, Fundación Universidad Agraria de Colombia, Bogotá, Colombia. Villarreal.luis@uniagraria.edu.co

Received: February 4th, 2016. Received in revised form: July 11th, 2016. Accepted: August 9th, 2016.

Abstract

This article presents the current state of artificial intelligence techniques and their application to the field of fault detection and diagnosis, in dynamical systems. Initially, a brief description of what is considered a mechanism for fault detection and diagnosis, and current approaches to the study and implementation of such mechanisms are explained. Subsequently, the most important results of the various artificial intelligence techniques applied to the fault detection and diagnosis are presented. Finally, a comparative analysis based on the desired characteristics of the mechanisms of fault detection and diagnosis is presented. The article concludes by mentioning the benefits of the classification of techniques presented and the listing possible pathways to where you should go research in this field.

Keywords: fault detection and diagnosis, artificial neural networks, fuzzy logic systems, neuro-fuzzy systems and immune systems.

Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte

Resumen

Este artículo presenta el estado actual de las técnicas de inteligencia artificial y su aplicación al campo de la detección y diagnóstico de fallas en sistemas dinámicos. Inicialmente, se hace una breve descripción de lo que se considera un mecanismo de detección y diagnóstico de fallas, y se explican los enfoques actuales de estudio y aplicación de tales mecanismos. Posteriormente, se presentan los resultados más importantes de las diferentes técnicas de inteligencia artificial aplicadas a la detección y diagnóstico de fallas. Finalmente, se presenta un análisis comparativo con base en las características deseables de los mecanismos de detección y diagnóstico de fallas. El artículo concluye mencionando los beneficios de la clasificación de las técnicas presentadas y enumerando las posibles vías hacia donde debe ir la investigación en este campo.

Palabras clave: detección y diagnóstico de fallas, redes neuronales artificiales, sistemas de lógica difusa, sistemas neurodifusos, sistemas inmunes.

1. Introducción

Los procesos actuales por su complejidad exigen sistemas de seguridad cada vez más confiables. El malfuncionamiento de los equipos, puede provocar pérdidas económicas, peligro para los operarios e inconvenientes para los usuarios, entre otros.

La supervisión de procesos, es el conjunto de acciones orientadas a asegurar un correcto funcionamiento, incluso en situaciones de riesgo. Un sistema de supervisión, debe

cumplir tres etapas fundamentales: la detección de fallas, su diagnóstico y el restablecimiento de las condiciones de operación de acuerdo con las especificaciones.

Una falla, es un cambio en el comportamiento de alguno de los componentes de un sistema, de manera que éste ya no puede cumplir con la función para la cual fue diseñado. Los sistemas de detección y diagnóstico de fallas, se presentan como una solución que permite determinar el estado de

How to cite: Hurtado-Cortés L. L., Villarreal-López E., & Villarreal-López L. Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte DYNA 83 (199) pp. 19-28, 2016



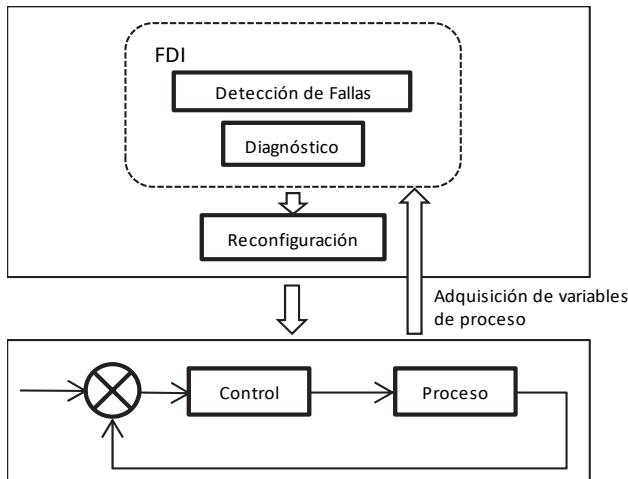


Figura 1. Esquema general de un sistema de detección y diagnóstico de fallas.

Fuente: Los autores.

operación del proceso, así como identificar la naturaleza de las fallas presentadas, su localización y riesgo.

La Fig. 1, ilustra un esquema general de un sistema de detección y diagnóstico de fallas. En este esquema, las entradas y salidas del bloque proceso-controlador alimentan un sistema de supervisión encargado de detectar la presencia de fallas y diagnosticar su naturaleza. Con esta información es posible corregir los parámetros del controlador de forma manual o automatizada, o intervenir en el proceso para corregir los problemas detectados.

Se han propuesto múltiples enfoques para realizar la detección y el diagnóstico de fallas, de los cuales se puede hacer la siguiente clasificación:

- Métodos basados en modelos matemáticos del proceso. Son estrategias que hacen uso de un modelo formulado a partir del conocimiento de las dinámicas involucradas en el proceso. Se fundamentan en la obtención de una diferencia entre las salidas del proceso y de un modelo del proceso, de donde se infiere la presencia de una falla. Este enfoque representa un costo computacional muy bajo y únicamente puede ser aplicado a procesos donde es posible obtener dicho modelo de forma analítica, lo que limita su aplicación en sistemas no lineales. La obtención de los parámetros del proceso también representa una gran dificultad, la cual puede ser abordada por técnicas de identificación de sistemas.
- Métodos a partir de modelos obtenidos de datos históricos del proceso. Para sistemas donde es posible recolectar numerosos datos representativos de su operación, tanto en condiciones normales como anómalas, es posible construir un modelo mediante técnicas como redes neuronales o modelos difusos del tipo Takagi-Sugeno. Estos enfoques son generalmente costosos computacionalmente y requieren de grandes volúmenes de datos representativos, los cuales en algunas ocasiones no están disponibles. Resultan muy útiles para obtener modelos de sistemas dinámicos no lineales.
- Métodos a partir de datos del proceso. Parten igualmente de grandes volúmenes de datos históricos, pero desde una

perspectiva diferente en la que no se busca obtener un modelo del proceso, sino resolver un problema de clasificación. Para este propósito se ha propuesto el uso de clasificadores difusos, análisis de componentes principales, redes neuronales artificiales, máquinas con vectores de soporte, funciones de base radial, entre otras. El principal inconveniente de estas técnicas radica en el costo computacional y en que generalmente operan como un sistema de "caja negra", incapaz de brindar información adicional sobre la falla.

Considerando las alternativas planteadas para la detección y diagnóstico de fallas, existen algunas características deseables con las cuales es posible comparar el desempeño de las estrategias como se detallan en [1].

Se han realizado múltiples revisiones sobre desarrollos y aplicaciones de la detección y diagnóstico de fallas. En [1] se presentan trabajos que hacen uso de modelos formales y técnicas del control clásico. Dicho artículo es complementado en [2], para modelos cualitativos y en [3] para métodos a partir de datos. De igual forma, en [4] se sistematiza la revisión en torno a métodos numéricos, de inteligencia artificial, o combinaciones de los dos.

Los métodos de detección y diagnóstico de fallas basados en la teoría de control y la estadística, han sido investigados principalmente por la comunidad FDI (por sus siglas en inglés). Una clase de técnicas basadas en modelos que utilizan la informática y la Inteligencia Artificial tienen actualmente una investigación activa por parte la comunidad de diagnóstico o DX, que utiliza modelos cualitativos y enfoques de lógica.

Este artículo recoge los resultados de trabajos recientemente publicados por la comunidad DX, que hacen uso de técnicas de inteligencia artificial, tales como las redes neuronales artificiales, los sistemas de inferencia difusa y neurodifusa y los sistemas inmunes, con el fin de actualizar la perspectiva teórica desarrollada en los últimos años, identificando las principales tendencias presentes en este tema.

Como se evidencia en [3-8], las redes neuronales y la lógica difusa han sido ampliamente utilizadas en el desarrollo de sistemas de detección y diagnóstico de fallas, debido a sus habilidades de aprendizaje puesto que se tratan de aproximadores universales.

