



1 8 0 3

Universidad de Antioquia

**DIAGNÓSTICO DE PROCESOS INDUSTRIALES BASADO EN  
PREDICCIÓN DE ESTADOS FUNCIONALES CON INTELIGENCIA  
ARTIFICIAL PARA EL CONTROL Y LA PROGRAMACIÓN DE  
MANTENIMIENTO**

JHON ALEXANDER RAMÍREZ URREGO

Universidad de Antioquia  
Facultad de Ingeniería-Maestría en Ingeniería  
Medellín Colombia  
2018



Universidad de Antioquia  
Facultad de Ingeniería  
Maestría en Ingeniería

## Trabajo de Investigación

Para optar por el título de

*Magister en Ingeniería*

JHON ALEXANDER RAMÍREZ URREGO

### **DIAGNÓSTICO DE PROCESOS INDUSTRIALES BASADO EN PREDICCIÓN DE ESTADOS FUNCIONALES CON INTELIGENCIA ARTIFICIAL PARA EL CONTROL Y LA PROGRAMACIÓN DE MANTENIMIENTO**

Evaluadores:

Evaluador 1: \_\_\_\_\_

Evaluador 2: \_\_\_\_\_

Director:

Jesús María López Lezama. PhD.

Codirector:

Henry Omar Sarmiento Maldonado. PhD.

Medellín 22 de Octubre de 2018

## **Resumen**

En este trabajo se 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 clases fueron analizadas por el experto del proceso para generar estados funcionales. Las RNAs de 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 los estados funcionales serán utilizados para generar las acciones preventivas antes de la transición hacia un estado de falla. La inteligencia artificial se presenta como una alternativa que al ser combinada con la ingeniería de mantenimiento permitirá el diseño de sistemas complejos y eficientes para programar acciones de tipo preventivas y predictivas sobre las máquinas en la industria. La estrategia propuesta fue implementada sobre un sistema de control convencional para la conmutación de los parámetros de control y la predicción de fallas; y sobre un sistema de producción de aire medicinal para la programación de acciones de manteniendo a partir de la predicción de estados funcionales.

**Palabras clave:** clasificador difuso, diagnóstico, inteligencia artificial, red neuronal.

## **Abstract**

In this work the design of an intelligent strategy for the automatic diagnosis of processes by means of Artificial Neural Networks (ANNs) prediction and diffuse classification is presented. 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. Classes are analyzed by the process expert to generate functional states. The ANNs of multilayer configuration was 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 will be used to generate the preventive actions before the transition to a fault state. Artificial intelligence is presented as an alternative that, when combined with maintenance engineering, will allow the design of complex and efficient systems to program preventive and predictive actions on machines in organizations. The proposed strategy was implemented on a conventional control system for the commutation of the control parameters and the prediction of faults; and on a medicinal air production system for programming maintenance actions based on the prediction of functional states.

## Contenido

RESUMEN .....	3
ABSTRACT .....	3
INTRODUCCIÓN GENERAL .....	12
OBJETIVOS.....	13
OBJETIVO GENERAL .....	13
OBJETIVOS ESPECÍFICOS .....	13
ESTRUCTURA DEL TRABAJO .....	14
CONTRIBUCIONES.....	15
<b>1. DIAGNÓSTICO DE FALLAS EN PROCESOS INDUSTRIALES MEDIANTE INTELIGENCIA ARTIFICIAL: REVISIÓN DEL ESTADO DEL ARTE.....</b>	<b>16</b>
1.1 INTRODUCCIÓN .....	16
1.2 METODOLOGÍA DE BÚSQUEDA DE INFORMACIÓN .....	18
1.3 DIAGNÓSTICO DE PROCESOS MEDIANTE INTELIGENCIA ARTIFICIAL.....	19
1.3.1 INFORMACIÓN HISTÓRICA DEL COMPORTAMIENTO DINÁMICO DE LOS PROCESOS .....	20
1.3.2 ESTRATEGIAS BASADAS EN LA LÓGICA DIFUSA .....	22
1.3.3 ESTRATEGIAS BASADAS EN REDES NEURONALES .....	23
1.3.4 ESTRATEGIAS BIO-INSPIRADAS .....	24
1.3.5 ESTRATEGIAS COMBINADAS.....	25
1.4 RESULTADOS.....	25
1.5 COMPARACIÓN DE TÉCNICAS DE IA PARA EL DIAGNÓSTICO DE PROCESOS INDUSTRIALES.....	27
1.6 CONCLUSIONES.....	28
1.7 REFERENCIAS BIBLIOGRÁFICAS.....	29
<b>2. DESCRIPCIÓN DE LOS PROCESOS DE PRUEBA .....</b>	<b>34</b>
2.1 INTRODUCCIÓN .....	34
2.2 PLANTA DE PRESIÓN.....	35
2.2.1 DESCRIPCIÓN DE LA PLANTA DE PRESIÓN.....	36
2.2.2 MODELO MATEMÁTICO DE LA PLANTA DE PRESIÓN.....	37
2.2.3 MODO CONTROL DE LA PLANTA DE PRESIÓN.....	38
2.3 SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL.....	41
2.3.1 DESCRIPCIÓN DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL.....	42
2.4 MONITOREO DE LAS VPCPAM.....	45
2.5 CONCLUSIONES.....	46
2.6 REFERENCIAS BIBLIOGRÁFICAS.....	47
<b>3. PREDICCIÓN DE VARIABLES MEDIANTE ESTRUCTURAS MRNAS AUTORREGRESIVAS NAR/NARX .....</b>	<b>49</b>

Diagnóstico de procesos industriales basado en predicción de estados funcionales con IA para el control y la programación de mantenimiento

3.1	INTRODUCCIÓN .....	49
3.2	REDES NEURONALES ARTIFICIALES (RNAs) .....	52
3.2.1	ENTRENAMIENTO DE LA MRNA .....	53
3.2.2	PREDICCIÓN DE VARIABLES MEDIANTE MRNA AUTORREGRESIVAS .....	57
3.3	RESULTADOS .....	59
3.3.1	PREDICCIÓN DE LAS VPCPAM MEDIANTE MRNA-NAR .....	59
3.3.2	PREDICCIÓN DE VARIABLES DE LA PLANTA DE PRESIÓN MEDIANTE MRNA-NARX .....	62
3.4	CONCLUSIONES .....	65
3.5	REFERENCIAS BIBLIOGRÁFICAS .....	65
<b>4.</b>	<b>ESTIMACIÓN DE ESTADOS FUNCIONALES DE PROCESOS A PARTIR DE CLASIFICACIÓN DIFUSA DE PATRONES .....</b>	<b>68</b>
	<b>RESUMEN .....</b>	<b>68</b>
4.1	INTRODUCCIÓN .....	68
4.2	LA CLASIFICACIÓN EN EL DIAGNÓSTICO AUTOMÁTICO DE PROCESOS .....	70
4.2.1	ENTRENAMIENTO Y RECONOCIMIENTO .....	70
4.2.2	PREPROCESAMIENTO DE LOS DATOS .....	72
4.2.3	CLASIFICACIÓN CONCRETA ( <i>HARD CLUSTERING</i> ) .....	73
4.2.4	CLASIFICACIÓN BORROSA O DIFUSA ( <i>FUZZY CLUSTERING</i> ) .....	75
4.3	SINTONIZACIÓN DEL CLASIFICADOR FCM Y ESTABLECIMIENTO DE LOS ESTADOS FUNCIONALES DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL .....	78
4.3.1	VALIDACIÓN DE CLASES (ESTADOS FUNCIONALES) DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL .....	81
4.3.2	EVALUACIÓN DEL CLASIFICADOR .....	82
4.4	SINTONIZACIÓN DEL CLASIFICADOR FCM Y ESTABLECIMIENTO DE LOS ESTADOS FUNCIONALES DE LA PLANTA DE PRESIÓN .....	83
4.4.1	VALIDACIÓN DE CLASES (ESTADOS FUNCIONALES) DE LA PLANTA DE PRESIÓN .....	85
4.4.2	EVALUACIÓN DEL CLASIFICADOR .....	86
4.5	CONCLUSIONES .....	86
4.6	REFERENCIAS BIBLIOGRÁFICAS .....	87
<b>5.</b>	<b>PREDICCIÓN DE ESTADOS FUNCIONALES DE PROCESOS MEDIANTE MRNAS NAR/NARX Y CLASIFICACIÓN DIFUSA .....</b>	<b>90</b>
	<b>RESUMEN .....</b>	<b>90</b>
5.1	INTRODUCCIÓN .....	90
5.1	ESQUEMA DE SUPERVISIÓN INTELIGENTE PARA EL DIAGNÓSTICO AUTOMÁTICO DE PROCESOS MEDIANTE MRNAS NAR/NARX Y CLASIFICACIÓN DIFUSA PARA LA PROGRAMACIÓN DE ACCIONES DE MANTENIMIENTO Y CONTROL .....	91
5.1.1	PREDICCIÓN DE ESTADOS FUNCIONALES Y PROGRAMACIÓN DE ACCIONES DE MANTENIMIENTO PARA EL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL .....	91
5.1.2	PROGRAMACIÓN DE ACCIONES DE MANTENIMIENTO MEDIANTE EL DIAGNÓSTICO INTELIGENTE DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL .....	94
5.1.2.1	PLANIFICACIÓN DEL MANTENIMIENTO PARA EL ESTADO FUNCIONAL (CLASE 1) .....	94
5.1.2.2	PLANIFICACIÓN DEL MANTENIMIENTO PARA EL ESTADO FUNCIONAL (CLASE 2) .....	95
5.1.2.3	PLANIFICACIÓN DEL MANTENIMIENTO PARA EL ESTADO FUNCIONAL (CLASE 3) .....	96

Diagnóstico de procesos industriales basado en predicción de estados funcionales con IA para el control y la programación de mantenimiento

5.1.2.4	PLANIFICACIÓN DEL MANTENIMIENTO PARA EL ESTADO FUNCIONAL (CLASE 4) .....	96
5.1.2.5	PLANIFICACIÓN DEL MANTENIMIENTO PARA EL ESTADO FUNCIONAL (CLASE 5).....	96
5.1.2.6	PLANIFICACIÓN DEL MANTENIMIENTO PARA EL ESTADO FUNCIONAL (CLASE 6).....	96
5.1.3	PREDICCIÓN DE ESTADOS FUNCIONALES Y PROGRAMACIÓN DE ACCIONES DE CONTROL PARA LA PLANTA DE PRESIÓN.....	97
5.1.4	PROGRAMACIÓN DE ACCIONES DE CONTROL MEDIANTE EL DIAGNÓSTICO INTELIGENTE DE LA PLANTA DE PRESIÓN. 100	
5.2	CONCLUSIONES.....	105
6.	ANEXOS.....	106
6.1	DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 1) .....	107
6.2	DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 2).....	108
6.3	DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 4).....	109
6.4	DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 5).....	110

