

Diagnosis of Industrial Processes through Prediction of Functional States with Artificial Intelligence

Diagnóstico de Procesos Industriales Mediante Predicción de Estados Funcionales con Inteligencia Artificial

J. A. Ramírez-Urrego  ; H. O. Sarmiento-Maldonado  ; J. M. López-Lezama 

Abstract— This work presents the design of an intelligent strategy for the automatic diagnosis of processes by means of Artificial Neural Networks (ANNs) prediction and fuzzy classification. To design the diagnosis strategy, historical information of the process is used. The classification is implemented as a tool for the diffuse grouping of patterns. ANNs of multilayer configuration were trained to predict the functional states of the process. The outputs in the prediction stage are the entries of the classifier. In the proposed diagnostic scheme, the functional states are presented to operators of the processes, as future information to generate the predictive-preventive actions before the transition to a fault state. The proposed strategy was implemented on a conventional control system; and on a medicinal air production system. In this last system, the predictor of functional states presented filtration capacity in the observation of relative humidity, which is considered as an additional gain in the design, as it is a variable of difficult prediction in tropical climates. It can be concluded that the proposed methodology is able to make appropriate diagnoses of both industrial processes.

Index Terms— fuzzy clustering, diagnosis, artificial intelligence, neuronal network.

Resumen— Este artículo presenta el diseño de una estrategia inteligente, para el diagnóstico automático de procesos industriales mediante la predicción con Redes Neuronales Artificiales (RNAs) y clasificación difusa. Para diseñar la estrategia de diagnóstico se utilizó información histórica del proceso. La clasificación fue implementada como herramienta para el agrupamiento difuso de patrones. Las RNAs de

Este manuscrito fue enviado el 05 de mayo de 2019 y aceptado el 25 de noviembre de 2019.

This work was supported by the Sustainability Program of the University of Antioquia and the Research Group of Automatic Control and Robotics Instrumentation (ICARO) of the Politécnico Colombiano Jaime Isaza Cadavid, Medellín, Colombia.

J. A. Ramírez-Urrego is with Politécnico Colombiano Jaime Isaza Cadavid (PCJIC), Cr 48 No 7-151, el Poblado, Medellín, Colombia (e-mail: jhon_ramirez91081@elpoli.edu.co).

H. O. Sarmiento Maldonado is with Politécnico Colombiano Jaime Isaza Cadavid (PCJIC), Cr 48 No 7-151, el Poblado, Medellín, Colombia (e-mail: hosarmiento@elpoli.edu.co).

J. M. López-Lezama is with the Department of Electrical Engineering, University of Antioquia (UdeA), Calle 67 No 53-108, Medellín, Colombia (e-mail: jmaria.lopez@udea.edu.co).

configuración multicapa fueron entrenadas para predecir los estados funcionales del proceso. Las salidas en la etapa de predicción son las entradas del clasificador. En el esquema de diagnóstico propuesto la estimación de los estados funcionales es presentada a los operarios de los procesos, como información futura para generar las acciones preventivas antes de la transición hacia un estado de falla. La estrategia propuesta fue implementada sobre un sistema de control convencional; y sobre un sistema de producción de aire medicinal. En este último sistema, el predictor de estados funcionales presentó capacidad de filtración en la observación de la humedad relativa. Lo anterior se considera como una ganancia adicional en el diseño, pues es una variable de difícil predicción en climas tropicales. Se puede concluir que la metodología propuesta puede hacer diagnósticos apropiados de ambos procesos industriales.

Palabras claves— clasificador difuso, diagnóstico, inteligencia artificial, red neuronal.

I. INTRODUCCION

LA información histórica del comportamiento dinámico de las variables en los procesos industriales se ha convertido en una herramienta fundamental para la implementación de algoritmos basados en la inteligencia artificial (IA). Estos se implementan en línea con el proceso para la detección temprana de estados funcionales y brindan información importante al operador del proceso. Mediante el diagnóstico automático se logra determinar el estado de falla para su posterior intervención, la cual permite llevar la(s) salida(s) a las condiciones de diseño deseadas. Durante la sintonización de estrategias inteligentes para el diagnóstico automático, se utiliza el conocimiento del experto humano del proceso. El aporte del operador permite crear una asociación cualitativa durante la extracción de características dinámicas del proceso [1-2].

Para intervenir los procesos, antes de la ocurrencia de una falla se hace necesario diseñar estrategias inteligentes apoyadas en la experticia de los operadores. Una de las alternativas a nivel mundial para la agrupación de rasgos en un sistema, es la clasificación mediante la implementación de la lógica difusa. En la clasificación difusa, un patrón puede pertenecer a más de una clase mediante un grado de pertenencia permitiendo manejar a su vez el concepto de incertidumbre [2]. Para completar el sistema, el operador dota



de características las clases obtenidas para transformarlas en estados funcionales. En general, los estados funcionales describen situaciones de falla, estados intermedios y estados normales de funcionamiento [3-4]. Por otro lado, la predicción se presenta como una alternativa eficiente para la anticipación de comportamientos dinámicos en el diagnóstico automático. La principal ventaja de conocer el comportamiento futuro de las variables radica en que es posible tomar acciones predictivas-preventivas, con el objetivo de evitar que los procesos se vean afectados por la transición hacia estados funcionales críticos o de falla inminente. Lo anterior permite que las plantas se mantengan al mínimo de intervenciones correctivas extendiendo su vida útil, a la vez que se protege la vida de los operarios del proceso. Sin embargo, la predicción no es una tarea fácil. La dinámica de los procesos se caracteriza por la presencia de no linealidades, cambios abruptos, incertidumbre y comportamientos caóticos; por lo tanto, la predicción se considera una tarea compleja desde el tratamiento convencional mediante técnicas estadísticas. En este contexto, la IA se ha mostrado como una herramienta eficiente que permite incorporar en los modelos la complejidad de los procesos, generando resultados que se aproximan a la realidad, siempre y cuando se utilice información representativa de la dinámica de las plantas. Una de las estrategias de la IA, basada en una aproximación del razonamiento humano y definida con un grafo dirigido ponderado, son las RNAs [5-7].