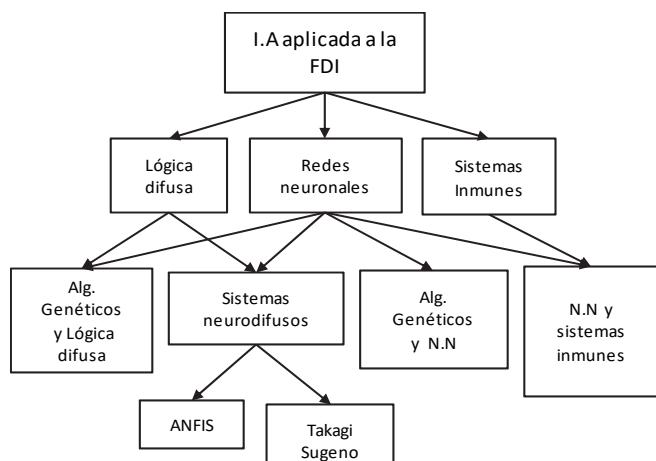


Figura 2. Clasificación de métodos de identificación y diagnóstico de fallas con inteligencia artificial.

Fuente: Los autores.

Con el objetivo de realizar un análisis de las distintas perspectivas desde las cuales se ha abordado la detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, se sugiere la división jerárquica de la Figura 2.

Dentro de los trabajos desarrollados, tienen gran relevancia el proyecto DAMADICS (Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems) [9], que constituye un esfuerzo para analizar comparativamente técnicas de detección y diagnóstico de fallas en un entorno estándar.

2. Redes neuronales artificiales para detección y diagnóstico de fallas

Las Redes Neuronales Artificiales o ANN han sido ampliamente utilizadas en tareas de identificación y diagnóstico de fallas dadas sus capacidades de aproximar cualquier función multivariada lineal o no lineal, a partir de datos.

Dicha cualidad ha sido explotada en dos tendencias principales, las técnicas que hacen uso de un modelo de regresión del proceso, para luego ser contrastado con el proceso real y obtener un residuo; y las técnicas que modelan directamente los datos de salida tanto para condiciones de operación normal como anormal.

2.1. Técnicas orientadas a datos

Los esquemas de detección y diagnóstico de fallas sin modelo, intentan descubrir comportamientos del sistema a partir del análisis de sus salidas. Se han propuesto múltiples enfoques para esta tarea, que van desde el uso de técnicas de procesamiento de señales, hasta el uso de herramientas estadísticas como el análisis de componentes principales. A continuación, se enumeran algunas de las estrategias orientadas a datos que hacen uso de redes neuronales.

En [10] se analiza la calidad de la aproximación de una red neuronal completamente interconectada frente a una red neuronal parcialmente interconectada para modelar un sistema dinámico no lineal. El criterio propuesto para realizar la interconexión parcial, consiste en que las entradas para cierto instante de tiempo forman una sub red, y la salida del sistema se logra con la interconexión de dichas sub redes. La funcionalidad se comprueba mediante el modelamiento de la dinámica de un avión, encontrando calidades comparables en la aproximación, pero con un costo computacional mucho menor.

En [11] se presenta la aplicación de una red neuronal múltiple (una red en la que cada uno de sus nodos es a su vez una red neuronal) aplicada a la supervisión del funcionamiento de un circuito electrónico. Los datos de entrenamiento corresponden a las entradas y salidas del circuito para diferentes instantes de tiempo.

En [12] se presenta una red neuronal como un sistema de diagnóstico de fallas aplicado a una planta de llenado de botellas. Se presentan 6 posibles escenarios de falla como la ausencia de botellas, de líquido o baja presión de aire. Uno de los principales aportes de este trabajo consiste en la selección de la arquitectura de la red a partir de un algoritmo genético en el que para cada individuo se genera una topología para luego ser entrenada mediante

retropropagación. Luego de un número establecido de iteraciones, se evalúa el desempeño penalizando las arquitecturas más complejas.

En [13] se aplica un esquema basado en datos del proceso para la identificación de fallas en motores de inducción. Se propone el uso de una red neuronal retroalimentada o de un mapa auto organizativo. Con el fin de que el sistema opere en tiempo real, se propone realizar un análisis de componentes principales previo al proceso de clasificación, para el cual se definieron 4 posibles estados en el motor (3 fallas y un estado normal). Este pre procesamiento reduce notablemente el costo computacional del entrenamiento del sistema. De igual forma, en [14] se plantea una aplicación de un sistema de detección y diagnóstico de fallas para una planta purificadora de humo en termoeléctricas. Se propone por lo tanto, modelar el proceso mediante una Red Neuronal Perceptron Multicapa o MPNN. La red propuesta considera únicamente las entradas, ignorando la dinámica del sistema.

En [15] se describe un esquema de detección de fallas orientado al manejo en línea de grandes volúmenes de información. Se propone inicialmente el pre procesamiento de datos mediante Análisis de Componentes Principales o PCA, para luego modelar las relaciones mediante una red neuronal con funciones de base elipsoidal. Se presentan ejemplos de aplicación para un motor a gas con datos simulados y reales.

En [16] se aborda el problema de la detección de fallas en manipuladores robóticos. Se presenta un esquema de modelamiento de algunos parámetros específicos del manipulador como la aceleración en sus articulaciones. El objetivo de este modelamiento es poder estimar a futuro el estrés al que han estado sometidos los componentes del robot para poder diseñar planes de mantenimiento. Los datos son medidos por acelerómetros y luego digitalizados en un procesador mediante un sistema de adquisición. Con dichos datos se entrena dos redes neuronales, una con Funciones de Base Radial o RBFNN y otra basada en un Mapa Auto Organizativo o SOMNN.

En [17] se propone la detección de fallas para una electroválvula a partir de algunos parámetros de operación que arroja un software de supervisión dedicado. Dichos datos conforman un vector de entrenamiento para una red neuronal retroalimentada. El objetivo del sistema radica en descubrir ciertas tendencias en los parámetros monitoreados presentes antes de la ocurrencia de una falla.

En [18] se introduce un esquema de detección de fallas aplicado a transmisiones, engranajes y rodamientos sin hacer uso de modelos. Este esquema pre procesa las señales de vibración del sistema mediante la transformada de ondícula y luego, a partir de las desviaciones estándar de los coeficientes, se entrena una red neuronal con una salida para cada una de las posibles fallas del sistema.

2.2. Generación de residuos

Un esquema general de un sistema de generación de residuos con RNA, puede verse en la Fig. 3, donde se tiene un modelo del proceso ejecutándose paralelamente con el proceso real. Las salidas son comparadas y a partir de las características de sus diferencias es posible estimar la presencia de una falla.

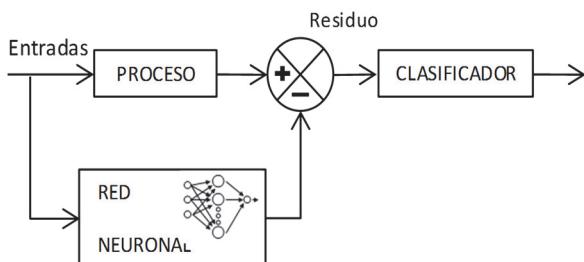


Figura 3. Esquema de un sistema generador de residuos a partir de RNA.
Fuente: Los autores.

Trabajos como los presentados en [18, 19], proponen una estrategia de generación de residuos acompañada de un sistema de aislamiento de fallas, ambos mediante redes neuronales. En [19] la topología de las redes de modelamiento y clasificación del error son escogidas de forma empírica intentando minimizar el error cuadrático medio de aproximación. La funcionalidad del sistema propuesto es evaluada mediante los datos del sistema descrito en [9]. Igualmente en [20], se plantea una red neuronal orientada al modelamiento tolerante a la incertidumbre, de tal forma que el modelo del sistema obtenido es capaz de soportar ciertos errores en sus parámetros y presentar aún una salida consistente. El sistema propuesto también se aplica al problema descrito en [9].