## Lista de Figuras

FIGURA 1. OPERADOR DEL PROCESO VERSUS HISTÓRICO DE DATOS .....	21
FIGURA 2. ESTRATEGIAS DE LA IA UTILIZADAS EN EL DISEÑO DE SISTEMAS DE DIAGNÓSTICO AUTOMÁTICO .....	21
FIGURA 3. RED NEURONAL ARTIFICIAL MULTICAPA .....	23
FIGURA 4. ESQUEMA GRÁFICO DE UN ALGORITMO PSO .....	24
FIGURA 5. PORCENTAJE DE PUBLICACIONES (2007-2017) SOBRE EL DIAGNÓSTICO DE PROCESOS MEDIANTE TÉCNICAS DE LA INTELIGENCIA ARTIFICIAL. ....	26
FIGURA 6. NÚMERO DE PUBLICACIONES (2007-2017) SOBRE EL DIAGNÓSTICO DE PROCESOS MEDIANTE TÉCNICAS DE LA INTELIGENCIA .....	26
FIGURA 7. PLANTA DIDÁCTICA PARA LA IMPLEMENTACIÓN DE ALGORITMOS DE CONTROL, MÉTODOS DE SUPERVISIÓN Y TÉCNICAS DE AGRUPAMIENTO. ....	35
FIGURA 8. DIAGRAMA DE PROCESO DE LA PLANTA DIDÁCTICA PARA LA IMPLEMENTACIÓN DE ALGORITMOS DE CONTROL, MÉTODOS DE SUPERVISIÓN Y TÉCNICAS DE AGRUPAMIENTO.....	36
FIGURA 9. RECTA DE LINEALIDAD DE LA PLANTA DE PRESIÓN .....	38
FIGURA 10. SISTEMA DE CONTROL DIGITAL REALIMENTADO IMPLEMENTADO EN LA PLANTA DE PRESIÓN .....	39
FIGURA 11. RESPUESTA GRÁFICA DE LA IMPLEMENTACIÓN DE CONTROLADOR SOBRE LA PLANTA DE PRESIÓN (PUNTO DE OPERACIÓN 25%) .....	40
FIGURA 12. RESPUESTA GRÁFICA DE LA IMPLEMENTACIÓN DE CONTROLADOR SOBRE LA PLANTA DE PRESIÓN (PUNTO DE OPERACIÓN 45%) .....	40
FIGURA 13. RESPUESTA GRÁFICA DE LA IMPLEMENTACIÓN DE CONTROLADOR SOBRE LA PLANTA DE PRESIÓN (PUNTO DE OPERACIÓN 55%) .....	40
FIGURA 14. RESPUESTA GRÁFICA DE LA PLANTA DE PRESIÓN ANTE DIFERENTES DINÁMICAS .....	41
FIGURA 15. DIAGRAMA DE ENTRADAS/SALIDAS Y SUBSISTEMAS DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL .....	42
FIGURA 16. RESPUESTA GRÁFICA DE LAS VPCPAM DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL .....	46
FIGURA 17. ANALOGÍA ENTRE UN PERCEPTRÓN Y UNA NEURONA BIOLÓGICA.....	52
FIGURA 18. ESTRUCTURA DETALLADA DE UNA MRNA. ....	53
FIGURA 19. GRADIENTE DESCENDENTE EN UNA SUPERFICIE PARABÓLICA.....	54
FIGURA 20. RNA SIMPLE CON FUNCIÓN DE ACTIVACIÓN SIGMOIDE .....	55
FIGURA 21. ARQUITECTURA MRNA SERIE-PARALELO.....	58
FIGURA 22. ESTRUCTURA MRNA-NARX .....	58
FIGURA 23. RESPUESTA GRÁFICA DE LA ESTRUCTURA MRNA-NAR ENTRENADA PARA LA PREDICCIÓN DE LAS PPMCO ..	60
FIGURA 24. RESPUESTA GRÁFICA DE LA ESTRUCTURA MRNA-NAR ENTRENADA PARA LA PREDICCIÓN DE LA TPR .....	60
FIGURA 25. RESPUESTA GRÁFICA DE LA ESTRUCTURA MRNA-NAR ENTRENADA PARA LA PREDICCIÓN DE LA HR .....	61
FIGURA 26. RESPUESTA GRÁFICA DE LA ESTRUCTURA MRNA-NAR ENTRENADA PARA LA PREDICCIÓN DE LA TA .....	61
FIGURA 27. RESPUESTA GRÁFICA DE LA ESTRUCTURA MRNA-NARX ENTRENADA PARA LA PREDICCIÓN DE LA VC .....	63
FIGURA 28. RESPUESTA GRÁFICA DE LA ESTRUCTURA MRNA-NARX ENTRENADA PARA LA PREDICCIÓN DE LA EC .....	64
FIGURA 29. RESPUESTA GRÁFICA DE LA ESTRUCTURA MRNA-NARX ENTRENADA PARA LA PREDICCIÓN DE LA TD .....	64
FIGURA 30. ESQUEMA DE DIAGNÓSTICO CON BASE EN CLASIFICADORES.....	71
FIGURA 31. ESQUEMA DE SUPERVISIÓN CON BASE EN CLASIFICADORES. ....	72
FIGURA 32. REPRESENTACIÓN GRÁFICA DE UN CLASIFICADOR C-MEANS.....	73

FIGURA 33. DIAGRAMA DE FLUJO DEL ALGORITMO C-MEANS .....	74
FIGURA 34. REPRESENTACIÓN GRÁFICA DE UN CLASIFICADOR FUZZY C-MEANS.....	76
FIGURA 35. DIAGRAMA DE FLUJO DEL ALGORITMO FCM. ....	77
FIGURA 36. ABOUT, APLICACIÓN, U-MEANS .....	78
FIGURA 37. ESQUEMA UTILIZADO PARA ENTRENAR EL CLASIFICADOR DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL....	79
FIGURA 38. RESPUESTA GRÁFICA DE LAS VPCPAM Y DEL CLASIFICADOR SINTONIZADO (ENTRENAMIENTO) PARA EL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL.....	80
FIGURA 39. RESPUESTA GRÁFICA DE LAS VPCPAM Y DEL CLASIFICADOR SINTONIZADO (ENTRENAMIENTO) PARA EL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL. AMPLIACIÓN ENTRE 0 A 120 MUESTRAS. ....	81
FIGURA 40. RESPUESTA GRÁFICA DE LAS VPCPAM Y DEL CLASIFICADOR SINTONIZADO (ENTRENAMIENTO) PARA EL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL. AMPLIACIÓN ENTRE 2400 A 2540 MUESTRAS. ....	81
FIGURA 41. RESPUESTA GRÁFICA DE PRUEBA DEL CLASIFICADOR, AMPLIACIÓN ENTRE 1590 A 1700 MUESTRAS. ....	82
FIGURA 42. RESPUESTA GRÁFICA DE LAS VARIABLES DE LA PLANTA DE PRESIÓN Y DEL CLASIFICADOR SINTONIZADO (ENTRENAMIENTO).....	84
FIGURA 43. RESPUESTA GRÁFICA DE LAS VARIABLES DE LA PLANTA DE PRESIÓN Y DEL CLASIFICADOR SINTONIZADO (ENTRENAMIENTO). AMPLIACIÓN ENTRE 345 A 638 MUESTRAS. ....	85
FIGURA 44. RESPUESTA GRÁFICA DE LAS VARIABLES DE LA PLANTA DE PRESIÓN Y DEL CLASIFICADOR SINTONIZADO (ENTRENAMIENTO). AMPLIACIÓN ENTRE 1845 A 2000 MUESTRAS. ....	85
FIGURA 45. RESPUESTA GRÁFICA DE PRUEBA DEL CLASIFICADOR, AMPLIACIÓN ENTRE 120 A 350 MUESTRAS. ....	86
FIGURA 46. ESQUEMA DE SUPERVISIÓN INTELIGENTE PARA EL DIAGNÓSTICO AUTOMÁTICO DE PROCESOS MEDIANTE MRNAS Y CLASIFICACIÓN DIFUSA PARA LA PROGRAMACIÓN DE ACCIONES DE CONTROL Y MANTENIMIENTO. ....	91
FIGURA 47. EVOLUCIÓN DE LOS ESTADOS FUNCIONALES (CLASES) SEGÚN CLASIFICADOR Y PREDICTOR. BASE DE DATOS DE ENTRENAMIENTO, AMPLIACIÓN ENTRE MUESTRAS 5 A 40. ....	92
FIGURA 48. EVOLUCIÓN DE LOS ESTADOS FUNCIONALES (CLASES) SEGÚN CLASIFICADOR Y PREDICTOR. BASE DE DATOS DE ENTRENAMIENTO, AMPLIACIÓN ENTRE MUESTRAS 350 A 390. ....	93
FIGURA 49. EVOLUCIÓN DE LOS ESTADOS FUNCIONALES (CLASES) SEGÚN CLASIFICADOR Y PREDICTOR. BASE DE DATOS DE PRUEBA AMPLIACIÓN ENTRE MUESTRAS 1264 A 1304. ....	94
FIGURA 50. DIAGRAMA DE FLUJO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN LOS ESTADOS FUNCIONALES (CONDICIONES) DEL PROCESO DE PRODUCCIÓN DE AIRE MEDICINAL.....	95
FIGURA 51. DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 6). ....	97
FIGURA 52. EVOLUCIÓN DE LOS ESTADOS FUNCIONALES (CLASES) SEGÚN CLASIFICADOR Y PREDICTOR. BASE DE DATOS DE ENTRENAMIENTO AMPLIACIÓN ENTRE MUESTRAS 5 A 40. ....	98
FIGURA 53. EVOLUCIÓN DE LOS ESTADOS FUNCIONALES (CLASES) SEGÚN CLASIFICADOR Y PREDICTOR. BASE DE DATOS DE ENTRENAMIENTO AMPLIACIÓN ENTRE MUESTRAS 360 A 360. ....	98
FIGURA 54. EVOLUCIÓN DE LOS ESTADOS FUNCIONALES (CLASES) SEGÚN CLASIFICADOR Y PREDICTOR. BASE DE DATOS DE ENTRENAMIENTO AMPLIACIÓN ENTRE MUESTRAS 900 A 950. ....	99
FIGURA 55. EVOLUCIÓN DE LOS ESTADOS FUNCIONALES (CLASES) SEGÚN CLASIFICADOR Y PREDICTOR. BASE DE DATOS DE PRUEBA AMPLIACIÓN ENTRE MUESTRAS 360 A 360. ....	100
FIGURA 56. APLICACIÓN <i>DIAGNOSIS_VI</i> PARA LA SUPERVISIÓN INTELIGENTE DE LA PLANTA DE PRESIÓN. ....	101
FIGURA 57. DIAGRA DE BLOQUES IMPLEMENTADO PARA LA PROGRAMACIÓN DE ACCIONES DE CONTROL SOBRE LA PLANTA DE PRESIÓN. ....	101