Algunos trabajos han demostrado la eficiencia de la IA en el diagnóstico automático de procesos. En [8], se presenta una revisión sobre el estado de las técnicas de la IA aplicadas al campo de la detección y el diagnóstico de fallas; mostrando además un análisis comparativo de cada técnica, en el que se describen características de robustez, adaptabilidad, costo computacional e identificación de fallas múltiples. Las RNAs se ha utilizado en el diseño de sistemas para el diagnóstico automático por medio de estrategias que involucran clasificación de fallas. Por ejemplo, una RNA multicapa modular se implementa en [9] para el diagnóstico de fallas en líneas de transmisión eléctrica. En [10] se presenta una RNA jerárquica en la etapa de clasificación dentro de un esquema de monitoreo basado en condición, utilizado para la detección de fallas en rodamientos, mientras que en [11-12] la emisión acústica es utilizada para entrenar una RNA multicapa empleada en el diagnóstico de fallas en las válvulas de un motor de combustión interna. Al igual que en la lógica difusa, las RNA se utilizan como estrategias de agrupamiento y clasificación, permitiendo al experto del proceso definir estados de falla, estado intermedios y estados normales de funcionamiento dentro del diagnóstico automático [2]. Otros esquemas de diagnóstico han combinado varias estrategias de la IA. En [13] se combina un clasificador difuso con un algoritmo evolutivo, la implementación de las dos estrategias dota al clasificador de adaptación ante nuevos estados del proceso. En [14] se combina un algoritmo genético con una RNA. El uso de ambas estrategias permitió configurar de forma rápida y eficiente la estructura neuronal multicapa utilizada para el diagnóstico de fallas en un sistema de

embotellamiento.

En este trabajo se presenta una estructura de supervisión inteligente para el diagnóstico de procesos, a través de la predicción de estados funcionales mediante RNAs y agrupamiento difuso. La estructura es implementada sobre dos sistemas de prueba. El primero de ellos corresponde a un esquema de control realimentado aplicado a una planta para la presurización de aire. El segundo proceso equivale a un sistema de generación de aire medicinal. En ambos procesos se estimaron los estados funcionales como información valiosa para los operarios de los procesos.

II. METODOLOGÍA

A continuación se describe los procesos de prueba y se presentan detalles de la metodología implementada para la predicción de estados funcionales.

A. Procesos de Prueba

El primer proceso de prueba corresponde a una planta de presión construida en el Politécnico Colombiano Jaime Isaza Cadavid y documentada en [15]. La planta se caracteriza por presentar dinámica lenta y tiempo muerto como en los procesos industriales reales. La planta permite la implementación de algoritmos de control tipo PID (Proporcional Integral Derivativo), DMC (*Dynamic Matrix Control*), técnicas avanzadas de control, y control fuzzy [16]. La planta de presión cuenta, además, con diversos componentes que permiten la perturbación de controladores, adquisición de datos, y medición de variables por medio de sensores (ver Fig. 1).

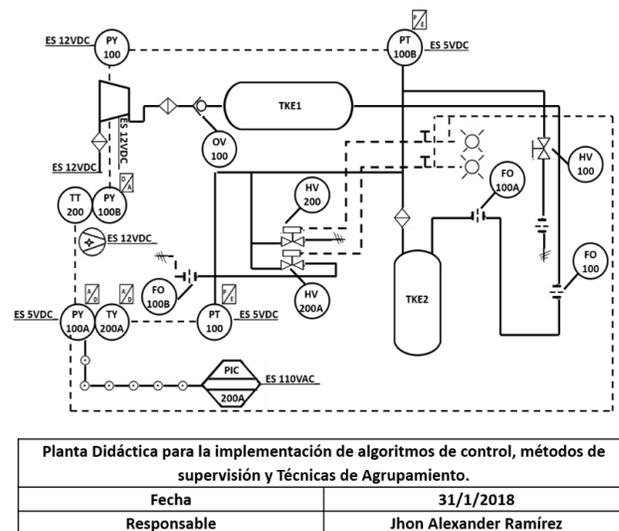


Fig. 1. Diagrama de proceso de la planta de presión.

El diagnóstico inteligente se implementará sobre la planta en modo de control de la variable presión, con el fin de supervisar el esquema de control mediante la predicción de estados funcionales.

El segundo proceso de prueba corresponde a un sistema de generación de aire medicinal, el cual tiene como objetivo final entregar aire con características de pureza de manera que

pueda ser suministrado al paciente. Las condiciones de consumo del aire medicinal se determinan a partir de la medición de las Variables Para el Control de la Producción de Aire Medicinal (VPCPAM). Las VPCPAM utilizadas para evaluar la condición del aire corresponden a la medición de la Temperatura Ambiente (TA), Humedad Relativa (HR), Partes Por Millón de Monóxido de Carbono (PPMO) y la Temperatura de Punto de Rocío (TPR). La TA y HR se miden en el área confinada para la producción de aire medicinal. Las PPCO y TPR se miden directamente en la salida final del aire; es decir, que corresponden a la medición directa del aire suministrado a la red para consumo por parte del paciente. Las VPCPAM deben estar bajo rangos establecidos de acuerdo con las Buenas Prácticas de Manufactura (BPM) para la producción de aire medicinal en sitio. Cualquier medición fuera del rango de operación de las VPCPAM podría ocasionar pérdida de la función en el proceso.

B. Predicción de Variables Mediante MRNAs

Dentro de las arquitecturas de las RNAs, se encuentran las MRNAs (Red Neuronal Artificial Multicapa), las cuales se han utilizado para la construcción de modelos de predicción de sistemas con dinámicas complejas. En general, una MRNA se considera como una estructura capaz de aproximar funciones no lineales, por lo que se le conoce como aproximador (interpolador) universal [17-18]. Con algunas configuraciones en la estructura de una MRNA y aprovechando su capacidad de interpolación, se puede obtener la predicción del comportamiento dinámico de una variable, utilizando información histórica de su comportamiento en el tiempo.

La MRNA mostrada en la Fig. 2, es denominada Red Neuronal Artificial *Bacpropagation* (RNABP), el nombre se debe a las múltiples capas que conforman la estructura de la red y al algoritmo de retropropagación del error utilizado en la etapa de entrenamiento de la RNA [19-21].