En [21] se propone una serie de tiempo combinada con una RBFNN para crear un predictor un paso adelante. El modelo predice una salida en el siguiente instante de tiempo discreto $k+1$ y con base en la diferencia con la salida medida se obtiene un residuo. Dependiendo del tamaño del residuo se detecta la falla. La ventaja de la propuesta consiste en la continua actualización del modelo. La funcionalidad se comprueba en la detección de una avería en un avión de combate.

2.3. Evaluación de residuos

En la detección y diagnóstico de fallas, un residuo consiste en la diferencia entre el comportamiento del proceso real y un modelo de su funcionamiento en condiciones normales. La existencia de un residuo se traduce en la detección de una falla y de la caracterización de dicho residuo se desprende la identificación del tipo de falla.

Múltiples escenarios son posibles a la hora de evaluar un residuo, como la detección de una falla conocida, desconocida o de múltiples fallas simultáneas. En [22] se propone una arquitectura de “redundancia analítica”, en lugar de tener sensores repetidos, se tienen modelos de cada uno de los componentes principales del sistema. En cada uno de los modelos se implementa mediante una red neuronal y se obtienen múltiples residuos lo que permite la identificación de fallas múltiples en el sistema. La funcionalidad de la propuesta se comprueba mediante su aplicación a un vehículo aéreo no tripulado.

2.4. Reflexión y proyección de las RNA en FDI

Las redes neuronales artificiales han sido ampliamente aplicadas debido a su característica de aproximación

universal lo que evita entrar en fases complejas de modelamiento analítico. Sin embargo, estas estrategias presentan inconvenientes sobre todo ante la presencia de nuevas fallas y de fallas múltiples. La adaptabilidad es baja debido a que requiere nuevas fases de entrenamiento lo que dificulta la identificación de fallas en línea. Estas deficiencias pueden ser abordadas por estrategias que realicen la adaptación continua de las redes a partir de información *on line*, o mediante el uso de arquitecturas dinámicas diferentes al enfoque tradicional de un modelo de falla.

3. Sistemas de lógica difusa para detección y diagnóstico de fallas.

Los sistemas basados en Lógica Difusa o LD han sido eficientemente aplicados en problemas de detección y diagnóstico de fallas. Una de las principales cualidades de dichos sistemas radica en la interpretabilidad del diagnóstico efectuado que se obtiene al observar las distintas reglas activadas en el proceso de inferencia.

Como se mencionó en la sección anterior para el caso del uso de las redes neuronales artificiales en la detección y diagnóstico de fallas, de manera análoga, las técnicas difusas han sido implementadas, tanto en arquitecturas que hacen uso de modelos y residuos, como en estructuras que modelan y procesan directamente las entradas y salidas del proceso sin un modelo explícito. Algunas de las técnicas propuestas se describen a continuación.

En [23] se presenta un análisis comparativo entre las técnicas difusas frente a las Funciones de Base Radial o RBF, viendo el problema diagnóstico como un problema de clasificación.

Por otro lado, en [24] se presenta un sistema de inferencia difuso aplicado a un problema de detección de fallas de un sistema de control de nivel de tanques. A partir de la simulación del proceso, se extraen los datos de entrenamiento para 9 posibles tipos de fallas, las cuales pueden estar presentes en un 10%, 25% o 40%. Se tienen 27 reglas y el ajuste del sistema se alcanza mediante la modificación de los puntos de frontera para cada uno de los conjuntos difusos. Se realiza el entrenamiento mediante descenso del gradiente, recocido simulado y algoritmos genéticos, minimizando el error cuadrático medio. Se comparan los resultados del sistema de diagnóstico con otro realizado mediante redes neuronales encontrando un mejor desempeño para el basado en lógica difusa.

En [25] se describe una arquitectura basada en un modelo del proceso en funcionamiento normal y k modelos del funcionamiento bajo fallas. Los residuos son calculados entre los modelos de las fallas y la salida real, y en el momento en que el residuo esté por debajo de un umbral, la falla será detectada. Esta arquitectura puede ser utilizada indistintamente del modelo del proceso que se tenga, bien sea analítico u obtenido a partir de datos. Los modelos de ejemplo son del tipo Takagi-Sugeno, cuya estructura y parámetros son obtenidos mediante propuestas realizadas en trabajos previos. La aplicación de ejemplo hace uso de los datos propuestos en [9].

Por otro lado, en [26, 27], se presenta un enfoque que permite identificar las desviaciones del sistema de un punto

de operación deseado y crea nuevos clusters correspondientes a los distintos estados de operación. Dicho procedimiento de entrenamiento puede ser realizado en línea. El algoritmo es evaluado en un sistema de control de flujo de agua dentro de un hervidor industrial.

En [27] se diseña un sistema del tipo Takagi-Sugeno complementado al que denominan Gaussian Evolving Fuzzy Modeling System. Una de las principales particularidades de la arquitectura propuesta radica en su capacidad de realizar aprendizaje en línea y fuera de línea, lo que permite la continua actualización de la herramienta de diagnóstico. Otra de sus características consiste en el aprendizaje adaptativo, ya que tiene en cuenta el conocimiento ya aprendido antes de crear un nuevo cluster, lo que lo hace robusto ante el ruido y a su vez sensible a nuevos estados del proceso. La arquitectura se pone a prueba modelando una ecuación diferencial con retardos y un sistema de previsión de demanda energética.

En [28] se expone el uso de un autómata difuso en el que la salida del sistema es modelada a partir de su fraccionamiento en segmentos lineales, los cuales son utilizados para generar patrones. El comportamiento del sistema se modela a partir de las transiciones entre patrones y se asocia a cada uno de ellos una función de pertenencia. La obtención de dicho patrón con una función de pertenencia que sobrepase cierto umbral se interpreta como un funcionamiento normal del sistema. Luego, al variar algún parámetro mediante la simulación de una falla, se puede obtener un patrón similar pero con funciones de pertenencia bajo el umbral definido, eso es lo que permite la detección.

En [29] se plantea un sistema de detección y diagnóstico específico para un sistema de distribución de energía. Dicho sistema se modela mediante conceptos de lógica difusa y la sintonización fina de los parámetros del sistema de diagnóstico se realiza mediante un algoritmo genético.

En [30] se expone el uso de un algoritmo genético para la obtención de la base de reglas de un sistema de inferencia difusa convencional, a partir de un conjunto de casos de entrenamiento, la función objetivo evalúa la sumatoria de la salida del sistema para cada ejemplo de entrenamiento frente a la salida deseada. El sistema se pone a prueba con un sistema de aire acondicionado.

En [31] se despliega un sistema de inferencia difusa para detectar fallas mecánicas en rodamientos. La señal es adquirida mediante un micrófono y el sistema difuso se alimenta con variables como la potencia y la variación de la señal.

En [32] se propone el uso de modelos difusos que pueden ser actualizados on-line. Se proponen múltiples modelos, uno para cada posible medida susceptible a fallas y se genera un residuo. La detección de la falla se da al sobrepasar cierto umbral definido para cada punto de trabajo denominado barra de error local.

En [33] se formula el desarrollo de múltiples modelos de referencia, tanto para las condiciones de falla como para la operación normal. Además, en línea se realiza la identificación de un modelo difuso el cual se compara continuamente con los modelos de referencia en busca de semejanzas mediante una medida difusa de similitud. La Fig. 4 describe el sistema propuesto.