Diagnóstico de procesos industriales basado en predicción de estados funcionales con IA para el control y la programación de mantenimiento

FIGURA 58. RESPUESTA GRÁFICA DE LA IMPLEMENTACIÓN DEL SISTEMA DE SUPERVISIÓN INTELIGENTE SOBRE LA PLANTA DE PRESIÓN. ESTADOS FUNCIONALES 6 Y 7. ....	102
FIGURA 59. RESPUESTA GRÁFICA DE LA IMPLEMENTACIÓN DEL SISTEMA DE SUPERVISIÓN INTELIGENTE SOBRE LA PLANTA DE PRESIÓN. ESTADOS FUNCIONALES 2, 4, 5 Y 6. ....	103
FIGURA 59. RESPUESTA GRÁFICA DE LA IMPLEMENTACIÓN DEL SISTEMA DE SUPERVISIÓN INTELIGENTE SOBRE LA PLANTA DE PRESIÓN. ESTADOS FUNCIONALES 2, 3, 4, 5 Y 6. ....	104
FIGURA 50. DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 1). ....	107
FIGURA 50. DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 2). ....	108
FIGURA 50. DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 4). ....	109
FIGURA 50. DIAGRAMA DE FLUJO PROPUESTO PARA ESTABLECER LAS ACCIONES DE MANTENIMIENTO BASADAS EN EL ESTADO FUNCIONAL (CLASE 5). ....	110

## Lista de Tablas

TABLA 1. COMPARACIÓN DE TÉCNICAS DE IA PARA EL DIAGNÓSTICO DE PROCESOS INDUSTRIALES .....	27
TABLA 2. SUBSISTEMA 1: TOMA DE AIRE AÉREA. ....	43
TABLA 3. SUBSISTEMA 2: FILTRADO INICIAL. ....	43
TABLA 4. SUBSISTEMA 3: TABLERO DE CONTROL. ....	43
TABLA 5. SUBSISTEMA 4: COMPRESOR DE AIRE.....	43
TABLA 6. SUBSISTEMA 5: TANQUE PULMÓN. ....	44
TABLA 7. SUBSISTEMA 6: UNIDAD DE SECADO.....	44
TABLA 8. SUBSISTEMA 7: FILTRADO FINAL. ....	44
TABLA 9. SUBSISTEMA 8: SISTEMA DE MONITOREO. ....	44
TABLA 10. SUBSISTEMA 9: SISTEMA DE RESERVA. ....	45
TABLA 11. SUBSISTEMA 10: SISTEMA DE SUSPENSIÓN AUTOMÁTICA DEL SUMINISTRO DE AIRE MEDICINAL. ....	45
TABLA 12. SUBSISTEMA 11: SISTEMA DE DISTRIBUCIÓN DE AIRE MEDICINAL. ....	45
TABLA 13. RESULTADOS DEL ENTRENAMIENTO DE LA MRNA-NAR PARA LA PREDICCIÓN DE LAS VPCPAM. ....	60
TABLA 14. RESULTADOS NUMÉRICOS DE LAS MRNA-NAR PARA LA PREDICCIÓN DE LAS VPCPAM. ....	62
TABLA 15. RESULTADOS DEL ENTRENAMIENTO DE LA MRNA-NAR PARA LA PREDICCIÓN DE LAS VARIABLES EN LA PLANTA DE PRESIÓN.....	63
TABLA 16. RESULTADOS NUMÉRICOS DE LAS MRNA-NARX PARA LA PREDICCIÓN DE LAS VARIABLES EN LA PLANTA DE PRESIÓN. ....	64
TABLA 17. DESCRIPCIÓN DE LOS ESTADOS FUNCIONALES DEL SISTEMA DE PRODUCCIÓN DE AIRE MEDICINAL A PARTIR DEL CLASIFICADOR FCM DISEÑADO.....	80
TABLA 18. MEDIDAS DE VALIDES DE PARTICIÓN DIFUSA.....	81
TABLA 19. DESCRIPCIÓN DE LOS ESTADOS FUNCIONALES DE LA PLANTA DE PRESIÓN A PARTIR DEL CLASIFICADOR FCM DISEÑADO. ....	84
TABLA 20. MEDIDAS DE VALIDES DE PARTICIÓN DIFUSA .....	85

## **Agradecimientos**

*Cuando Violeta observaba las gráficas del esquema de supervisión, decía que eran toboganes y castillos... ella siempre estuvo presente, a veces me pedía que terminara rápido para jugar un poco. Silvana permitió que Violeta existiera. A Silvana y Violeta, mil gracias por el apoyo y la paciencia infinita.*

*A los profesores Jesús María López (Director) y Henry Omar Sarmiento (Co-director), por el apoyo incondicional y por siempre haber creído en mi trabajo.*

## **Introducción general**

Mantener los índices deseados de producción en una organización es una tarea compleja. Independientemente del tipo de procesos a nivel industrial, se encuentran tres índices fundamentales: confiabilidad, mantenibilidad y disponibilidad. La confiabilidad es un índice que depende tanto del departamento de producción como del área de mantenimiento. Lo anterior hace que el departamento de mantenimiento este en constante búsqueda de alternativas que permitan mantener al máximo la confiabilidad; detectando mediante sistemas de diagnóstico las perturbaciones internas, errores humanos, incertidumbre y fallas en los procesos.

La información histórica del comportamiento dinámico de las variables en los procesos se ha convertido en una herramienta fundamental para la implementación de algoritmos fundamentados 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.

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. 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. Por otro lado, la predicción se presenta como una alternativa eficiente para la anticipación de comportamientos dinámicos en el diagnóstico automático. La predicción se utiliza para anticipar la transición hacia estados funcionales no deseados, permitiendo prevenir las fallas antes de su ocurrencia y, por lo tanto, manteniendo la confiabilidad deseada. Una de las estrategias para la predicción de sistemas con dinámicas complejas está basada en la imitación del procesamiento humano, y es conocida como red neuronal artificial (RNA).

## **Objetivos**

### **Objetivo general**

Implementar una estructura de supervisión «inteligente» para el diagnóstico de procesos, a través de la predicción de estados funcionales mediante redes neuronales artificiales y agrupamiento difuso, que permita ejecutar acciones de control sobre el proceso y programar acciones de mantenimiento requeridas.

### **Objetivos específicos**

- Describir el estado del arte del diagnóstico de procesos implementando inteligencia artificial.
- Implementar la estructura de predicción y de estimación de estados en un esquema de supervisión basado en clasificadores.
- Definir las acciones de control y mantenimiento requeridas de acuerdo con los estados funcionales estimados.
- Validar el diagnóstico inteligente y la programación de actividades de mantenimiento y control en procesos simulados y en un proceso real del sector salud.

## **Estructura del trabajo**

Para cumplir con el objetivo general se establecieron cinco capítulos que estructuran el trabajo, así:

En el capítulo 1 se presenta una revisión sobre el diagnóstico de fallas en procesos industriales mediante IA, se exponen las generalidades, principales estrategias inteligentes utilizadas en el diagnóstico, y un análisis comparativo de los trabajos encontrados en la literatura técnica. La descripción del estado del arte permite encontrar resultados importantes para soportar la investigación. En los trabajos consultados y que estructuraron el estado del arte, los autores resaltaron la efectividad de combinar estrategias de la IA en el diseño de esquemas de diagnóstico automático de procesos.

En el capítulo 2 se describen los procesos de prueba para los cuales se diseñó la estructura de supervisión inteligente. Uno de los procesos está conformado por una planta, en la cual se regula la presión en un tanque de almacenamiento mediante una estructura de control realimentado. El otro proceso comprende un sistema de producción de aire medicinal. Para ambos procesos se describen sus componentes, así como la respuesta gráfica de las variables que intervienen en cada uno de ellos. El conocimiento del proceso por parte del experto es fundamental durante el diseño del diagnóstico inteligente, en especial en la descripción cualitativa de estados funcionales.

En el capítulo 3 se presenta la predicción de variables mediante estructuras neuronales autorregresivas MRNAs-NAR/NARX. Se muestran algunos trabajos e investigaciones donde se emplearon las RNAs como estructuras de predicción, obteniendo resultados que superaron las técnicas convencionales basadas en métodos estadísticos. Se muestran además las configuraciones de las RNAs propuestas, resultados de entrenamiento, validación, y prueba de la predicción de variables de los dos sistemas de prueba.

En el capítulo 4 se presentan los estados funcionales de los sistemas de prueba a partir de la clasificación difusa de patrones. El establecimiento de los estados funcionales mediante la clasificación difusa de patrones es soportado por un marco teórico, en el que se incluyen trabajos e investigaciones donde se implementaron clasificadores mediante lógica difusa en el diagnóstico de procesos. Durante el análisis de las clases obtenidas por el clasificador, se tuvo en cuenta la experticia de los operadores del proceso, para el establecimiento de los estados funcionales de los procesos de prueba.

En el capítulo 5 se presentan los resultados del esquema de supervisión inteligente propuesto para los dos sistemas de prueba. Se describe como se combinó la predicción mediante MRNAs-NAR/NARX con el clasificador difuso, y se muestran los resultados gráficos y el análisis respectivo.

## Contribuciones

Como resultados del capítulo 1 relacionado con el estado del arte del diagnóstico automático de procesos industriales basado en IA, se generó la siguiente publicación:

- Ramírez, J., Sarmiento, H., López J. (2018). Diagnóstico de fallas en procesos industriales mediante inteligencia artificial. *Revista Espacios*, 28, pp. 12-28. *ISSN: 0798-1015*

La experticia y conocimiento de los procesos es fundamental para el establecimiento de los estados funcionales. Comprender como responden los procesos ante diferentes señales, controladores y perturbaciones, dotan de experticia al operador para la posterior descripción cualitativa de las clases generadas por los esquemas de clasificación difusa. Como resultados del capítulo 2, asociado a la descripción de los procesos de prueba, se generó la siguiente publicación, en la que se implementaron diversas estrategias de control sobre la planta de presión utilizada:

- Ramírez, J., López, J., Muñoz, N. (2018). *Particle Swarm Metaheuristic Applied to the Optimization of a PID Controller. Contemporary Engineering Sciences*. 11, p.3333 – 3342. *ISSN: 1314-7641*.