Las MRNAs se pueden configurar para obtener la predicción \hat{y}_{k+m} del comportamiento dinámico de la variable y , a partir del valor actual y_k , y de las observaciones pasadas (regresores) de la variable (1); con posibilidad de incluir entradas exógenas en el modelo de predicción (2). Los modelos anteriores son conocidos como autorregresivos, los cuales, al ser combinados con las MRNAs, generan las estructuras de predicción no lineales MRNAs-NAR y MRNAs-NARX, respectivamente.

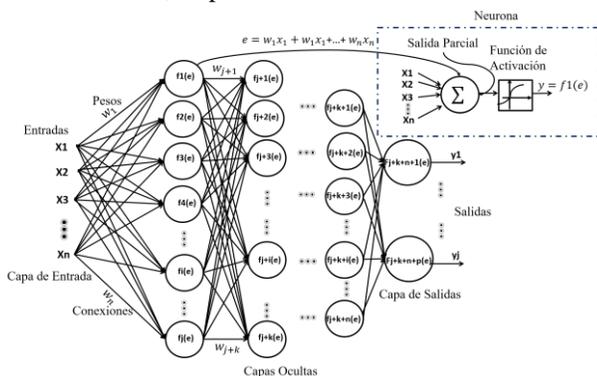


Fig. 2. Estructura detallada de una MRNA.

$$\hat{y}_{k+m} = f(y_k, y_{k-1}, y_{k-2}, y_{k-3} \dots y_{k-m}); \quad (1)$$

$f(\cdot)$ función no lineal

$$\hat{y}_{k+m} = f(\mu_k, \mu_{k-1}, \dots \mu_{k-m}, y_k, y_{k-1}, \dots y_{k-m}); \quad (2)$$

$f(\cdot)$ función no lineal

Las observaciones pasadas de las variables de los procesos son utilizadas en el entrenamiento de la MRNA NAR/NARX, e ingresan como entradas por medio de vectores extendidos a partir del operador retraso Time Delay (z^{-1}). Como la verdadera salida de la red está disponible en el entrenamiento, se recomienda utilizar una arquitectura serie-paralelo como la mostrada en la Fig. 3. Lo anterior presenta la ventaja de permitir trabajar con una estructura directa *feedforward*, y entrenamiento estático mediante algoritmos convencionales BP (*BackPropagation*). Además, al trabajar con la verdadera salida deseada se incrementa la precisión de la MRNA al no introducir un lazo de realimentación con la salida estimada \hat{y}_{k+m} , la cual contiene por si misma error de predicción [22].

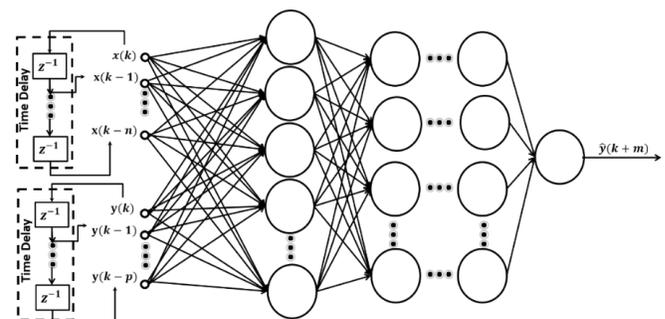


Fig. 3. Arquitectura MRNA Serie-Paralelo.

Para obtener la predicción de variables mediante MRNAs-NAR/NARX se utilizó el histórico de las respuestas de los procesos de prueba, almacenado en bases de datos en formato (.txt). De la planta de presión se tiene registro de las variables de salida, así como de la variable de entrada que afecta la serie (Ley de Control), por lo tanto, se implementaron estructuras MRNA-NARX. Del sistema de producción de aire medicinal, solo se tiene registro de las variables de salida, por lo que se implementaron estructuras MRNA-NAR. Las MRNAs se entrenaron con el algoritmo LM (*Levenberg-Marquardt*); y una sola capa oculta en la configuración de la red, de acuerdo con la fundamentación matemática dada por *Kolmogorov* [18], [23].

C. Estimación de Estados Funcionales a Partir de la Clasificación Difusa de Patrones

La clasificación borrosa o difusa se presenta como una alternativa para la discriminación de patrones que presentan cierto grado de similitud y que pertenecen simultáneamente a más de una clase. En esta clasificación se utiliza el concepto de partición difusa definida como la generalización de la partición concreta en la cual se permite un grado de pertenencia $\mu = [0 \text{ ó } 1]$ pero ahora en el intervalo de valores reales $\mu = [0, 1]$ donde el mayor grado de pertenencia es 1 y el menor es 0, [3], [24]. La clasificación borrosa permite que n

patrones diferentes de la matriz de datos $\mathbb{X} = [x_1, x_2, x_3 \dots x_n]$ pertenezcan parcialmente a una clase C_j o a varias clases $C = [C_1, C_2, C_3 \dots C_n]$ limitada por su respectivo centroides c_j . Lo anterior hace posible extender el espacio de búsqueda sujeto a pocas restricciones, lo que permite mayor flexibilidad en la clasificación.

Uno de los algoritmos para la clasificación borrosa de patrones es el *Fuzzy C-means* (FCM). A diferencia del algoritmo *C-means* en el cual se hacen particiones duras, en el algoritmo FCM se trabajan con particiones suaves, restringidas por la función objetivo-definida en la ecuación (3).

$$J_m(U, v) = \sum_{i=1}^N \sum_{j=1}^C \mu_{ij}^m \|x_i - c_j\|^2 \quad (3)$$

Donde:

J_m = Función objetivo.

U = Matriz de particiones de valores reales en el intervalo continuo $[0,1]$.

v = Vector de centro de las clases; m = Parámetro que regula la fusividad de la partición.

μ_{ij} = Pertenencia de los datos x_i a la clase j .

x_i = Muestra de los datos a evaluar; c_j = Centroide de la clase j .

$\|x_i^j - c_j\|^2$ = Distancia euclidiana medida en un espacio de m dimensiones entre la muestra x_i^j y el centro c_j del *cluster* i .

m = grado de fusividad.