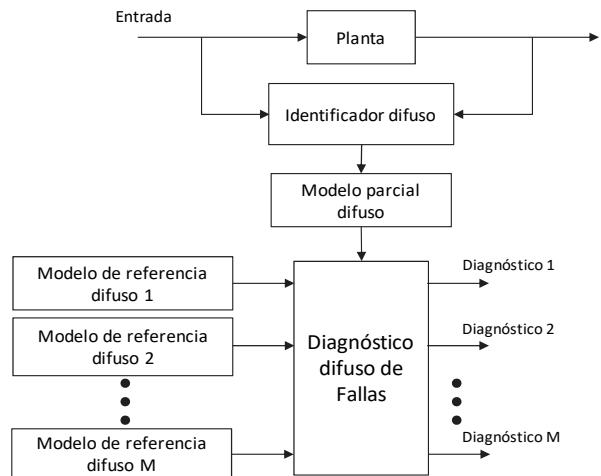


Figura 4. Esquema de detección y diagnóstico de fallas a partir de múltiples modelos de referencia difusos.
Fuente: [33].

3.1. Reflexión y proyección de la LD en FDI

Las estrategias basadas en lógica difusa favorecen la explicabilidad de los diagnósticos obtenidos. Dicha característica es muy deseable en sistemas de apoyo a la decisión. Sin embargo, sus principales deficiencias se encuentran en las fases de entrenamiento. Las múltiples estrategias aquí citadas favorecen su aplicación a partir de algoritmos automatizados de entrenamiento.

Por lo tanto, en términos generales, las estrategias que hacen uso de técnicas difusas apoyadas por algoritmos automatizados de entrenamiento son de las estrategias más promisorias y de mayor aplicabilidad en la detección y diagnóstico de fallas en línea.

4. Sistemas neurodifusos para detección y diagnóstico de fallas.

Un Sistema Adaptativo de Inferencia Neuro-Difusa o ANFIS (Adaptive Neuro-Fuzzy Inference System) combina la capacidad de los sistemas difusos para dar respuestas legibles a partir de las interpretaciones lingüísticas, con la habilidad de las redes neuronales de aprender a partir de datos.

Estos sistemas han tenido gran acogida en aplicaciones de detección y diagnóstico de fallas, dada la capacidad de justificar, al menos parcialmente, el razonamiento que lleva al diagnóstico de una falla, representa una ventaja al compararlo con un sistema de diagnóstico tipo caja negra.

A continuación se hace referencia a los desarrollos de mayor relevancia que hacen uso de los sistemas neuro-difusos.

En [34] se expone un esquema que hace uso de un modelo neuro-difuso del proceso para obtener un residuo. Cuando dicho residuo sobrepasa un umbral establecido, se detecta una falla. Para identificar de qué tipo de falla se trata, se compara estadísticamente el valor del residuo (mínimo, máximo, medio y gradiente), con una base de conocimiento heurístico derivado del conocimiento del operador del proceso, la cual puede ser actualizada continuamente. La Fig. 5 presenta la arquitectura propuesta.

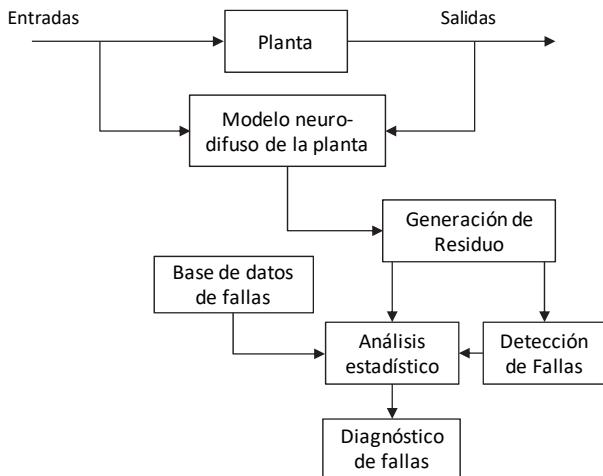


Figura 5. Detección y diagnóstico de fallas a partir de análisis estadístico de residuos.

Fuente: [34].

En [35] se despliega una arquitectura basada en una RBFNN que construye hiper-rectángulos donde cada uno de ellos cubre una región del espacio de clasificación correspondiente a una clase. La red se acompaña de un sistema de generación de reglas que intenta explicar la decisión en términos lingüísticos, lo que permite solventar la principal desventaja de las redes neuronales para el diagnóstico, su incapacidad de explicar sus decisiones. La arquitectura propuesta se aplica a un sistema de distribución de agua.

Por otro lado, en [36] se formula una aplicación sobre el mismo sistema de prueba propuesto en [9] que consiste de un sistema ANFIS para la obtención de un modelo del sistema a partir de datos. La obtención de los residuos para el diagnóstico se realiza mediante una resta directa entre las salidas reales y modeladas del sistema, y un filtro pasa bajos para eliminar la sensibilidad excesiva del sistema. Estos residuos alimentan otro conjunto de modelos neuro-difusos que opera como un clasificador. Cada uno de los sistemas ANFIS del clasificador está relacionado con una falla específica del sistema, permitiendo así la detección de múltiples fallas de forma simultánea.

En [37] se expone el análisis de un sistema complejo (turbina de vapor) mediante su descomposición en sistemas más simples para mejorar el desempeño del diagnóstico. El criterio para la distribución de variables se da a partir del conocimiento del proceso. Cada uno de los sub sistemas y sus correspondientes fallas son representados mediante un sistema ANFIS. Este enfoque justifica, además, en que el modelo de un sistema sencillo resulta más confiable y fácil de obtener que en el modelo de un sistema completo.

En [38] se detalla el uso de un sistema ANFIS generalizado que permite tener múltiples salidas del sistema denominado Coactive Adaptive Neuro-Fuzzy System o CANFIS. El algoritmo se aplica a un sistema de monitoreo del estado de vías férreas. En lugar de proponer múltiples sistemas ANFIS, se construye un único modelo lo que reduce de forma importante la cantidad de parámetros a ajustar. El modelo consta de 8 mediciones de voltaje y corriente en distintos puntos del circuito como variables de entrada, y 10 salidas, cada una de ellas correspondiente a una posible falla.

Las salidas fueron divididas en 3 posibles estados, la ausencia de falla, el deterioro y la falla como tal.

En [39, 40], se presenta el problema de la obtención de un modelo difuso del proceso del tipo Takagi-Sugeno. Con el objetivo de manejar la incertidumbre del modelo se plantea la evaluación de los residuos a partir de umbrales adaptativos. Finalmente en [39] se diseña un experimento con datos provenientes de un motor eléctrico para comprobar la funcionalidad de la metodología propuesta, se resalta la importancia de incluir la dinámica del sistema dentro del modelo mediante la inclusión de las salidas y entradas retrasadas como entradas de la red. En [40] se extiende el algoritmo de entrenamiento planteado a una red neuro-difusa y se aplica al problema de prueba propuesto en [9].

En [41] se propone el uso de un sistema tipo Takagi-Sugeno para cada escenario de fallas posible, junto con el modelamiento del estado normal de operación, y de acuerdo a la comparación final entre el estado real de la planta y la salida de los múltiples modelos, se realiza el diagnóstico final. Como novedad se plantea el uso del algoritmo LOLIMOT (LOcal LInear MOdel Tree) para el entrenamiento del sistema neuro-difuso.

En [42] se tratan dos esquemas de detección basados en múltiples sistemas tipo ANFIS en paralelo para procesos MIMO (Multiple Input Multiple Output), llamados M-ANFIS. La primera fase del procesamiento consiste en la generación de residuos a partir de la comparación entre el proceso y el modelo M-ANFIS. Los residuos son posteriormente evaluados y categorizados por una red neuronal. El segundo esquema consiste en múltiples modelos M-ANFIS, uno por cada escenario de falla.