Del capítulo 4, se generó una publicación en la que se establecieron los estados funcionales del sistema de producción de aire medicinal:

- Ramírez, J., Sarmiento, H., López J. (2017). Diseño de un Clasificador Difuso para el Establecimiento de los Estados Funcionales de un Sistema de Producción de Aire Medicinal. *Revista Información Tecnológica*, 28(6), pp. 147-160. *ISSN: 0718-0764*.

Como resultado del capítulo 4 y 5, se generó una publicación en la que se establecieron las acciones de mantenimiento a partir de los estados funcionales obtenidos mediante la clasificación difusa de patrones:

- Ramírez, J., Sarmiento, H., López J. (2018). Programación de acciones de mantenimiento basada en los estados funcionales obtenidos mediante un clasificador difuso de un sistema de producción de aire medicinal. *Revista Espacios*, 39(44), *ISSN: 0798-1015*.

## **1. Diagnóstico de fallas en procesos industriales mediante inteligencia artificial: revisión del estado del arte**

### **Resumen**

Los procesos industriales involucran variables que deben ser gestionadas por sistemas de monitoreo. Diversos estados funcionales en los procesos industriales pueden ser detectados por sistemas de diagnóstico basados en información histórica de las variables y en inteligencia artificial. En este capítulo se presenta una revisión sobre el diagnóstico de fallas en procesos industriales mediante inteligencia artificial, se presentan las generalidades, principales estrategias inteligentes utilizadas en el diagnóstico, y un análisis comparativo de los trabajos encontrados en la literatura técnica.

### **1.1 Introducción**

Los procesos industriales juegan un papel primordial dentro del sector productivo. Las exigencias de producción han obligado a buscar estrategias como el diagnóstico automático para mantener la producción continua con minimización de fallas en las máquinas. En términos generales, un proceso industrial provee gran cantidad de variables medidas, controladas y manipuladas que asocian no linealidades e incertidumbres (Sarmiento, 2013). Por lo anterior, se hace necesario monitorear las variables, con el fin de adquirir información sobre el comportamiento dinámico del proceso. La información histórica y presente resultante del monitoreo es utilizada para implementar sistemas inteligentes de supervisión. Dentro del esquema de supervisión se encuentra la detección de las fallas, el diagnóstico y el restablecimiento de las condiciones de operación de acuerdo con criterios de desempeño del proceso (Hurtado, *et al.*, 2016). El diagnóstico a su vez se divide en dos grupos. El primero corresponde a procesos en los cuales se requiere de un modelo explícito mientras que el segundo grupo se apoya en el histórico de datos con información importante de estados funcionales del proceso (Hernández, *et al.*, 2014) (Soualhi, *et al.*, 2013).

La inteligencia artificial (IA) es una disciplina que presenta ventajas en la solución de sistemas complejos o con un entorno bajo incertidumbre; además, permite de manera flexible solucionar problemas multidisciplinarios de manera eficiente mediante diferentes perspectivas (Kose, *et al.*, 2017) y soportar ambientes cooperativos en la toma de decisiones (Khalyasmaa, *et al.*, 2017) (Santos, *et al.*, 2011) (Reyes, *et al.*, 2016).

La IA es una herramienta capaz de resolver el problema de análisis de información histórica de los procesos, encontrando tendencias, patrones, dinámicas, y pronósticos, en grandes volúmenes de datos (Sarmiento, 2013).

La revisión presentada en este trabajo muestra nuevas perspectivas, y se expone como un soporte para la comunidad académica que se encuentre en el desarrollo de investigaciones dirigidas al diseño de sistemas automáticos para el diagnóstico de fallas en procesos industriales. De igual forma, el trabajo pretende mostrarse en el sector industrial como una tendencia basada en la inteligencia artificial para la detección temprana de fallas, a partir de información histórica de la dinámica de los sistemas productivos. En la actualidad diversos sectores industriales cuentan con sistemas sofisticados de monitoreo que se quedan simplemente en el registro de información sin interpretación de los datos adquiridos; alertando al operador solo ante la falla inminente. Lo anterior presenta el inconveniente de permitir que las máquinas transiten hacia la pérdida de su función, perturbando la confiabilidad del proceso. Con la implementación de estrategias basadas en IA se podría analizar la información histórica adquirida por sistemas de monitoreo, prevenir fallas y programar acciones preventivas de mantenimiento.

En los últimos 10 años se han encontrado diversas revisiones sobre la IA implementada en sistemas para el diagnóstico de procesos industriales. En (Hurtado, *et al.*, 2016), 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 estrategias basadas en redes neuronales, lógica difusa, y sistemas inmunes se exponen en (Hurtado, *et al.*, 2016), como las principales estrategias para la identificación y el diagnóstico de fallas. En (Uraikul, *et al.*, 2007) se presenta una visión general de los sistemas inteligentes para el monitoreo, control y diagnóstico de procesos a nivel de la ingeniería de sistemas, discutiendo tres enfoques adoptados con frecuencia durante la construcción de sistemas automatizados: enfoque impulsado por datos, enfoque analítico y enfoque basado en conocimiento. De acuerdo con (Uraikul, *et al.*, 2007), el enfoque basado en conocimiento se ha combinado con las técnicas de IA como los sistemas expertos, lógica difusa, aprendizaje automático y reconocimiento de patrones, para adaptar sistemas de monitoreo, control y diagnóstico en la industria de procesos.

Una perspectiva sobre la detección y el diagnóstico automático de fallas en procesos complejos se presenta en (Xuewu & Zhiwei, 2013). La perspectiva está enfocada hacia el uso de información reflejada en el procesamiento de datos y la implementación de la IA y el aprendizaje de máquina. En (Xuewu & Zhiwei, 2013) se resalta la importancia de la comprensión humana para la interpretación de datos y se presenta una división basada en el tipo de información, la cual puede ser representada por modelos, señales o conocimiento del experto. En (Bayar, *et al.*, 2015) se presenta una revisión sobre los sistemas biológicos aplicados al diagnóstico de fallas. En general, se muestra el sistema inmune como una estrategia de IA capaz de realizar tareas de detección, monitoreo, diagnóstico y recuperación de procesos. En el diagnóstico inteligente

basado en sistemas biológicos, las fallas y errores son tratadas como enfermedades o cuerpos extraños, los cuales son extinguidos por el sistema inmune, llevando el proceso a la recuperación de las condiciones de operación deseadas.

Un área de interés en la ingeniería corresponde a la detección de fracturas en sistemas mecánicos. En (Nasiri, *et al.*, 2017) se presenta una revisión sobre 5 estrategias de IA utilizadas para la detección de fracturas en mecanismos. Entre las estrategias utilizadas se mencionan las redes neuronales artificiales, lógica difusa, redes bayesianas, algoritmos genéticos y el razonamiento basado en casos. La ingeniería electrónica también se ha favorecido de la IA para la predicción de fallas y el pronóstico del índice de salud de componentes electrónicos. En (Bhargava, *et al.*, 2014) se presenta una revisión de las principales estrategias de predicción de fallas en las cuales se encuentran las técnicas que utilizan el concepto de Soft Computing. Las redes neuronales, lógica difusa y las estrategias neurodifusas se presentan como las principales técnicas usadas para la predicción de fallas y la posterior programación de acciones, que permitan reestablecer la confiabilidad del dispositivo electrónico. Una revisión de los principales algoritmos utilizados para el monitoreo y diagnóstico de fallas se presenta en (Pandian, *et al.*, 2009); entre los algoritmos mencionados se destacan las redes neuronales y los algoritmos genéticos. En general en (Hurtado, *et al.*, 2016), (Uraikul, *et al.*, 2007), (Xuewu & Zhiwei, 2013), (Bayar, *et al.*, 2015), (Nasiri, *et al.*, 2017), (Bhargava, *et al.*, 2014) y (Pandian, *et al.*, 2009) se muestran diversas perspectivas, que involucran la IA en el diseño de sistemas automáticos para el diagnóstico de fallas.

Este capítulo se divide en cuatro secciones. En la primera sección se hace una introducción sobre el diagnóstico de fallas en procesos industriales y las principales técnicas que se emplean en su análisis. En la segunda sección se presenta la metodología utilizada para el proceso de revisión sistemática de la literatura especializada y una breve descripción de las principales técnicas utilizadas en el diagnóstico de fallas. En la sección de pruebas y resultados se presentan los resultados obtenidos en la búsqueda y la clasificación de las técnicas utilizadas en el diagnóstico de fallas. Finalmente, en la última sección se presentan las principales conclusiones derivadas del capítulo.

## **1.2 Metodología de búsqueda de información**

Entendiendo la necesidad de prevenir las fallas en los procesos manteniendo a su vez los índices deseados, en especial la confiabilidad, se desarrolló una revisión de estrategias inteligentes implementadas en sistemas para el diagnóstico automático de fallas en procesos industriales; concretamente las estrategias que utilizan información histórica para predicción, clasificación y obtención de estados funcionales en los procesos; y que se implementan por medio de redes neuronales, algoritmos bio-inspirados, lógica difusa o la combinación de las mismas.

Las bases de datos consultadas para la investigación fueron IEEE Xplore, Science Direct, Scielo y Scopus. La búsqueda inició con información sobre el diagnóstico de procesos sin la inclusión

de la IA, posteriormente se adicionaron adjetivos a la búsqueda para filtrar la información, por ejemplo: diagnóstico automático de procesos. En vista de que la búsqueda no presentaba buenos resultados se decidió cambiar la expresión por diagnóstico inteligente de fallas. Finalmente, la búsqueda presentó mejores resultados al incluir la expresión “inteligencia artificial”; sin embargo, la información mostró algunos trabajos sobre la implementación de la inteligencia artificial en el área de la salud. Para eliminar lo anterior se anexó el sustantivo “falla” en la búsqueda. En las cuatro bases de datos utilizadas se filtró la información en una ventana temporal de 10 años, en este caso, septiembre de 2007 a septiembre de 2017.