Los centroides de cada clase se calculan como se muestra en (4).

$$c_j = \frac{\sum_{i=1}^N \mu_{ij}^m * x_i}{\sum_{i=1}^N \mu_{ij}^m} \quad (4)$$

Como el FCM es un algoritmo iterativo, la actualización de la matriz de particiones para cada iteración se calcula mediante (5). La convergencia del algoritmo tiene lugar cuando se cumple un número de iteraciones definido en los parámetros de inicialización o mediante la comparación de la matriz de particiones frente a un parámetro de tolerancia e como se muestra en (6).

$$u_{ij} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_i - c_j\|}{\|x_i - c_j\|} \right)^{\frac{2}{m-1}}} \quad (5)$$

$$\|U^{k+1} - U^k\| < e \quad (6)$$

En el diagnóstico automático de procesos implementando clasificadores, cada clase resultante de la convergencia del algoritmo es interpretada por los expertos operarios-ingenieros, para producir los estados funcionales. En estados

de falla el experto es quien determinara su prioridad para intervenir el proceso y llevarlo a condiciones funcionales de manera que su disponibilidad se mantenga en los niveles deseados por la industria. La clasificación permite discriminar estados funcionales y detectar estados normales de funcionamiento, estados de alarma y estados de falla en el diagnóstico del proceso.

III. RESULTADOS

A continuación se presentan los resultados obtenidos con los procesos de prueba.

A. Predicción de Variables de los Procesos de Prueba

Los datos del comportamiento dinámico de las VPCPAM se registraron en una base de datos de 99750 muestras para las 4 variables (matriz $[99750 \times 4]$), a un período de adquisición de datos de 2 minutos. Los datos fueron sometidos a preprocesamiento eliminando información redundante, dejando solo información con transiciones importantes como: cambios bruscos, registros críticos y de falla, y estados normales de funcionamiento. El preprocesamiento generó una nueva base de datos de 5609 muestras (matriz $[5609 \times 4]$), disponiendo de esta el 66% de datos (3679 muestras) para el diseño del modelo de predicción: entrenamiento, validación y prueba. Y el 34% de datos para evaluación (1930 muestras). El objeto (vector característico) de la matriz de datos se muestra en la ecuación (29) y está conformado por la medición en el instante k de las VPCPAM.

$$x_{i(k)} = [PPMCO_{(k)} \quad TPR_{(k)} \quad HR_{(k)} \quad TA_{(k)}]; \quad (7)$$

k : instante de medición;

Las variables fueron normalizadas para trabajar en el intervalo $(0,1)$. Para configurar las entradas se generaron 3 retrasos más el valor de la variable y_k , la salida deseada se configuró mediante el vector extendido a partir del estado inicial y_{k+1} . Luego de configurar las entradas y salida, se entrenó cada MRNA-NAR.

La Tabla I muestra los resultados numéricos obtenidos a partir del entrenamiento de las MRNA-NAR. Se observa en general que el R^2 supera el 98% en cada una de las estructuras entrenadas, indicando una relación lineal positiva fuerte entre las VPCPAM y las salidas entregada por cada modelo neuronal. Los MSE se mantuvieron en valores menores a $1,10 \times 10^{-5}$, caso del modelo de predicción de la TA, hasta $2,10 \times 10^{-4}$ en el caso de la predicción de la HR. Los valores del MSE cercanos a cero, en conjunto con valores de $R^2 > 98\%$, se utilizaron como parámetros de desempeño para la aceptación de los modelos.

TABLA I
RESULTADOS DEL ENTRENAMIENTO DE LA MRNA-NAR PARA LA
PREDICCIÓN DE LAS VPCPAM

VPCPAM	#Neuronas en la capa oculta	R^2	MSE
PPMCO	8 - f(.) Sigmoide	0,9854	$9,96 \times 10^{-4}$
TPR	4 - f(.) Sigmoide	0,9991	$4,35 \times 10^{-5}$

HR	4 – f(.) Sigmoide	0,9977	2,10 X 10 ⁻⁴
TA	4 – f(.) Sigmoide	0,9994	1,10 X 10 ⁻⁵

Los datos del comportamiento dinámico de las variables en modo control de la planta de presión, se almacenaron en una base de datos de 4105 muestras para las 4 variables (matriz [4105 x 4]); disponiendo de esta del 81% de datos (3400 muestras) para el diseño del modelo de predicción: entrenamiento, validación y prueba. Y el 19% de datos para evaluación (805 muestras). El vector característico de la matriz de datos se muestra en (8) y está conformado por la medición en el instante k , de la presión en el tanque de almacenamiento Variable Controlada, VC), Error de Control (EC), Temperatura del *Driver* de corriente (TD), y la entrada exógena Ley de Control (LC).

$$x_i(k) = [VC_{(k)} \ EC_{(k)} \ TD_{(k)} \ LC_{(k)}]; \quad (8)$$

k : instante de medición;

Para configurar las entradas a la MRNA-NARX se generaron 2 retrasos, además del valor actual en la variable de salida y entrada exógena (9). La salida deseada se configuró mediante el vector extendido a partir del estado inicial y_{k+1} . Luego de configurar las entradas y salida, se entrenó cada MRNA-NARX.

$$y = [y_{(k-1)} \ y_{(k-2)} \ y_{(k)} \ u_{(k)} \ u_{(k-1)} \ u_{(k-2)}]; \quad (9)$$

La Tabla II muestra los resultados numéricos obtenidos a partir del entrenamiento de las MRNA-NARX. El coeficiente de determinación R^2 supera el 99% en cada una de las estructuras entrenadas, indicando una relación lineal positiva fuerte entre cada variable de entrada utilizada para la predicción y la salida entregada por cada estructura neuronal. Los MSE se mantuvieron en valores menores a 6.95×10^{-4} , en el caso del modelo de predicción del EC, hasta 5.17×10^{-5} en el caso de la predicción de la VC. Los valores del MSE cercanos a cero, en conjunto con valores de $R^2 > 99\%$, se utilizaron como parámetros de desempeño para aceptación de los modelos.