En [43] se plantea el uso de dos redes tipo ANFIS para la detección de fallas. La primera se utiliza para modelar el sistema a monitorear, mientras que la segunda para modelar los residuos. El entrenamiento de dichas redes puede ser realizado en línea mediante mínimos cuadrados. Una vez que la red dedicada a modelar los residuos ha finalizado su entrenamiento se extraen las reglas activadas para cada una de las fallas creando así una serie de patrones de fallas con relación a dicha base de reglas es posible extraer la información lingüística correspondiente a una falla, así como también para fallas múltiples. La funcionalidad del esquema propuesto es comprobada mediante un sistema de tanques en cascada, detallando el modelo, así como los parámetros de simulación de las averías y del controlador implementado. La Fig. 6 ilustra el esquema de detección propuesto.

En [44], se propone también un sistema que hace uso de múltiples modelos ANFIS, cada uno de ellos relacionado con una posible falla en particular alrededor de determinado punto de operación. Las salidas de estos modelos se contrastan con las salidas de la planta real, obteniendo así un residuo para cada uno de los escenarios planteados, lo que permite identificar la falla siempre y cuando se trate de una condición anormal prevista con anterioridad (no es sensible con fallas desconocidas). El sistema es aplicado al problema descrito en [9].

En [45] se propone también un esquema de generación de residuos a partir de un modelo difuso del proceso. Para la detección de las fallas se propone una red ANFIS. El uso de un modelo desarrollado a partir de razonamiento cualitativo, reduce bastante el costo computacional.

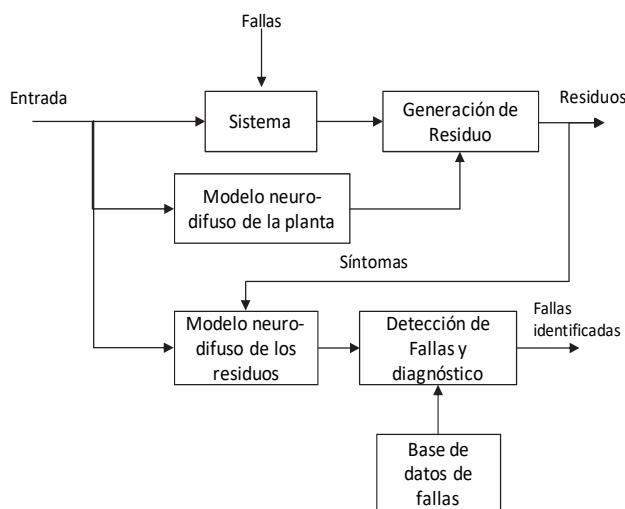


Figura 6. Esquema de detección basado en 2 ANFIS.
Fuente: [43].

Existen enfoques que plantean el uso de sistemas neurodifusos sin la necesidad de usar residuos, sino únicamente a partir de sus características como clasificadores. En [46] se plantea la detección de fallas orientado en datos a partir del uso de un clasificador neuro-difuso. La funcionalidad se comprueba con el problema DAMADICS [9], orientándose a la detección de la intensidad de cada falla.

En [47] se propone una red neuronal donde la primera de las capas ocultas es una capa difusa que se encarga de normalizar las variables de entrada. Las siguientes capas ocultas de la red operan de forma análoga a una red neuronal retroalimentada. Este sistema se orienta en la obtención de un modelo para la generación de residuos. La evaluación de dichos residuos se realiza mediante umbrales fijos.

Por último, en [48] se describe el uso de un esquema compuesto por una red neuronal complementado por un sistema de inferencia difuso que opera a partir de las observaciones de la planta, junto con la salida de la red neuronal.

4.1. Reflexión y proyección de ANFIS en FDI

El uso de sistemas ANFIS para el modelamiento de sistemas dinámicos es ampliamente aprovechado en muchas de las investigaciones aquí reportadas. Sin embargo, la reducida explicabilidad de los resultados de la inferencia resulta poco conveniente en sistemas de apoyo al diagnóstico. Otra deficiencia importante radica en la baja capacidad de detección de nuevas fallas debido al enfoque ampliamente utilizado de “modelo por falla”. Es aquí donde radica la principal oportunidad de mejora; estrategias capaces de identificar nuevas fallas a partir de estructuras dinámicas entrenadas en línea.

5. Sistemas inmunes para detección y diagnóstico de fallas.

Los sistemas inmunes por sí solos no son utilizados en la identificación y diagnóstico de fallas debido a la necesidad de un elevado proceso de cómputo. Sin embargo, han sido utilizados como herramienta de apoyo para optimizar la arquitectura de

sistemas de identificación como redes neuronales o las bases de reglas de sistemas de inferencia difusa.

En [49], se propone la optimización de la arquitectura, las funciones de activación, los parámetros de entrenamiento, el número de épocas, entre otros factores que hacen parte de la definición de una red neuronal retroalimentada, mediante un sistema inmune. Todos estos parámetros se codifican de forma binaria. El sistema se entrena con casos provenientes de un sistema de medición de calidad de agua.

En [50] se plantea un esquema de detección de fallas a partir de la emulación de la respuesta del sistema inmune. Se fundamenta en recientes estudios que plantean que la respuesta inmunológica no es ocasionada simplemente por entes extraños dentro del organismo, sino por señales de alarma desencadenadas por las células cuando no mueren naturalmente. Mediante un modelo del proceso y su comparación con el funcionamiento real, se obtiene un residuo, el cual es categorizado dentro de un clasificador difuso como una señal de peligro.

En [51] se describe un procedimiento de detección y diagnóstico de fallas inspirado en la respuesta temprana de algunas células del sistema inmune conocidas como “Asesinos Naturales”. El esquema no hace uso de un modelo ni de residuos sino únicamente de datos de entrenamiento extraídos de estados de operación normales y anormales. Inicialmente se realiza una inicialización estocástica de las células para posteriormente realizar un entrenamiento. Finalmente, cuando las células ya se encuentran “maduras” es posible iniciar el diagnóstico de fallas. El sistema de clasificación es utilizado en el sistema DAMADICS [9].

En [52] se propone un sistema de detección y diagnóstico de fallas sin modelo a partir de la clasificación de un sistema autoinmune en el que primero se presentan casos de operación normal, y luego con fallas. Con la continua presentación de fallas se crean regiones correspondientes a cada una de ellas. Pueden detectarse nuevas fallas y eliminarse las antiguas.

6. Comparación de las técnicas de inteligencia artificial para detección y diagnóstico de fallas

La presente revisión bibliográfica, se ha centrado exclusivamente en técnicas de detección y diagnóstico de fallas en sistemas que hacen uso de las principales vertientes de la inteligencia artificial como las redes neuronales, los sistemas difusos y neurodifusos, y los sistemas inmunes. Es evidente la gran cantidad de alternativas que han sido planteadas para abordar esta problemática.

Se han realizado múltiples esfuerzos para elaborar un “Benchmarking”, DAMADICS [9], proyecto que ha sido referenciado ampliamente en este trabajo es uno de los intentos de comparación con mayor relevancia, dada la gran cantidad de publicaciones derivadas de los datos provistos por este experimento. Otro referente importante a considerar es el proyecto CHEM [53], que consiste en un equipo multidisciplinario para la obtención de sistemas de soporte a la decisión para la industria química y petroquímica, un proyecto europeo de donde se generaron múltiples investigaciones a nivel de desarrollo de software y de tesis doctorales [54, 55] entre otros.

Una de las conclusiones importantes presentadas por trabajos de revisión previos [3] consiste en que las debilidades propias de cada una de las estrategias pueden ser mitigadas mediante el uso combinado de varias de ellas, lo que ha dado origen a múltiples técnicas híbridas, hecho que ha tenido amplia aceptación en las aplicaciones industriales de estos sistemas.

Como conclusión de la recopilación presentada en este artículo, la tabla 1 presenta el resultado de la comparación de las distintas estrategias aquí mencionadas frente a las características definidas en [1].

Tabla 1.
Comparación de técnicas de inteligencia artificial para detección y diagnóstico de fallas de acuerdo con las características definidas en [1].