### **1.3 Diagnóstico de procesos mediante inteligencia artificial**

El diagnóstico automático de procesos se encuentra implementado bajo dos metodologías. La primera de ellas requiere de un modelo explícito del modelo, mientras que la segunda utiliza información histórica de la dinámica del proceso. El diagnóstico basado en modelos explícitos del proceso involucra modelos matemáticos de difícil obtención; además, encontrar la relación matemática entre la falla y el modelo es una tarea compleja debido a la cantidad de componentes dinámicos que conforman el proceso (Biçen & Aras, 2104). El diagnóstico basado en información de las variables de los procesos permite clasificar y comparar las variables respecto a un valor esperado. Las desviaciones entre el valor de las variables y el valor esperado se procesan por sistemas implementados bajo IA, sistemas que además permiten la incorporación del conocimiento del experto del proceso para discriminar las desviaciones como: anomalías, fallas y errores (Hernández, *et al.*, 2014) (Bayar, *et al.*, 2015). Lo anterior permite obtener estados funcionales que describen fallas o estados intermedios que brindan información del proceso (Ramírez, *et al.*, 2017).

El diagnóstico basado en información histórica del proceso se ha combinado con la IA para diseñar sistemas inteligentes y automáticos caracterizados por robustez ante anomalías (Lemos, *et al.*, 2013). La información histórica del comportamiento dinámico de las variables en los procesos se ha convertido en una herramienta fundamental para el entrenamiento de estrategias inteligentes. Mediante el diagnóstico automático se logra determinar el estado de falla para su posterior intervención, la cual permitirá llevar la(s) salida(s) a las condiciones de diseño deseadas.

Los sistemas para el diagnóstico de procesos basado en la inteligencia artificial presentan dos ventajas importantes. La primera consiste en que el diseño del diagnóstico puede ser ejecutado fuera de línea, es decir, sin alterar los índices de CMD (Confiabilidad, Mantenibilidad y Disponibilidad) del proceso (Ramírez, 2016) (Mora, 2016). La segunda ventaja es que se puede incorporar el conocimiento de los expertos del proceso permitiendo hacer una relación difusa con posibilidad de manejar el concepto de incertidumbre (Sarmiento, *et al.*, 2013).

El esquema convencional para el diagnóstico inteligente de procesos está estructurado por tres componentes: adquisición de señales o histórico de datos, extracción de características, y

clasificación de las fallas (Worden, et al., 2011) (Shatnawi & khassaweneh, 2014) (Lei, et al., 2016). En la etapa de adquisición, los datos son registrados por sensores instalados sobre puntos críticos o dinámicos del proceso (Ramírez, et al., 2017). El histórico de datos es utilizado en la etapa de entrenamiento y prueba del diseño. En la extracción de características, los expertos describen rasgos cualitativos de clases semejantes asociadas a estados funcionales que permiten clasificar las fallas. Al esquema anterior se le puede anexar un componente predictivo capaz de anticipar el próximo estado del proceso (Sarmiento, 2013). La predicción de estados funcionales permite programar acciones predictivas antes de la transición a estados de falla.

Durante la sintonización de estrategias inteligentes para el diagnóstico automático, se utiliza el conocimiento del experto humano. El aporte del operador permite crear una asociación cualitativa durante la extracción de características dinámicas del proceso y la generación de consecuentes (acciones de mantenimiento) (Lemos, et al., 2013). Lo anterior permite calificar al operario como el principal actor en la toma de decisiones a nivel industrial ubicándolo en la cima de los sistemas de supervisión (Sarmiento, 2013).

### **1.3.1 Información histórica del comportamiento dinámico de los procesos**

La información de diversas dinámicas, adquirida por sensores instalados en los procesos, es parte fundamental de los sistemas de monitoreo, supervisión y diagnóstico (Ramírez, et al., 2017). La información es almacenada en bases de datos que terminan por convertirse en registros de gran volumen; en algunos casos los datos se muestran en línea y se supervisan por operadores humanos, en otros casos los datos se almacenan y se menosprecian. En ambos casos y debido a la cantidad de datos adquiridos, se presentan problemas que se sintetizan en el análisis de la información.

El volumen de los datos registrados en tareas de monitoreo depende del periodo de adquisición de los mismos. Periodos cortos producen bases de datos de gran volumen difícilmente interpretadas por un operador humano, mientras que períodos de adquisición largos provocan pérdida de información que generalmente se encuentra inmersa en eventos esporádicos asociados a las no linealidades de la dinámica de los mecanismos en las máquinas, y a su desgaste por operación (Ramírez, et al, 2016). Analizar el histórico de datos del proceso presenta ventajas que podrían facilitar la detección temprana de fallas y la programación preventiva de acciones que permitan mantener la confiabilidad del proceso.

La información histórica adquirida del comportamiento dinámico de los procesos es almacenada en una matriz de datos  $\mathbb{X}$ . El tamaño de  $\mathbb{X}$  depende de la cantidad de sensores ( $a_{i,m}$ ) dispuestos en las máquinas y puntos críticos. Cada fila de  $\mathbb{X}$  corresponde a un vector de datos  $x_i = [a_{i,1} \ a_{i,2} \ \dots \ a_{i,m}]$  registrados en un instante de tiempo ( $i$ ). La pregunta del operador del proceso es qué hacer con esta información (ver Figura 1); más aún, si el volumen de información se caracteriza por su gran tamaño, y por contener dinámicas ocultas en ciertos vectores que podrían indicar estados o transiciones importantes en el comportamiento del sistema.

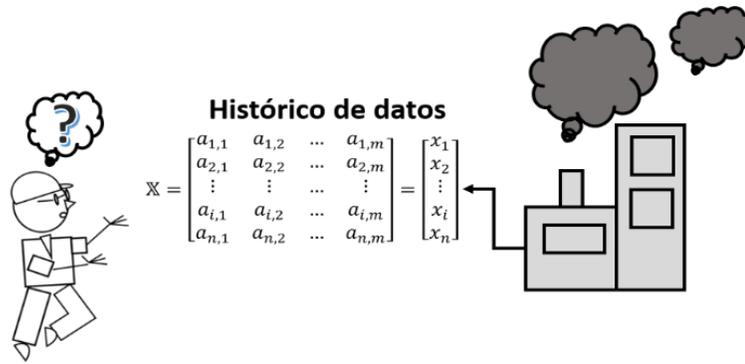


Figura 1. Operador del proceso versus historico de datos  
Fuente: Elaboración propia.

La pregunta sobre qué hacer con el historico de datos y la medición presente de las variables en los procesos se puede solucionar a partir de estrategias pertenecientes a la IA. Entre estas estrategias se encuentran: las redes neuronales artificiales, algoritmos bio-inspirados, y lógica difusa. En la actualidad los ingenieros en las plantas pueden disponer de diversas opciones para analizar la información y diseñar sistemas de diagnóstico automático (ver Figura 2), aprovechando el historico de datos y la particularidad de que el diseño se puede realizar fuera de línea, sin intervención sobre el proceso, con solo algunas validaciones en línea para determinar el desempeño del diagnóstico.

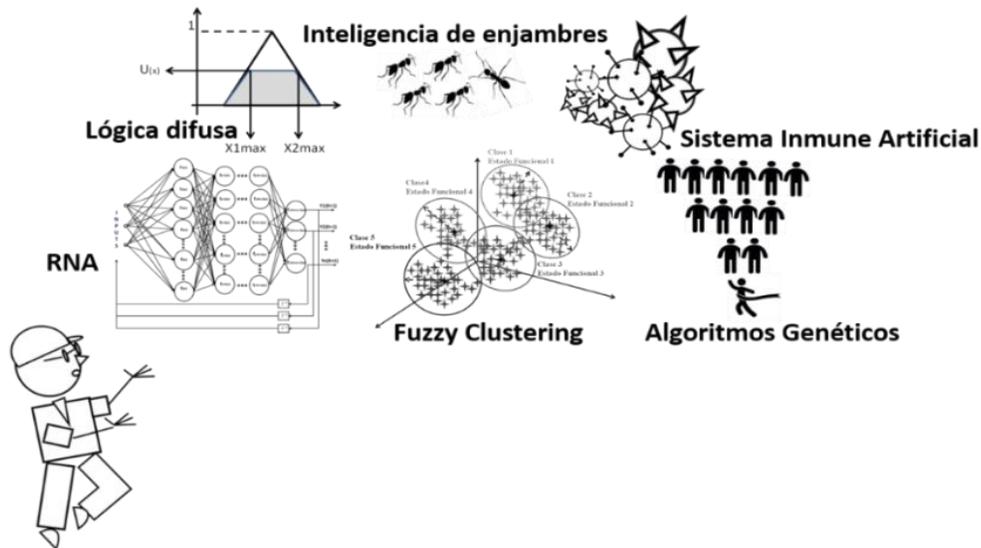


Figura 2. Estrategias de la IA utilizadas en el diseño de sistemas de diagnóstico automático  
Fuente: Elaboración propia.

A continuación, se presenta una breve descripción de cada estrategia inteligente: lógica difusa, redes neuronales, algoritmos bio-inspirados y estrategias combinadas. Una descripción detallada de estas estrategias está fuera del alcance del presente documento. Al final de cada

estrategia se referencian algunas de las investigaciones y trabajos sobre el diagnóstico automático.

### **1.3.2 Estrategias basadas en la lógica difusa**

La lógica difusa es una propuesta que busca incorporar en los sistemas de ingeniería el conocimiento expresado en términos lingüísticos o expresiones verbales (Ramírez, et al., 2017). Las expresiones lingüísticas utilizadas en la lógica borrosa se denominan variables lingüísticas ( $V_L$ ) y se definen como aquellas variables que no adoptan un valor numérico, sino que adoptan un valor lingüístico.

Mientras que en la lógica convencional un elemento ( $A$ ) solo puede pertenecer mediante un grado de pertenencia ( $\mu$ ) =  $\{0, 1\}$ ; falso o verdadero a un único conjunto ( $X$ ), en la lógica borrosa el elemento ( $A$ ) puede pertenecer simultáneamente al conjunto ( $X$ ) y ( $Y$ ) mediante un grado de pertenencia ( $\mu_{X(A)} = [0,1]$ ) y ( $\mu_{Y(A)} = [0,1]$ ). El grado de pertenencia ( $\mu$ ) trabaja en todo el intervalo continuo  $[0,1]$  (Jantzen, 2007) y se extiende en general para ( $n$ ) elementos y ( $m$ ) conjuntos mediante funciones de pertenencia.