TABLA II
RESULTADOS DEL ENTRENAMIENTO DE LA MRNA-NAR PARA LA PREDICCIÓN DE LAS VARIABLES EN LA PLANTA DE PRESIÓN

VPCPAM	#Neuronas en la capa oculta	R ²	MSE
VC	8 – f(.) Sigmoide	0,999	5,17 X 10 ⁻⁵
EC	8 – f(.) Sigmoide	0,990	6,95 X 10 ⁻⁴
TD	8 – f(.) Sigmoide	0,998	1,36 X 10 ⁻⁵

B. Sintonización de los Clasificadores Fcm para los Sistemas de Prueba

Con el fin de mantener la relación con la predicción de la dinámica de las variables de los sistemas de prueba, se utilizaron las mismas bases de datos implementadas en la etapa de configuración de las MRNAs. El objeto (vector característico) x_i de cada proceso se muestran en (10-11).

$$x_i(k) = [PPMCO_{(k)} \ TPR_{(k)} \ HR_{(k)} \ TA_{(k)}] \quad (10)$$

Atributos_(k) = PPMCO_(k); TPR_(k); HR_(k); TA_(k)

$$x_i(k) = [VC_{(k)} \ EC_{(k)} \ TD_{(k)}] \quad (11)$$

Atributos_(k) = VC_(k) EC_(k) TD_(k)

Los estados funcionales del sistema de producción de aire medicinal se obtuvieron, a partir del análisis del registro de las VPCPAM y de los resultados gráficos del clasificador. El análisis gráfico multivariable y la experticia de 4 operadores del proceso, incluido el ingeniero jefe de producción, permitieron establecer los estados funcionales reportados en la Tabla III.

TABLA III
DESCRIPCIÓN DE LOS ESTADOS FUNCIONALES DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL A PARTIR DEL CLASIFICADOR FCM DISEÑADO

Clase	Estado Funcional
C1	Falla: Incremento considerable en las partes por millón de monóxido de carbono (PPMCO)
C2	Falla: Incremento considerable de la temperatura ambiente (TA) y decremento considerable de la humedad relativa HR
C3	Alerta: Incremento de la temperatura ambiente (TA<TA de la clase C2) y decremento de la humedad relativa (HR>HR de la clase 2)
C4	Alerta: incremento de la temperatura de punto de rocío (TPR) e incremento de la temperatura ambiente (TA)
C5	Alerta: Incremento considerable de la humedad relativa (HR)
C6	Operación Normal: Las VPCPAM se encuentran dentro de los rangos normales de operación.

Los estados funcionales de la planta de presión se obtuvieron a partir del análisis de los resultados gráficos del clasificador. El análisis gráfico multivariable y la experticia del operador del proceso permitieron establecer los estados funcionales reportados en la Tabla IV.

Como medidas de validación de los clasificadores se calculó el Coeficiente de Partición (*Partition Coefficient- PC*) (12) y la Entropía de la Partición (*Partition Entropy – PE*) (13). Los resultados obtenidos de estos índices, mostrados en las Tablas V y VI, en conjunto con el reconocimiento y validación de las clases, con base en el conocimiento experto de los involucrados directamente sobre el proceso, dan cuenta del número válido y acertado de clases (C1 a C6).

TABLA IV
DESCRIPCIÓN DE LOS ESTADOS FUNCIONALES DE LA PLANTA DE PRESIÓN A PARTIR DEL CLASIFICADOR FCM DISEÑADO

Clase	Estado Funcional
C1	Falla: Incremento considerable en la temperatura en el driver de corriente
C2	Alerta: Perturbación de la variable controlada. Sistema controlando en región próxima a saturación del EFC
C3	Falla: Fuga considerable en la planta, con despresurización total del tanque de almacenamiento
C4	Operación Normal 1: El sistema se encuentra en modo control sin variaciones considerables en las variables (Set Point: 40% a 50%)
C5	Alerta: Salida controlada con perturbación: fuga mínima
C6	Operación Normal 2: El sistema se encuentra en

modo control sin variaciones considerables en las variables (Set Point: 15% a 25%)

$$PC(c) = 1/N \sum_{i=1}^c \sum_{j=1}^N \mu_{ij}^2 \quad (12)$$

$$PE(c) = -1/N \sum_{i=1}^c \sum_{j=1}^N \mu_{ij} \log_2(\mu_{ij}) \quad (13)$$

TABLA V

MEDIDAS DE VALIDES DE PARTICIÓN DIFUSA DEL CLASIFICADOR FCM PARA EL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL

Índice de Validación	Resultado	Mínimo Posible	Máximo Posible
Coficiente de Partición	0,667	$\text{Min} = \frac{1}{c}$ 0,1667	1
Entropía de la Partición	0,9796	0	$\text{Max} = \text{Log}_2(c)$ 2,585

TABLA VI

MEDIDAS DE VALIDES DE PARTICIÓN DIFUSA DEL CLASIFICADOR FCM PARA LA PLANTA DE PRESIÓN

Índice de Validación	Resultado	Mínimo Posible	Máximo Posible
Coficiente de Partición	0,746	$\text{Min} = \frac{1}{c}$ 0,1667	1
Entropía de la Partición	1,127	0	$\text{Max} = \text{Log}_2(c)$ 2,585

C. Predicción de estados funcionales de procesos mediante MRNAs NAR/NARX y clasificación difusa

La Fig. 5 muestra el esquema propuesto de supervisión inteligente para el diagnóstico automático de procesos.

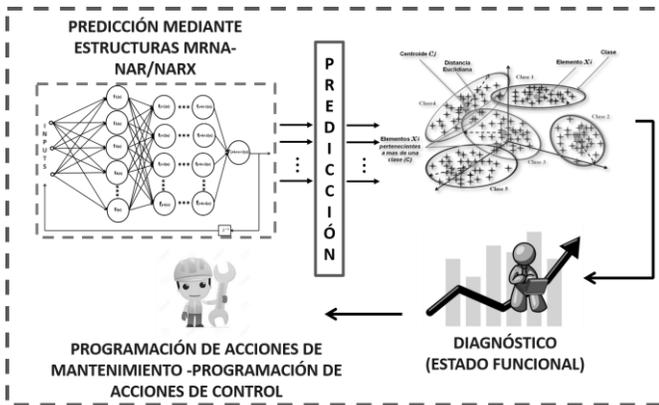


Fig. 5. Esquema de supervisión inteligente para el diagnóstico automático de procesos mediante MRNAs y clasificación difusa.