Estrategia citada en	Aislamiento	Robustez	Identificación de novedades	Adaptabilidad	Explicabilidad	Tipo de Modelo del proceso	Costo computacional	Identificación fallas múltiples
[10]	Sí	Bajo	No	No	No	ANN	Medio	No
[11]	No	Bajo	No	No	No	Sin modelo	Medio	No
[12]	Sí	Bajo	No	No	No	Sin modelo	Medio	No
[13]	Sí	Medio	No	No	No	Sin modelo	Bajo	No
[14]	No	Bajo	No	No	No	ANN	Medio	No
[15]	Sí	Alto	Sí	Sí	No	Sin modelo	Medio	No
[16]	No	Bajo	No	No	No	Sin modelo	Bajo	No
[17]	Sí	Bajo	No	No	No	Sin modelo	Bajo	No
[18]	Sí	Medio	No	No	No	Sin modelo	Bajo	No
[19]	Sí	Medio	No	No	No	ANN	Medio	No
[20]	Sí	Medio	No	No	No	Sin modelo	Bajo	No
[21]	No	Medio	Sí	Sí	No	RBFNN	Alto	No
[22]	Sí	Medio	No	No	No	ANN	Alto	Sí
[24]	Sí	Medio	No	No	Sí	Difuso	Alto	No
[25]	Sí	Alto	No	No	Sí	Difuso	Bajo	No
[26]	Sí	Medio	Sí	Sí	Sí	Sin modelo	Alto	No
[27]	Sí	Medio	Sí	Sí	Sí	Sin modelo	Alto	No
[28]	No	Medio	Sí	No	No	Difuso	Bajo	Sí
[29]	Sí	Medio	No	No	Sí	Sin modelo	Alto	Sí
[30]	Sí	Bajo	No	No	Sí	Sin modelo	Alto	No
[31]	Sí	Medio	No	No	No	Sin modelo	Bajo	No
[32]	Sí	Medio	Sí	Sí	No	Difuso	Alto	No
[33]	Sí	Medio	No	No	No	Difuso	Alto	Sí
[34]	Sí	Medio	No	Sí	Sí	ANFIS	Alto	No
[35]	Sí	Alto	Sí	Sí	Sí	Sin modelo	Alto	No
[36]	Sí	Alto	No	No	No	ANFIS	Alto	Sí
[37]	Sí	Alto	No	Sí	ANFIS	Alto	Sí	
[38]	Sí	Medio	No	No	Sí	ANFIS	Medio	Sí
[39]	Sí	Alto	No	No	Sí	ANFIS	Alto	No
[40]	Sí	Alto	No	No	Sí	ANFIS	Alto	No
[41]	Sí	Medio	No	No	No	ANFIS	Alto	Sí
[42]	Sí	Medio	No	No	No	ANFIS	Alto	No
[43]	Sí	Medio	Sí	Sí	Sí	ANFIS	Alto	No
[44]	Sí	Medio	No	No	No	ANFIS	Alto	Sí
[45]	Sí	Medio	No	No	Sí	ANFIS	Bajo	No
[46]	Sí	Medio	Sí	Sí	No	Sin modelo	Medio	No
[47]	Sí	Alto	No	No	No	ANFIS	Medio	No
[48]	No	Medio	No	No	No	Sin modelo	Bajo	No
[49]	Sí	Medio	No	No	No	Sin modelo	Bajo	No
[50]	Sí	Medio	No	Sí	No	Analítico	Bajo	No
[51]	No	Alto	No	No	No	Sin modelo	Alto	No
[52]	Sí	Alto	Sí	Sí	No	Sin modelo	Alto	No

Fuente: Los autores.

7. Conclusiones y oportunidades de trabajo futuro

El uso de técnicas de inteligencia artificial para abordar la detección y el diagnóstico de fallas constituye en la actualidad campo activo de investigación, hecho que se refleja en la extensa literatura disponible sobre propuestas metodológicas y aplicaciones derivadas de su uso.

En el presente artículo se han organizado, clasificado y comparado algunas de ellas teniendo en cuenta algunas de las características que pueden ser consideradas como deseables en un sistema de detección y diagnóstico de fallas. La primera gran división categórica está en aquellas estrategias orientadas a residuos, frente a las que se orientan al análisis de datos de entradas y salidas del proceso sin necesidad de un modelo explícito. Del análisis frente a los factores presentados en la Tabla 2, se evidencia que las estrategias que no utilizan modelos, son más eficaces en la detección de fallas.

Por otro lado, otro enfoque ampliamente utilizado consiste en el desarrollo de múltiples modelos de proceso, en distintas condiciones de operación, tanto normal como anormal, que se están comparando continuamente con el proceso real permitiendo así identificar su estado actual. Este enfoque permite la identificación de múltiples fallas, siempre y cuando estas no estén acopladas, pero restringe la adaptabilidad del sistema y lo limita únicamente a estados conocidos.

Como alternativa para alcanzar la detección de múltiples fallas se describen algunas técnicas que descomponen el sistema total en distintos subsistemas más simples de analizar, lo que, a pesar de elevar el costo computacional, facilita la obtención de modelos locales del proceso, permitiendo además identificar el origen de una falla favoreciendo la interpretación.

Del presente análisis se concluye que las futuras estrategias de detección y diagnóstico deberán centrarse en mejorar la robustez y la adaptabilidad, permitiendo la continua evolución del sistema, centrándose además en alcanzar diagnósticos interpretables por el operador en los que se aíslen las localizaciones de las fallas y sus posibles causas.

Referencias

- [1] Venkatasubramanian, V., Rengaswamy, R., Yin K. and Kavuri, S., A review of process fault detection and diagnosis: Part I: Quantitative model-based methods, *Computers & Chemical Engineering*, 27(3), pp. 293-311, 2003. DOI: 10.1016/S0098-1354(02)00160-6.
- [2] Venkatasubramanian, V., Rengaswamy, R., Yin K. and Kavuri, S., A review of process fault detection and diagnosis: Part II: Qualitative models and search strategies, *Computers & Chemical Engineering*, 27(3), pp. 313-326, 2003. DOI: 10.1016/S0098-1354(02)00161-8.
- [3] Venkatasubramanian, V., Rengaswamy, R., Yin K. and Kavuri, S., A review of process fault detection and diagnosis: Part III: Process history based methods, *Computers & Chemical Engineering*, 27(3), pp. 327-346, 2003. DOI: 10.1016/S0098-1354(02)00162-X.
- [4] Angeli, C. and Chatzikonikolaou, A., On-line fault detection techniques for technical systems: A survey. *International Journal of Computer Science & Applications*, 1(1), pp. 12-30, 2004. DOI: 10.1.1.100.6189.