Una función de pertenencia se define como aquella aplicación que asocia a cada elemento de un conjunto borroso el grado con que pertenece al valor lingüístico asociado (Aguilar-Martín, 2007). Lo anterior permite expresar la pertenencia del elemento ( $A$ ) a los conjuntos ( $X$ ) y ( $Y$ ) mediante la definición alterna mostrada en (1).

$$X = \{(A, \mu_{X(A)}) | A \in U\}; Y = \{(A, \mu_{Y(A)}) | A \in U\}; (\mu_{X(A)} = [0,1] ; (\mu_{Y(A)} = [0,1] \quad (1)$$

La lógica difusa se ha utilizado en el diseño de sistemas para el diagnóstico automático por medio de estrategias que involucran modelos lineales y no lineales difusos (Zarkovic & Stojkovic, 2017), clasificación difusa (*fuzzy Clustering*) y establecimiento de estados funcionales de procesos complejos (Sarmiento, et al., 2103), programación del mantenimiento de un sistemas de producción de aire medicinal a partir de los estados funcionales obtenidos mediante la implementación de un clasificador difuso (Ramírez, 2016); y clasificación difusa de señales de vibración para el monitoreo de rodamientos (Otero, *et al.*, 2011). La lógica difusa también ha logrado introducirse en la ingeniería de mantenimiento en estrategias como el mantenimiento basado en condición y el mantenimiento centrado en confiabilidad, basados en el diagnóstico de los modos de falla (Felecia, 2014), (Hernández, *et al.*, 2015), y en modelado difuso para determinar el periodo de mantenimiento de redes eléctricas bajo la confiabilidad del proceso (Escalona, 2013). El éxito de las clasificación difusa de patrones en los sistemas de diagnóstico se debe a que el agrupamiento 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 permite incrementar el espacio de búsqueda de estados de falla minimizando las restricciones (Ramírez, *et al.*, 2017).

### 1.3.3 Estrategias basadas en redes neuronales

Las redes neuronales artificiales RNA son estructuras conexionistas inspiradas en la neurona biológica. Las RNA imitan la forma de procesamiento humano tanto en su estructura como en la capacidad de procesamiento paralelo y aprendizaje (Gómez, *et al.*, 2017) (Santa Cruz & Correa, 2017). Dependiendo de la configuración, las RNA pueden cumplir con tareas de reconocimiento, identificación de sistemas lineales y no lineales, predicción, clasificación y control automático de procesos. En el diagnóstico automático las RNA se utilizan como estrategias para la clasificación, modelación y predicción de fallas. Entre las configuraciones de las RNA se destaca la conexión multicapa donde cada unidad funcional neuronal se conecta con las demás por medio de lazos que se caracterizan por ponderar la señal mediante un peso sináptico. La Figura 3 muestra una RNA multicapa y la representación de cada unidad funcional que la conforma.

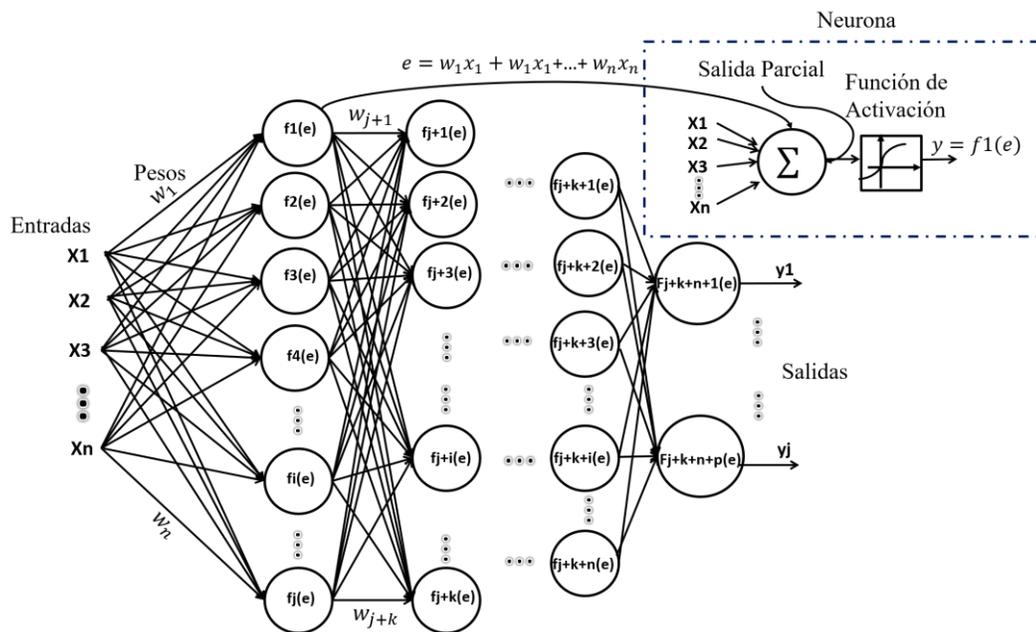


Figura 3. Red Neuronal Artificial Multicapa  
Fuente: Elaboración propia.

Las RNA 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 (Flores, *et al.*, 2016) para el diagnóstico de fallas en líneas de transmisión eléctrica. En (Cadena, *et al.*, 2008) se implementa una RNA probabilística para la detección de fallas incipientes en transformadores. Un caso similar se muestra en (Delgado, *et al.*, 2013) para la detección fallas en rodamientos, implementando una RNA jerárquica en la etapa de clasificación dentro de un esquema de monitoreo basado en condición. En (Cai, *et al.*, 2014) se presenta un esquema basado en una RNA Bayesiana para la detección de fallas mediante la fusión de información de múltiples fuentes, mientras que en (Jafari, *et al.*, 2014) y (Shatnawi & khassaweneh, 2014) 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 (Ramírez, *et al.*, 2017).

### 1.3.4 Estrategias bio-inspiradas

Las estrategias bio-inspiradas están fundamentadas en la imitación del comportamiento de seres vivos como bancos de peces, parvadas de aves, colonia de hormigas, y enjambre de abejas. También se tienen evidencias de algoritmos inspirados en estructuras biológicas como: el sistema inmune, la forma de reproducción y el sistema genético del ser humano. La imitación de sistemas biológicos permite diversificar mediante algoritmos los resultados obtenidos en la medida en que se obtiene mejores resultados, extendiendo a su vez el espacio de búsqueda en un espacio n dimensional (Flórez, *et al.*, 2018).

La inspiración del comportamiento biológico ha permitido dar solución a problemas complejos flexibilizando aspectos como: manejo de incertidumbre, extensión del espacio de búsqueda, probabilidad, y restricciones. La Figura 4 representa un algoritmo PSO (*particle swarm optimization*) en el cual un enjambre formado por la matriz  $X$  contiene la población con las partículas necesarias para dar solución a problemas de búsqueda u optimización. La partícula ( $x_i$ ) es evaluada de acuerdo con una función de aptitud mono o multi-objetivo que mide la capacidad de la partícula en la iteración ( $k$ ) para dar solución al problema. La posición ( $P_i$ ) y velocidad ( $V_i$ ) de la partícula es modificada conforme se evalúa la función de aptitud. El algoritmo PSO imita el comportamiento de parvadas de aves en la forma como buscan su comida y su mejor refugio para pasar la noche.

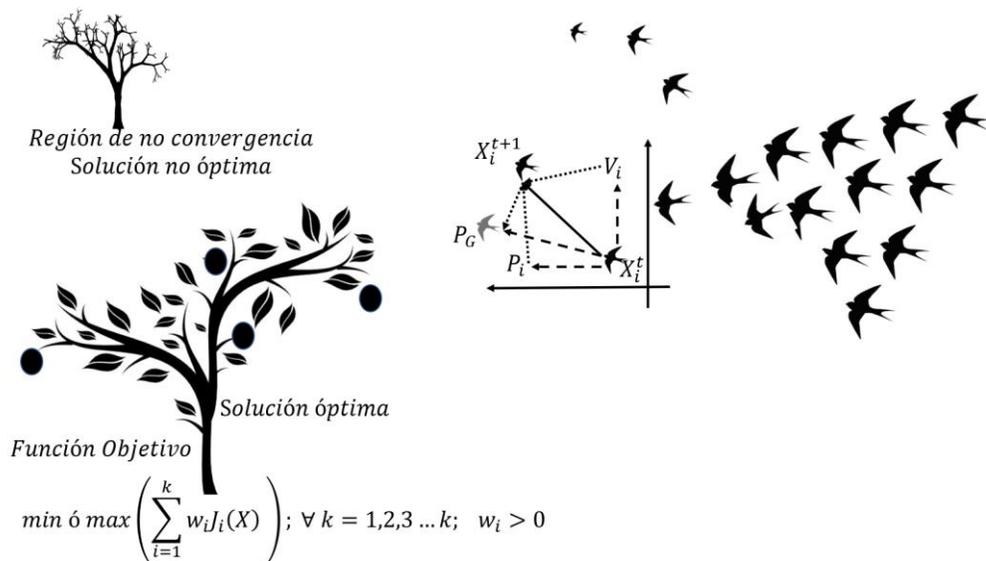


Figura 4. Esquema gráfico de un algoritmo PSO  
Fuente: Elaboración propia

En el diseño de sistemas de diagnóstico automático de procesos, los algoritmos bio-inspirados se han utilizado para optimizar el diagnóstico. En (Echeverría, *et al.*, 2011) se expone una propuesta para el diagnóstico de fallos en sistemas industriales mediante dos algoritmos bio-inspirados: evolución diferencial y optimización por colonia de hormigas, mediante la implementación de los algoritmos demuestran la robustez de la estrategia ante perturbaciones y rapidez en el diagnóstico. También se han utilizado algoritmos como el inspirado en el sistema inmune para la detección de errores en el diagnóstico de fallas utilizando células NK (*Natural Killer Immune Cell*) como estructuras de detección temprana de errores (Laurentys, *et al.*, 2011). Una propuesta de diagnóstico inverso de fallas se muestra en (Echevarría, *et al.*, 2014), implementando una optimización por medio del algoritmo de colonia de hormigas. Finalmente, en (Dalian, *et al.*, 2015) se presenta una optimización basada en el algoritmo de colonia de abejas que permite encontrar los mejores parámetros de una máquina de soporte vectorial implementada para el diagnóstico de fallas.

### **1.3.5 Estrategias combinadas**

Se trata de estrategias que utilizan más de una técnica de la inteligencia artificial en el diseño del diagnóstico automático de procesos. La combinación de estrategias permite darle robustez al diagnóstico. En (Lemos, *et al.*, 2013) 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. La combinación de redes neuronales para la predicción y un clasificador difuso se implementan en (Hernández, *et al.*, 2014). La combinación demuestra resultados satisfactorios en la predicción de coagulante y el establecimiento de los estados funcionales en una planta de potabilización de agua. La lógica difusa para la detección de fallas y una RNA probabilística para el diagnóstico son utilizados en (Hernández, *et al.*, 2014) para la supervisión de una red eléctrica. La combinación permite generar un sistema robusto y seguro con la propiedad de detectar fallas simétricas y asimétricas. En (Demetgul, *et al.*, 2011) 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.