En el esquema se observa como las entradas al clasificador difuso, corresponden a las predicciones de las variables de los procesos, realizadas por las estructuras neuronales. Las clases previamente definidas como estados funcionales de los procesos se presentan como información de la dinámica estimada de los procesos, para ser analizada por el grupo de

operadores e ingenieros en las industrias. Lo anterior permite programar acciones de mantenimiento y control antes de la transición del proceso hacia un estado de falla, manteniendo a su vez la confiabilidad del sistema, garantizando la seguridad de los operarios, y minimizando los costos por mantenimiento.

Para la predicción de estados funcionales del sistema de producción de aire medicinal, se implementaron, a partir de los modelos MRNAs-NAR, predicciones iteradas hasta obtener el valor estimado de cada VPCPAM en un horizonte de predicción $h = 5$. El horizonte se definió a partir de varias condiciones. La primera de ellas es que se debe minimizar al máximo la transición del proceso hacia estados de falla, solo 4 minutos se tienen estipulados para atender de forma inmediata el proceso. El flujo continuo de aire por compresor es interrumpido ante estados de falla de acuerdo con las BPM. Con 5 muestras adelante y teniendo en cuenta que el registro de las variables se hace cada 2 minutos, además, tolerando un error de predicción de (-2) muestras en el peor de los casos, se tiene un periodo mínimo de 6 minutos para analizar la información, activar código de emergencia y reunir el personal operario del sistema para activar el *manifold* de reserva, y ejecutar las acciones de mantenimiento que permitan llevar el sistema a las condiciones deseadas de operación.

En la Fig. 6 se puede observar una ampliación de la respuesta entre las muestras 1264 a 1304 del predictor de estados funcionales. En este caso el predictor clasifica acertadamente hasta la muestra 1266, donde detecta transición hacia el estado funcional de alerta (clase 3) con dos muestras de anticipación, y posteriormente hacia el estado funcional de falla (clase 5) con 3 muestras de anticipación, luego el predictor detecta nuevamente cambio hacia la clase 3 en la muestra 1273. El clasificador detecta transiciones solo hasta la muestra 1274; es decir, 7 muestras después que el predictor.

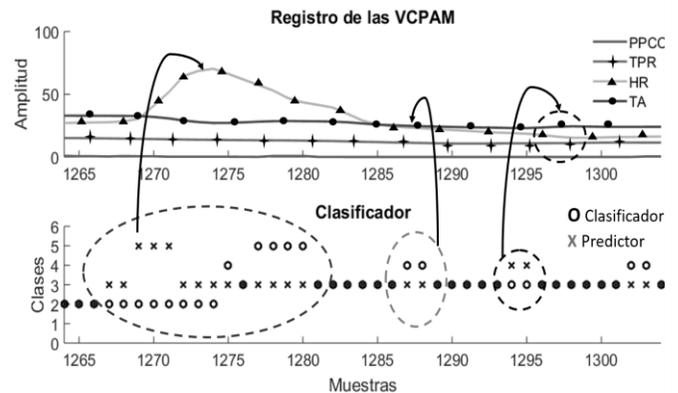


Fig. .6. Evolución de los estados funcionales (clases) según clasificador y predictor. Ampliación entre muestras 1264 a 1304.

Existe una transición no detectada por el predictor en la muestra 1275 demostrando que se mantienen conservativamente los estados del sistema, con conmutaciones asociadas a verdaderos cambios. En este caso el predictor decide mantenerse en la clase 3 observando el decremento de la HR e incrementos en la TA, de igual manera que en las muestras 1287-1288. El análisis anterior se puede verificar en las muestras 1294-1295 donde existe un cambio con pendiente

positiva en la TA (23.47°C a 24.58°C) y TPR (10.98°F a 12.54°F) de manera que activaron la transición en el predictor de la clase 3 a la clase 4 (estado de alerta, incremento de la TA y TPR), transición que es detectada por el clasificador después de 6 muestras, demostrando que la predicción es acertada.

Para la predicción de estados funcionales de la planta de presión, se implementaron a partir de los modelos neuronales MRNAs-NARX, predicciones iteradas hasta obtener el valor estimado de las variables $\hat{x}_i = [VC, EC, TD]$ en un horizonte de predicción $h = 3$ muestras. El horizonte se definió a partir del período de muestreo $T = 3s$, elegido durante la discretización del modelo continuo de la planta. Con $h * T$ se dispone de 9s para generar las alarmas al operador o las acciones de control sobre el proceso.

La Fig. 7 muestra una ampliación entre las muestras 900 a 950 del predictor de estados funcionales de la planta de presión. Se puede observar como el predictor detecta transición hacia el estado funcional de falla 1, con 5 muestras adelante respecto al clasificador entrenado. Luego, en la muestra 921 el predictor detecta un cambio de clase C1 a C5 y posteriormente en la muestra 922 transición entre C5 a C6, cambios no detectados por el clasificador. En este caso el predictor decidió predecir el cambio en la zona de trabajo del controlador (del 25% al 40%) primero como una perturbación (por cambio en el punto de consigna), y luego con una muestra conservativa sobre la clase C6, como una transición hacia el estado normal de funcionamiento después de cambio en el *Set Point*. El comportamiento anterior es detectado por el clasificador solo hasta la muestra 928, clasificando 8 muestras como estado perturbado. Aunque las clases no coinciden entre el predictor y el clasificador entre las muestras 923 a 938, el diagnóstico no se ve afectado. Se demuestra que el predictor trabaja de forma conservativa, detectando las transiciones suaves del clasificador difuso y los cambios en la zona de trabajo como perturbaciones rápidas, que logra predecir luego de pocas muestras como estados que tienden a comportarse de forma estable. Mientras que el clasificador detecta el cambio en la zona de trabajo como una perturbación extendida que finalmente transita hacia estado normal de funcionamiento. Tanto predictor como clasificador logran clasificar acertadamente después de la muestra 938 sobre el estado funcional normal de funcionamiento de la planta de presión en la zona de trabajo (40% a 50%).