- [5] [5] Hwang, I., Kim, S. Kim, Y. and Seah, C., A survey of fault detection, isolation, and reconfiguration methods, *IEEE Transactions on Control Systems Technology*, 18(3), pp. 636-653, 2010. DOI: 10.1109/TCST.2009.2026285.
- [6] [6] Dash, S. and Venkatasubramanian, V., Challenges in the industrial applications of fault diagnostic systems, *Computers & Chemical Engineering*, 24(2-7), pp. 785-791, 2000. DOI: 10.1016/S0098-1354(00)00374-4.
- [7] [7] Marzat, J., Piet-Lahanier, H., Damongeot, F., Walter, E. et all, Autonomous fault diagnosis: state of the art and aeronautical benchmark, in *Proceedings of the 3rd European Conference for Aerospace Sciences, EUCAST'2009*, 2009. HAL: 00429743.
- [8] [8] Frank, P. and Köppen-Seliger, B., Fuzzy logic and neural network applications to fault diagnosis. *International Journal of Approximate Reasoning*, 16(1), pp. 67-88, 1997. DOI: 10.1016/S0888-613X(96)00116-8.
- [9] [9] DAMADICS, DAMADICS RTN Information Web site. [Online]. [Date of reference October 26th of 2015]. Available at: <http://diag.mchtr.pw.edu.pl/DAMADICS/>.
- [10] [10] Fekih, A. Xu, H. and Chowdhury, F., Two neural net-learning methods for model based fault detection, in *Fault Detection, Supervision and Safety of Technical Processes 2006*, Hong-Yue Zhang, Ed. Oxford: Elsevier Science Ltd, 2007. pp. 72-77. DOI: 10.3182/20060829-4-CN-2909.00011.
- [11] [11] Madani, K., A survey of artificial neural networks based fault detection and fault diagnosis techniques, in *Neural Networks. International Joint Conference on Neural Networks, IJCNN'99*, 5, pp. 3442-3446, 1999. DOI: 10.1109/IJCNN.1999.836218.
- [12] [12] Demetgul, M., Unal, M., Tansel, I. and Yazıcıoğlu, O., Fault diagnosis on bottle filling plant using genetic-based neural network, *Advances in Engineering Software*, 42(12), pp. 1051-1058, 2011. DOI: 10.1016/j.advengsoft.2011.07.004.
- [13] [13] Ghate, V. and Dudul, S., Optimal MLP neural network classifier for fault detection of three phase induction motor, *Expert Systems with Applications*, 37(4), pp. 3468-3481, 2010. DOI: 10.1016/j.eswa.2009.10.041.
- [14] [14] Krzysztof, S., Neural networks based diagnostic system for industrial purifying fumes installation, in *Fault Detection, Supervision and Safety of Technical Processes 2006*, Hong-Yue Zhang, Ed. Oxford: Elsevier Science Ltd, 2007, pp. 681-686.
- [15] [15] Jakubek, S. and Strasser, T., Artificial neural networks for fault detection in large-scale data acquisition systems, *Engineering Applications of Artificial Intelligence*, 17(3), pp. 233-248, 2004. DOI: 10.1016/j.engappai.2004.03.002.
- [16] [16] Eski, I., Erkaya, S., Savas, S. and Yildirim, S., Fault detection on robot manipulators using artificial neural networks, *Robotics and Computer-Integrated Manufacturing*, 27(1), pp. 115-123, 2011. DOI: 10.1016/j.rcim.2010.06.017.
- [17] [17] Karpenko, M. and Sepehri, N., A neural network based fault detection and identification scheme for pneumatic process control valves, in *2001 IEEE International Conference on Systems, Man, and Cybernetics*, 1, pp. 93-98, 2001. DOI: 10.1109/ICSMC.2001.969794.
- [18] [18] Sadeghi, M., Rafiee, J., Arvani, F. and Harifi, A., A Fault detection and identification system for gearboxes using neural networks, in *International Conference on Neural Networks and Brain, ICNNB'05*, 2, pp. 964-969, 2005. DOI: 10.1109/ICNNB.2005.1614780.
- [19] [19] Kourd, Y. and Guersi, N., Faults diagnosis by neural networks application on DAMADICS Benchmark, in *4th International Conference on Computer Integrated Manufacturing CIP'2007*, 2007.
- [20] [20] Witczak, M., Korbicz, J., Mrugalski, M. and Patton, R., A GMDH neural network-based approach to robust fault diagnosis: Application to the DAMADICS benchmark problem, *Control Engineering Practice*, 14(6), pp. 671-683, 2006. DOI: 10.1016/j.conengprac.2005.04.007.
- [21] [21] Zhengdao, Z. and Weihua, Z., Neural network based fault detection and identification for fighter control surface failure, in *Control and Decision Conference, CCDC'09*, pp. 5256-5261, 2009.
- [22] [22] Samy, I., Postlethwaite, I. and Gu, D., Survey and application of sensor fault detection and isolation schemes, *Control Engineering Practice*, 19(7), pp. 658-674, 2011. DOI: 10.1016/j.conengprac.2011.03.002.
- [23] [23] Catelani, M. and Fort, A., Soft fault detection and isolation in analog circuits: some results and a comparison between a fuzzy approach and radial basis function networks, *IEEE Transactions on Instrumentation and Measurement*, 51(2), pp. 196-202, 2002. DOI: 10.1109/19.997811.
- [24] [24] White, C. and Lakany, H., A fuzzy inference system for fault detection and isolation: Application to a fluid system, *Expert Systems with Applications*, 35(3), pp. 1021-1033, 2008. DOI: 10.1016/j.eswa.2007.08.029.
- [25] [25] Mendonça, L., Sousa, J. and Sá da Costa, J., An architecture for fault detection and isolation based on fuzzy methods, *Expert Systems with Applications*, 36(2), Part 1, pp. 1092-1104, 2009. DOI: 10.1016/j.eswa.2007.11.009.
- [26] [26] Lemos, A. Caminhas, W. and Gomide, F., Adaptive fault detection and diagnosis using an evolving fuzzy classifier, *Information Sciences: An International Journal*, 222, 64-85, 2013. DOI: 10.1016/j.ins.2011.08.030.
- [27] [27] Lemos, A. Caminhas, W. and Gomide, F., Multivariable Gaussian Evolving Fuzzy Modeling System, *IEEE Transactions on Fuzzy Systems*, 19(1), pp. 91-104, Feb. 2011. DOI: 10.1109/TFUZZ.2010.2087381.
- [28] [28] Rigatos, G., Fault detection and isolation based on fuzzy automata, *Information Sciences*, 179(12), pp. 1893-1902, 2009. DOI: 10.1016/j.ins.2009.01.015.
- [29] [29] Srinivasan, D., Cheu, R. Poh, Y. and Ng, A., Automated fault detection in power distribution networks using a hybrid fuzzy-genetic algorithm approach, *Engineering Applications of Artificial Intelligence*, 13(4), pp. 407-418, 2000. DOI: 10.1016/S0952-1976(00)00012-9.
- [30] [30] Lo, C., Chan, P., Wong, Y., Rad, A. and Cheung, K., Fuzzy-genetic algorithm for automatic fault detection in HVAC systems, *Applied Soft Computing*, 7(2), pp. 554-560, 2007. DOI: 10.1007/s12273-016-0285-4.
- [31] [31] Boutros, T. and Liang, M., Mechanical fault detection using fuzzy index fusion, *International Journal of Machine Tools and Manufacture*, 47(11), pp. 1702-1714, 2007. DOI: 10.16/j.ijmachtools.2007.01.001.
- [32] [32] Lughofer, E. and Guardiola, C., Applying evolving fuzzy models with adaptive local error bars to on-line fault detection, in *3rd International Workshop on Genetic and Evolving Systems, GEFS 2008*, pp. 35-40, 2008. DOI: 10.1109/GEFS.2008.4484564.
- [33] [33] Ganjehdesh, Y., Manjili, Y., Vafaei, M., Zamanzadeh, E. and Jahanshahi, E., Fuzzy fault detection and diagnosis under severely noisy conditions using feature-based approaches, in *2008 American Control Conference*, pp. 3319-3324, 2008. DOI: 10.1109/ACC.2008.4587004.
- [34] [34] Shabanian, M., and Montazeri, M., A neuro-fuzzy online fault detection and diagnosis algorithm for nonlinear and dynamic systems, *International Journal of Control, Automation and Systems*, 9(4), pp. 665-670, 2011. DOI: 10.1007/s12555-011-0407-9.
- [35] [35] Tan, S., Lim, C. and Rao, M., A hybrid neural network model for rule generation and its application to process fault detection and diagnosis, *Engineering Applications of Artificial Intelligence*, 20(2), pp. 203-213, 2007. DOI: 10.1016/j.engappai.2006.06.007.
- [36] [36] Kourd, Y., Guersi, N. and Lefebvre, D., Neuro-fuzzy approach for default Diagnosis: Application to the DAMADICS, in *4th IEEE International Conference on Digital Ecosystems and Technologies, DEST*, pp. 107-111, 2010. DOI: 10.1109/DEST.2010.5610663.
- [37] [37] Salahshoor, K., Khoshro, M. and Kordestani, M., Fault detection and diagnosis of an industrial steam turbine using a distributed configuration of adaptive neuro-fuzzy inference systems, *Simulation Modelling Practice and Theory*, 19(5), pp. 1280-1293, 2011. DOI: 10.1016/j.simpat.2011.01.005.
- [38] [38] Chen, J., Roberts, C. and Weston, P., Fault detection and diagnosis for railway track circuits using neuro-fuzzy systems, *Control Engineering Practice*, 16(5), pp. 585-596, 2008. DOI: 10.1016/j.conengprac.2007.06.007.
- [39] [39] Kowal, M., Fault detection under fuzzy model uncertainty, *International Journal of Automation and Computing*, 4(2), pp. 117-124, 2007. DOI: 10.1007/s11633-007-0117-1.
- [40] [40] Korbicz, J. and Kowal, M., Neuro-fuzzy networks and their application to fault detection of dynamical systems, *Engineering*