## **1.4 Resultados**

En la presente revisión bibliográfica se mostraron las generalidades y ventajas de trabajar con estrategias perteneciente a la inteligencia artificial para el diseño de sistemas de diagnóstico de procesos. Se presentaron las redes neuronales, lógica difusa, estrategias bio-inspiradas y combinadas, con sus principales aportes y resultados.

La importancia de implementar estrategias de la inteligencia artificial para el diseño de sistemas de diagnóstico se evidencia en la cantidad de publicaciones en conferencias y artículos de investigación presentados en revistas especializadas. En la Figura 5. se puede observar el porcentaje de publicaciones de acuerdo con el tipo de documento. En los diez años consultados

se observa que el mayor número de publicaciones corresponde a artículos presentados en conferencias con un 62.25%, seguido de artículos científicos con un 31.56%. Los trabajos de revisión solo suman el 2,79% de las publicaciones sobre el diagnóstico de procesos mediante la implementación de estrategias de la inteligencia artificial. El gráfico fue consultado en la base de datos Scopus y se obtuvo como resultado un total de 1147 trabajos.

La Figura 6, muestra el número de publicaciones de los últimos diez años consultados. La gráfica se obtuvo como resultado de utilizar en la búsqueda la siguiente sintaxis: “diagnóstico de procesos e inteligencia artificial”. Se observa que en los años 2014 a 2015 se generó la mayor cantidad de publicaciones, mientras que en los años 2010 a 2013 las publicaciones no superaron los 100 trabajos. Entre los años 2007 a 2009 se evidencia un estudio favorable del diagnóstico inteligente, en especial en el año 2008. El año 2016 fue el periodo con más publicaciones, disminuyendo en el 2017 a 40 trabajos, sin embargo, la cantidad supera positivamente las 100 publicaciones.

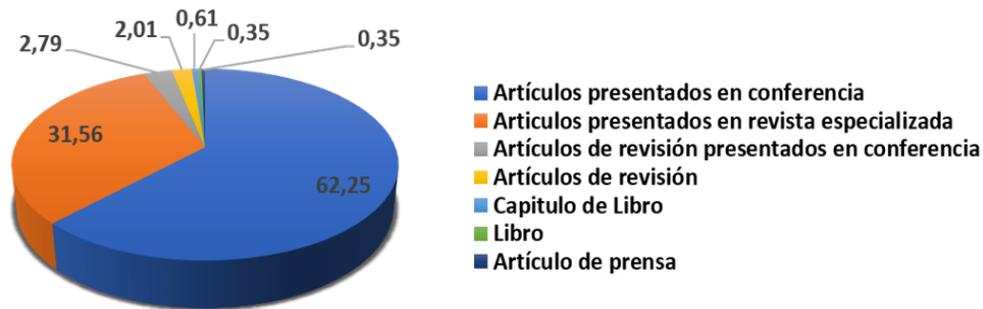


Figura 5. Porcentaje de publicaciones (2007-2017) sobre el diagnóstico de procesos mediante técnicas de la inteligencia artificial.  
Fuente: Scopus

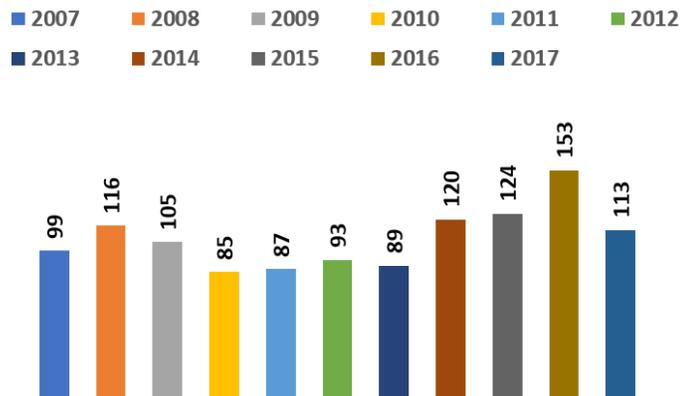


Figura 6. Número de publicaciones (2007-2017) sobre el diagnóstico de procesos mediante técnicas de la inteligencia artificial.  
Fuente: Scopus

## 1.5 Comparación de técnicas de IA para el diagnóstico de procesos industriales

La tabla 1 muestra un cuadro comparativo donde se exponen los trabajos e investigaciones utilizados en la revisión bibliográfica; y en los cuales se utilizaron estrategias de IA para el diagnóstico de fallas en procesos industriales. La recopilación mostrada a continuación muestra el objetivo de cada investigación reportada, así como el sistema sobre el cual se implementó la estrategia y hallazgos importantes en los resultados.

Tabla 1. Comparación de técnicas de IA para el diagnóstico de procesos industriales.

Referencia	Objetivo	Sistema o Modelo	Hallazgos importantes
(Zarkovic & Stojkovic, 2017)	Presentar una metodología basada en la inteligencia artificial para la detección y clasificación de fallas.	Trasformador de potencia	La propuesta se presenta como un soporte para la toma de decisiones en el CBM
(Sarmiento, et al., 2103)	Estimar los estados funcionales de un proceso complejo.	Conductor eléctrico. Caldera.	La estrategia presenta buen desempeño en sistemas con dinámica lenta ante perturbaciones.
(Ramírez, 2016)	Establecer los estados funcionales de un sistema de producción de aire medicinal.	Sistema de producción de aire medicinal.	La estrategia permite programar acciones de mantenimiento antes de la ocurrencia de la falla.
(Otero, et al., 2011)	Implementar un clasificador difuso para el monitoreo de rodamientos	Motor de inducción.	Robustez de la lógica difusa para clasificar patrones de espectro de frecuencia.
(Escalona, 2013)	Obtener un modelo difuso para establecer el periodo de mantenimiento en líneas de aires de distribución.	Líneas aéreas de distribución	Robustez de la lógica difusa para el manejo de información imprecisa y con incertidumbre.
(Felecia, 2014)	Diseñar una estrategia para la programación de mantenimiento bajo confiabilidad y lógica difusa.	Empresa de fabricación de hilos	La estrategia permite elegir qué tipo de acción de mantenimiento requieren los mecanismos de la empresa.
(Hernández, et al., 2015)	Diseñar un sistema de detección y diagnóstico de fallas	Caldera acuaturbular	La estrategia puede ser expandida para cualquier sistema debido a que es una metodología ajustable.
(Cadena, et al., 2008)	Implementar una RNA probabilística para la detección de fallas incipientes en transformadores	Transformador eléctrico	Diagnóstico aproximado de lo que sucede al interior del transformador.
(Flores, et al., 2016)	Implementar una RNA multicapa modular para el diagnóstico de fallas en línea de transmisión	Líneas de transmisión eléctricas	Estructura RNA modular que permite hacer un diagnóstico de fallas por elemento, zona o por todo el contexto eléctrico.
(Delgado, et al., 2013)	Detectar fallas de rodamientos por medio de un esquema de monitoreo basado en condición implementando funciones de tiempo estadísticas y redes neuronales.	Motor de inducción con freno controlado	La estrategia permite detectar fallas locales y fallas distribuidas.

(Shatnawi & khassaweneh, 2014).	Diagnosticar las fallas en motores de combustión interna usando una red neuronal extendida.	Motor de combustión interna	de	Estrategia adaptativa a partir de la adición de nuevos nodos en la red sin alterar la red previamente construida.
(Cai, et al., 2014)	Diagnosticar las fallas de una bomba de calor mediante la fusión de información de múltiples fuentes y una RNA Bayesiana.	Bomba de calor		La implementación permite la fusión de información de múltiples fuentes permitiendo la corrección de diagnósticos incorrectos.
(Jafari, et al., 2014).	Diagnosticar las fallas en las válvulas de un motor de combustión Interna usando emisión acústica y una RNA.	Motor de combustión interna	de	La estrategia permite encontrar en la falla, el daño y su ubicación.
(Echeverría, et al., 2011)	Proponer una estrategia para el diagnóstico de fallos en sistemas industriales mediante el uso de estrategias bio-inspiradas.	Sistema de dos tanques de nivel		Diagnóstico rápido en cuanto a la detección de fallas y robusto ante perturbaciones
(Laurentys, et al., 2011)	Presentar una estrategia novedosa para la detección del comportamiento de fallas mediante un algoritmo artificial inmune.	Actuador Industrial		Mejoras considerables de la compensación entre la tasa de detección y la tasa de fallas.
(Echevarría, et al., 2014),	Formular una metodología para el diagnóstico inverso de fallas implementando el algoritmo de optimización por colonia de hormigas.	Péndulo Invertido		Diagnóstico inverso de fallas. Diagnóstico robusto y sensible con tiempo de procesamiento adecuado.
(Dalian, et al., 2015)	Diagnosticar las fallas en una caja de cambio mediante la optimización de una máquina de soporte vectorial con el algoritmo por colonia de abejas.	Caja engranajes	de	Menor costo computacional y mejor precisión frente a los algoritmos genéticos,
(Lemos, et al., 2013).	Presentar un enfoque para la detección y el diagnóstico adaptativo de fallas.	Actuador industrial		Diagnóstico adaptativo
(Hernández, et al., 2014)	Diagnosticar las fallas en una planta de tratamiento de agua mediante la metodología LAMBDA.	Planta de tratamiento de agua	de	Modelación no lineal y predicción mediante RNA. La combinación de estrategias puede llevar a mejorar la calidad del proceso.
(Hernández, et al., 2014)	Presentar una metodología para la supervisión de una red eléctrica implementado Lógica difusa y RNA	Red eléctrica		La combinación de la lógica difusa y la RNA produce un diagnóstico robusto y seguro permitiendo detectar fallas simétricas y asimétricas.
(Demetgul, et al., 2011)	Diagnosticar las fallas en una planta de embotellamiento usando una RNA genética.	Planta de embotellamiento	de	Es posible implementar con cambios menores la estrategia para cualquier sistema. La combinación del algoritmo genético con la RNA permitió configurar la mejor estructura neuronal.

## 1.6 Conclusiones

En este capítulo se presentó una revisión sobre el diagnóstico inteligente de fallas en procesos industriales mediante IA. En la revisión se pudo encontrar que la implementación de estrategias

como las redes neuronales, lógica difusa, algoritmos bio-inspirados y estrategias combinadas; para el diagnóstico de procesos, se presentan como una alternativa que brinda robustez, adaptabilidad y seguridad en la detección de fallas.