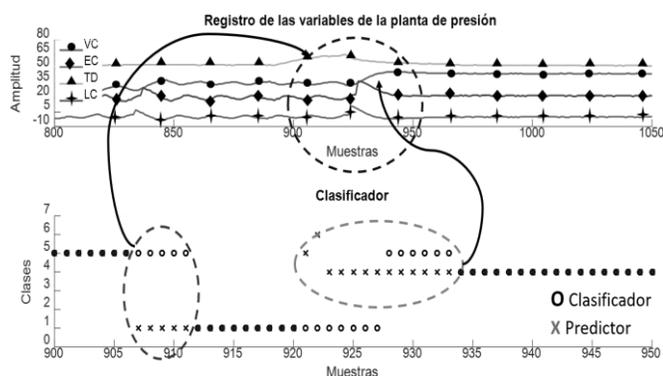


Fig. 7. Evolución de los estados funcionales (clases) según clasificador y predictor. Ampliación entre muestras 900 a 950.

IV. CONCLUSIONES

Se construyeron los modelos de predicción para cada variable de los sistemas de prueba. Se utilizaron métricas relacionadas con el error para determinar el desempeño de los modelos. En general las métricas MSE, RMSE, MAE se mantuvieron en valores próximos a cero. El MAPE por su parte logró ubicarse por debajo del 0.1%. El coeficiente R^2 superó el 98% en la etapa de entrenamiento, y el 97% en la etapa de evaluación con datos fuera de muestra, indicando una relación lineal fuerte entre la variable de entrada, y la predicción en cada estructura neuronal. Lo resultados anteriores se utilizaron como parámetros de aceptación de los modelos.

Se estimaron los estados funcionales de los procesos de prueba a partir de la clasificación difusa de patrones, definiendo para ambos procesos, estados de falla, estado se alerta y estados normales de funcionamiento. Durante la estimación de los estados funcionales, se tuvieron en cuenta los conocimientos del grupo de ingeniería involucrado con el proceso de producción de aire y de la planta de presión. El conocimiento de los expertos de los procesos fue fundamental para la asignación de clases, y la definición y descripción cualitativa de los estados funcionales.

Se implementó una estructura de supervisión inteligente para el diagnóstico automático de procesos mediante la predicción de estados funcionales con MRNAs y clasificación difusa de patrones. La estructura fue implementada sobre dos procesos de prueba: un sistema de producción de aire medicinal en una institución hospitalaria y una planta de presión. El predictor de estados funcionales en el sistema de producción de aire medicinal presentó capacidad de filtración, en especial en la observación de la HR. Lo anterior fue considerado como ganancia adicional en el diseño, debido a que la HR es una variable de difícil predicción en climas tropicales y esporádicos como los presentados en el área metropolitana de Medellín. En presencia de ruido en las mediciones, el predictor decidió observar verdaderos cambios, antes de transitar hacia otros estados funcionales.

AGRADECIMIENTOS

Los autores agradecen al grupo de investigación en Manejo Eficiente de la Energía (GIMEL) de la UdeA, al proyecto de Sostenibilidad de la Universidad de Antioquia y al grupo de investigación en Instrumentación Control Automático y Robótica (ICARO) del Politécnico JIC, por la colaboración en la ejecución del proyecto.

REFERENCIAS

- [1] J. A. Ramírez Urrego, "Diagnóstico de procesos industriales basado en predicción de estados funcionales con inteligencia artificial para el control y la programación de mantenimiento," Tesis de Maestría, Universidad de Antioquia, Medellín, Colombia, 2019.
- [2] J. A. Ramírez Urrego, H. O. Sarmiento, and J. M. López Lezama, "Diseño de un Clasificador Difuso para el Establecimiento de los Estados Funcionales de un Sistema de Producción de Aire Medicinal," *Inf. Tecnológica*, vol. 28, pp. 147–160, 2017. DOI: 10.4067/S0718-07642017000600016.