- Applications of Artificial Intelligence, 20(5), pp. 609-617, 2007. DOI: 10.1016/j.engappai.2006.11.009.
- [41] [41]Sadeghian, M. and Fatehi, A., Identification, prediction and detection of the process fault in a cement rotary kiln by locally linear neuro-fuzzy technique, Journal of Process Control, 21(2), pp. 302-308, 2011. DOI: 10.1016/j.jprocont.2010.10.009.
- [42] [42]Yüksel, T. and Sezgin, A., Two fault detection and isolation schemes for robot manipulators using soft computing techniques, Applied Soft Computing, 10(1), pp. 125-134, 2010. DOI: 10.1016/j.asoc.2009.06.011.
- [43] [43]Mok, H. and Chan, C., Online fault detection and isolation of nonlinear systems based on neurofuzzy networks, Engineering Applications of Artificial Intelligence, 21(2), pp. 171-181, 2008. DOI: 10.1016/j.engappai.2007.04.002.
- [44] [44]Uppal, F., Patton, R. and Witczak, M., A neuro-fuzzy multiple-model observer approach to robust fault diagnosis based on the DAMADICS benchmark problem, Control Engineering Practice, 14(6), pp. 699-717, 2006. DOI: 10.1016/j.conengprac.2005.04.015.
- [45] [45]Calado, J., Sá da Costa, J., Bartys, M. and Korbicz, J., FDI approach to the DAMADICS benchmark problem based on qualitative reasoning coupled with fuzzy neural networks, Control Engineering Practice, 14(6), pp. 685-698, 2006. DOI: 10.1016/j.conengprac.2005.03.025.
- [46] [46]Bocaniala, C. and Sá da Costa, J., Application of a novel fuzzy classifier to fault detection and isolation of the DAMADICS benchmark problem, Control Engineering Practice, 14(6), pp. 653-669, 2006. DOI: 10.1016/j.conengprac.2005.06.008.
- [47] [47]Xu, Y. and Wang, Z., On a fault detection system based on neuro-fuzzy fusion method, in Control and Decision Conference, CCDC, 2010, pp. 3190-3193, 2010. DOI: 10.1109/CCDC.2010.5498631.
- [48] [48]Ruiz, D., Nougués, J. and Puigjaner, L., Fault diagnosis support system for complex chemical plants, Computers & Chemical Engineering, 25(1), pp. 151-160, 2001. DOI: 10.1016/S0098-1354(00)00638-4.
- [49] [49]Chen, X. and Huang, H., Immune feedforward neural network for fault detection, Tsinghua Science & Technology, 16(3), pp. 272-277, 2011. DOI: 10.1016/S1007-0214(11)70039-6.
- [50] [50]Laurentys, C., Palhares, R. and Caminhos, W., Design of an artificial immune system based on Danger Model for fault detection, Expert Systems with Applications, 37(7), pp. 5145-5152, 2010. DOI: 10.1016/j.eswa.2009.12.079.
- [51] [51]Laurentys, C., Palhares, R. and Caminhos, W., A novel Artificial Immune System for fault behavior detection, Expert Systems with Applications, 38(6), pp. 6957-6966, 2011. DOI: 10.1016/j.eswa.2010.12.019.
- [52] [52]Weng, L., Bikdash, M., Liao, X. and Song, D., Immune system inspired fault detection and identification with application to crew exploration vehicles, in Proceeding of the Thirty-Eighth Southeastern Symposium on System Theory, SSST'06, pp. 372-376, 2006. DOI: 10.1109/SSST.2006.1619127.
- [53] [53]Cauvin, S. and Celse, B., CHEM: Advanced decision support systems for chemical/petrochemical process industries, in Computer Aided Chemical Engineering, 18, A. Barbosa-Póvoa and H. Matos, Ed. Elsevier, pp. 1027-1032, 2004. DOI: 10.1016/S1570-7946(04)80237-2.
- [54] [54]Kempowski, T., Surveillance de procédés à base de méthodes de classification: conception d'un outil d'aide pour la détection et le diagnostic des défaillances, INSA de Toulouse, 2004. tel-00010247.
- [55] [55]Gamero, F., Colomer, J., Meléndez, J. and Berjaga, X., Qualtras: A tool for qualitative trend representations, in 20th International Workshop on Principles of Diagnosis, Stockholm, pp. 187-194, 2009.

L.L. Hurtado-Cortés, obtuvo su título de Ing. Mecánico en 1995 de la Universidad INCCA de Colombia, su MSc. en Ingeniería en 2005 y su PhD. en Ingeniería en 2014 ambos de la Universidad Nacional de Colombia. Ha sido docente en la Universidad Nacional de Colombia, Universidad de San Buenaventura, Universidad INCCA de Colombia y Universidad Católica de Colombia. Actualmente es profesor asociado en la Universidad Distrital Francisco José de Caldas y profesor adjunto en la Universidad Autónoma de Colombia. Sus áreas de interés son control automático, automatización industrial y sistemas humano-máquina.
ORCID: 0000-0002-1675-9471

E. Villarreal-López, obtuvo su título de Ing. de Diseño y Automatización Electrónica en 2004 de la Universidad de la Salle, su MSc. en Automatización Industrial en 2008 de la Universidad Nacional de Colombia, actualmente cursa estudios de Doctorado en Ingeniería de Sistemas en la Universidad Nacional de Colombia. Ha sido docente en la Universidad de la Salle, Universidad Autónoma de Colombia, Universidad Manuela Beltrán y Universidad Jorge Tadeo Lozano. Actualmente es docente de la Universidad de San Buenaventura. Sus áreas de interés son control automático, automatización industrial y sistemas inteligentes.
ORCID: 0000-0002-1401-955X

L. Villarreal-López, obtuvo su título de Ing. Industrial en 2001 de la Universidad Distrital Francisco José de Caldas, su MSc. en Automatización Industrial en 2004 de la Universidad Nacional de Colombia. Ha sido profesor en la Universidad Católica, Universidad Autónoma de Colombia, Universidad Militar y Universidad Manuela Beltrán. Actualmente es docente de la Fundación Universitaria Agraria de Colombia. Sus áreas de interés son Control Automático y Automatización Industrial.
ORCID: 0000-0002-0921-035X



UNIVERSIDAD NACIONAL DE COLOMBIA

SEDE MEDELLÍN

FACULTAD DE MINAS

Área Curricular de Ingeniería
de Sistemas e Informática

Oferta de Posgrados

Especialización en Sistemas
Especialización en Mercados de Energía
Maestría en Ingeniería - Ingeniería de Sistemas
Doctorado en Ingeniería- Sistema e Informática

Mayor información:

E-mail: acsei_med@unal.edu.co

Teléfono: (57-4) 425 5365