- [3] H. O. Sarmiento, C. V. Isaza, T. Kempowsky-Hamon, and M.-V. LeLann, "Estimación de Estados Funcionales en Procesos Complejos con Base en Agrupamiento Difuso," *Inf. Tecnológica*, vol. 24, no. 2, pp. 79–98, 2013. DOI: 10.4067/S0718-07642013000200010.
- [4] H. Ricardo Hernandez, J. Luis Camas, A. Medina, M. Perez, and M. Veronique Le Lann, "Fault Diagnosis by LAMDA methodology Applied to Drinking Water Plant," *IEEE Lat. Am. Trans.*, vol. 12, no. 6, pp. 985–990, Sep. 2014. DOI: 10.1109/TLA.2014.6893990.
- [5] L. Corrales Barrios and A. Ramírez Vázquez, "Clasificación de fallas con redes neuronales para grupos electrógenos," *Ing. Energética*, vol. 34, pp. 137–150, 2013. Available at: <http://www.redalyc.org/articulo.oa?id=329127757006>
- [6] J. Gómez-Durán, J. Simancas-García, M. Acosta-Coll, F. Meléndez-Pertuz, and J. Vélez-Zapata, "Algoritmo de reconocimiento de comandos voz basado en técnicas no-lineales," *Rev. Espac.*, vol. 38, no. 17, Apr. 2017. Available at: <https://www.revistaespacios.com/a17v38n17/a17v38n17p04.pdf>
- [7] R. S. Cruz and C. Corrêa, "Intermittent demand forecasting with time series methods and artificial neural networks: A case study," *DYNA Rev. Fac. Minas Univ. Nac. Colomb. Sede Medellín*, vol. 84, no. 203, pp. 9–16, 2017. <https://dialnet.unirioja.es/servlet/articulo?codigo=6406270>
- [8] L. H. Cortes, E. Villarreal-López, and L. Villarreal-López, "Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte," *DYNA*, vol. 83, no. 199, pp. 19–28, Oct. 2016. <https://www.redalyc.org/articulo.oa?id=49648868002>.
- [9] A. Flores Novelo, E. Quiles Cucarella, E. Garcia Moreno, and F. Morant Anglada, "Fault Diagnosis of Electric Transmission Lines using Modular Neural Networks," *IEEE Lat. Am. Trans.*, vol. 14, no. 8, pp. 3663–3668, Aug. 2016. DOI: 10.1109/TLA.2016.7786348.
- [10] M. D. Prieto, G. Cirrincione, A. G. Espinosa, J. A. Ortega, and H. Henao, "Bearing Fault Detection by a Novel Condition-Monitoring Scheme Based on Statistical-Time Features and Neural Networks," *IEEE Trans. Ind. Electron.*, vol. 60, no. 8, pp. 3398–3407, Aug. 2013. DOI: 10.1109/TIE.2012.2219838.
- [11] S. M. Jafari, H. Mehdigholi, and M. Behzad, "Valve Fault Diagnosis in Internal Combustion Engines Using Acoustic Emission and Artificial Neural Network," *Shock Vib.*, vol. 2014, p. 9, 2014. <https://www.hindawi.com/journals/sv/2014/823514/>
- [12] Y. Shatnawi and M. Al-khassaweneh, "Fault Diagnosis in Internal Combustion Engines Using Extension Neural Network," *IEEE Trans. Ind. Electron.*, vol. 61, no. 3, pp. 1434–1443, Mar. 2014. DOI: 10.1109/TIE.2013.2261033.
- [13] A. P. Lemos, W. M. Caminhas, and F. A. C. Gomide, "Adaptive fault detection and diagnosis using an evolving fuzzy classifier," *Inf Sci*, vol. 220, pp. 64–85, 2013. DOI: 10.1016/j.ins.2011.08.030.
- [14] M. Demetgul, M. Unal, I. N. Tansel, and O. Yazıcıoğlu, "Fault diagnosis on bottle filling plant using genetic-based neural network," *Adv. Eng. Softw.*, vol. 42, no. 12, pp. 1051–1058, Dec. 2011. DOI: 10.1016/j.advengsoft.2011.07.004.
- [15] J. A. Ramírez Urrego and H. Sarmiento, *Planta Didáctica Portable para la Implementación de Algoritmos de Control y de Técnicas para Monitoreo (Supervisión) de Procesos*. Fondo Editorial Politécnico, 2014.
- [16] J. A. Ramírez Urrego, "Construcción de una Planta de Presión Didáctica y Portable para Implementación de Algoritmos de Control," presented at the VIII Congreso de Ingeniería Mecánica, Cuenca-Ecuador, pp. 1160–1165.
- [17] P. Jarrín and J. Xavier, "Comparación entre varios métodos de pronósticos basados en series de tiempo para predecir la demanda de placas digitales en empresas del sector gráfico quiteño desde el año 2009 hasta el año 2015," Tesis de Maestría, Escuela Politécnica Nacional, Quito-Ecuador, 2017. <https://bibdigital.epn.edu.ec/handle/15000/17016>
- [18] P. A. Sánchez Sánchez, "Una nueva metodología de entrenamiento de redes neuronales y sus implicaciones en la selección de modelos," Tesis Doctoral, Universidad Nacional de Colombia, Medellín, Colombia, 2012.
- [19] L. M. Lizarraga Orozco, G. Ronquillo Lomeli, J. G. Rios Moreno, and M. Trejo Perea, "Identification Inverted Pendulum System using Multilayer and Polynomial Neural Networks," *IEEE Lat. Am. Trans.*, vol. 13, no. 5, pp. 1569–1576, May 2015. DOI: 10.1109/TLA.2015.7112017.
- [20] J. Wang, G. Yang, S. Liu, and J. M. Zurada, "Convergence Analysis of Multilayer Feedforward Networks Trained with Penalty Terms: A Review," *J. Appl. Comput. Sci. Methods*, vol. 7, no. 2, pp. 89–103, Nov. 2015. <https://content.sciendo.com/view/journals/jacsm/7/2/article-p89.xml>
- [21] M. Hassan and M. Hamada, "Performance Comparison of Featured Neural Network Trained with Backpropagation and Delta Rule Techniques for Movie Rating Prediction in Multi-criteria Recommender Systems," *Inform. Slov.*, vol. 40, pp. 409–414, 2016. <https://pdfs.semanticscholar.org/f973/11466154d4d1c43b7df0729a485920075286.pdf>
- [22] M. del C. M. L. R. Martínez, "Sistemas inteligentes para el ajuste de modelos hidrológicos: aplicación al río Paraná," Tesis Doctoral, Universidad de Cantabria, Santander, España, 2013.
- [23] L. O. González Salcedo, A. P. Guerrero, S. Delvasto Arjona, and A. L. Ernesto Will, "Exploración con redes neuronales artificiales para estimar la resistencia a la compresión, en concretos fibroreforzados con acero," *Cienc. E Ing. Neogranadina*, vol. 22, pp. 19–41, 2012. http://www.scielo.org.co/scielo.php?script=sci_abstract&pid=S0124-81702012000100002
- [24] B. Ojeda Magaña, "Aportación a la extracción de conocimiento aplicada a datos mediante agrupamientos y sistemas difusos," Tesis Doctoral, Escuela Técnica Superior de Ingenieros de Telecomunicación, Universidad Politécnica de Madrid, Madrid, España, 2010.

John A. Ramírez received his B.Sc degree from the Politécnico Colombiano Jaime Isaza Cadavid - PCJIC. He also received his Specialist and M.Sc. degrees from the Universidad de Antioquia-Colombia, in 2017 and 2019, respectively. He is currently a professor at PCJIC. His major research interests are automatic, intelligent and advanced control, and intelligent process supervision.
ORCID: <https://orcid.org/0000-0002-2980-6724>

Henry O. Sarmiento Maldonado received his B.Sc in Electrical Engineering, Specialist degree in Industrial Automatization, M.S. degree in Engineering and Ph.D degree in Electronic Engineering from Universidad de Antioquia in 1996, 1998 and 2008 and 2013, respectively. He is currently an Associate Professor in Instrumentation and Control Engineering at the Politécnico Colombiano Jaime Isaza Cadavid PCJIC (Medellín – Colombia) since 2007. His research interests include control systems, electric power system and complex systems monitoring using clustering methods, data mining, fuzzy logic, and artificial neural networks. He served as Director of Research and Postgraduate Studies at PCJIC from 2016 to 2017(July). Since 2017 he is the director of ICARO research group at PCJIC.
ORCID: <https://orcid.org/0000-0001-8011-1293>

Jesús M. López-Lezama received his B.Sc. and M.Sc. degrees from the Universidad Nacional de Colombia in 2001 and 2006, respectively. He also received his Ph.D. degree at the Universidade Estadual Paulista (UNESP), SP, Brazil in 2011. Currently he is an associate Professor at Universidad de Antioquia, Medellín, Colombia. His major research interests are planning and operation of electrical power systems and distributed generation.
ORCID: <https://orcid.org/0000-0002-2369-6173>