La importancia de la implementación de estrategias de IA para el diseño de sistemas de diagnóstico de procesos se evidencia en la extensa cantidad de trabajos e investigaciones presentados en conferencias y revistas especializadas. Además, los sistemas de diagnóstico inteligente basados en información histórica de los procesos industriales presentan la ventaja que pueden ser diseñados fuera de línea, sin alterar el nivel de producción.

Dentro de las implementaciones encontradas en la revisión se evidencia que la clasificación de patrones mediante estrategias como el agrupamiento difuso o la clasificación mediante redes neuronales, son claves para el establecimiento de estados funcionales definidos por el operador experto del proceso. Lo anterior indica que es indispensable la participación del experto humano dentro del diseño, implementación y mantenimiento del diagnóstico inteligente.

En la revisión bibliográfica se encontró que las redes neuronales y la lógica difusa son implementadas para establecer estados funcionales, modelación no lineal, y predicción para la posterior programación del mantenimiento dentro del esquema diagnóstico. Con las estrategias combinadas se evidenció la capacidad de dotar de adaptabilidad al diagnóstico. Finalmente, los resultados obtenidos con el uso de algoritmos bio-inspirados, indicaron optimización del diagnóstico inteligente, minimizando errores en la detección de fallas del proceso.

## **1.7 Referencias bibliográficas**

Aguilar-Martín, J. (2007). *Inteligencia Artificial para la Supervisión de Procesos Industriales*. Mérida, Venezuela: ULA, 1a edición.

Abid, A., Khan, M., Khan, M., S. (2017). Multidomain Features-Based GA Optimized Artificial Immune System for Bearing Fault Detection. *IEEE Transactions on Systems, Man, And Cybernetics: Systems*.

Bayar, N., Darmoul, S., Hajri-Gabouj, S., Pierreval, H. (2015). Fault detection, diagnosis and recovery using Artificial Immune Systems: A review. *Engineering Applications of Artificial Intelligence*, 46, pp. 43–57.

Bhargava, C., Banga, V., Singh, Y. (2014). Failure Prediction and Health Prognostics of Electronic Components: A Review. *Engineering and Computational Sciences (RAECS)*, UIET Panjab University Chandigarh, India.

Biçen, Y., Aras F. (september, 2014). Intelligent Condition Monitoring Platform Combined with Multi-Agent Approach for Complex Systems. *IEEE Environmental Energy and Structural Monitoring Systems (EESMS)*. Naples, Italy.

Cadena, J., Cadena, J., Pérez, S. (2008). Aplicación de redes neuronales probabilísticas en la detección de fallas incipientes en transformadores. *Scientia et Technica*, 39, pp. 48-53.

Cai, B., Liu, Y., Fan, Q., Zhang, Y., Liu, Z., Yu, S., Ji, R. (2014). Multi-source information fusion-based fault diagnosis of ground-source heat pump using Bayesian network. *Applied Energy* 114, pp. 1–9.

Dalian, Y., Yilun, L., Songbai, L., Xuejun, L., Liyong, M. (2015). Gear fault diagnosis based on support vector machine optimizad by artificial bee colony algorithm. *Mechanism and Machine Theory* 90, pp. 219–229.

Delgado, M., Cirrincione, G., Garcia, A., Ortega, J., Henao, H. (2013). Bearing Fault Detection by a Novel Condition-Monitoring Scheme Based on Statistical-Time Features and Neural Networks. *IEEE Transactions on Industrial Electronics*, 30 (8), pp. 3398-3407.

Demetgul, M., Unal, M., Tansel, I.N., Yazıcıođlu, O. (2011). Fault diagnosis on bottle filling plant using genetic-based neural network. *Advances in Engineering Software* 42, pp. 1051–1058.

Echevarría, L., De Campos, H., Becceneri, J., Da Silva, J., Llanes, O. (2014). The fault diagnosis inverse problem with Ant Colony Optimization and Ant Colony Optimization with dispersión. *Applied Mathematics and Computation* 227, pp. 687–700.

Escalona, L. W., Jiménez, C. J., Ferrera, A. J., Arteaga, F. J. (2013). Diseño de sistema para la detección de fallas en planta compresora con mantenimiento centrado en confiabilidad usando lógica difusa. *Ingeniería UC*, 10 (1), pp. 1-9.

Felecia., (2014). Fuzzy Logic Reliability Centered Maintenance. *Jurnal Teknik Industri/JTI*, 16 (2), pp. 121-126.

Flores, A., Quiles, E., García E., Morant, F. (2016). Fault Diagnosis of Electric Transmission Lines Using Modular Neural Networks. *IEEE Latin America Transactions*. 14(8), pp. 3663-3668.

Flórez, E., Díaz, N., Gómez, W., Bautista, L., Delgado, D. (2018). Evaluación de algoritmos bioinspirados para la solución del problema de planificación de trabajos. *I+D Revista de Investigaciones*, 11(1) pp. 142-155.

Gómez, Julieth., Simancas, J., Acosta, M., Meléndez, F., Vélez, J. Algoritmo de reconocimiento de comandos de voz basado en técnicas no-lineales. *Revista Espacios*. Vol. 38, Año 2017, Número 17, Pág. 4.

Hernández, C., Nieto, J., Carrum, E. (2014). Detección y diagnóstico de fallas en sistemas eléctricos de potencia (SEP) combinando lógica difusa, métricas y una red neuronal probabilística. *Research in Computing Science*, 72, pp. 47–59.

Hernández, M., Sandoval, A., Valencia, F. (2015). Sistema difuso para la detección y diagnóstico de falla en la generación a vapor. *Scientia et Technica*, 20(1), pp. 4-9.

Hernández, H., Camas J., Medina, A., Pérez, M., Le Lann, M. (2014). Fault Diagnosis by LAMDA Methodology Applied to Drinking Water Plant. *IEEE Latin America Transactions*, 12 (6), pp. 985-990.

Hurtado L., Villarreal E., Villarreal L. (2016). Detección y diagnóstico de fallas mediante técnicas de inteligencia artificial, un estado del arte. *DYNA* 83 (199), pp. 19-28.

Jafari, S., Mehdigholi, H., Behzad, M. (2014). Valve Fault Diagnosis in Internal Combustion Engines Using Acoustic Emission and Artificial Neural Network. Hindawi Publishing Corporation, *Shock and Vibration*, 2014, pp. 1-9.

Jantzen, J. (2007). *Foundation of fuzzy control*, Chichester. England: John Wiley & Sons Ltd.

Khalyasmaa, S., Eroshenko, A. (2017). The Analysis of Efficiency of Artificial Intelligence Methods Application for an Assessment of Feasibility of Scientific and Technical Decisions. *Soft Computing and Measurements (SCM), 2017 XX IEEE International Conference on*. St. Petersburg, Russia.

Kose, U., Vasant, P. (2017). Fading Intelligence Theory: A Theory on Keeping Artificial Intelligence Safety for the Future. *Artificial Intelligence and Data Processing Symposium (IDAP), 2017 International*, Malatya, Turkey.

Laurentys, C., Palhares, R., Caminhas, W. (2011). A novel Artificial Immune System for fault behavior detection. *Expert Systems with Applications* 38, pp. 6957–6966.

Lei, Y., Jia, F., Lin, J., Xing, S., Ding, S. (2016). An Intelligent Fault Diagnosis Method Using Unsupervised Feature Learning Towards Mechanical Big Data. *IEEE Transactions on Industrial Electronics*, 63 (5), pp. 3137-3147.

Lemos, A., Caminhas, W., Gomide, F. (2013). Adaptive fault detection and diagnosis using an evolving fuzzy classifier. *Information Sciences*, 220, 64–85.

Lídice, C., Orestes, Santiago., Antonio J. Silva, N. (2011). A proposal to fault diagnosis in industrial systems using bio-inspired strategies. *Ingeniare*, 19 (2), pp. 240-252.

Mora, A. (2016). *Mantenimiento industrial efectivo*. Medellín, Colombia: COLDI LTDA.

Nasiri, S., Khosravani, M., Weinberg, K. (2017). Fracture mechanics and mechanical fault detection by artificial intelligence methods: A review. *Engineering Failure Analysis*, 81, pp. 270–293.

Otero, F., Pardo, J., Quiroga, J. (2011). Clasificador difuso de señales de vibración para el monitoreo de rodamientos. *Revista de Ingeniería*. Universidad de los Andes. 35, pp. 20-26.

- Pandian, A., Ali, A. (2009). A Review of Recent Trends in Machine Diagnosis and Prognosis Algorithms. World Congress on Nature & Biologically Inspired Computing (NaBIC 2009). Coimbatore, India.
- Ramírez J, A. (2016). Diagnóstico Inteligente de las Variables para el Control de Calidad de la Producción de Aire Medicinal del Hospital Manuel Uribe Ángel. Monografía para obtener título de Especialista en Gerencia de Mantenimiento, Universidad de Antioquia, Medellín, Colombia.
- Ramírez, J., Sarmiento, H., López J. (2017). Diseño de un Clasificador Difuso para el Establecimiento de los Estados Funcionales de un Sistema de Producción de Aire Medicinal. *Revista Información Tecnológica*, 28(6), pp. 147-160.
- Reyes, Y., Claro, A., Martínez, N., Hernández, A. (2016). Agrupamiento conceptual lógico combinatorio: una alternativa para la toma de decisiones. *Inteligencia Artificial* 19(57), pp. 82-96.
- Ruz, J., Sánchez, E., Suárez, D. (2008). Algoritmo de Entrenamiento Optimo para Diseñar una Memoria Asociativa de Diagnostico de Fallas. *Revista Iberoamericana de Automática e Informática Industrial*, 5 (1), pp. 115-123.
- Santa Cruz R., Correa, C. (2017). Intermittent demand forecasting with time series methods and artificial neural networks: A case study. *Revista DYNA*, 84(203), pp. 9-16.
- Santos, M. (2011). Aplicaciones Exitosas de Control Inteligente a Casos Reales. *Revista Iberoamericana de Automática e Informática industrial*, 00, pp. 1–8.
- Sarmiento, H. (2013). Metodología para el establecimiento y ponderación automática de conexiones entre estados funcionales de un proceso como herramienta para el diagnóstico y la predicción de fallos. (Tesis de Doctorado), Departamento de Ingeniería, Universidad de Antioquia, Medellín, Colombia.
- Sarmiento, H., Isaza, C., Kempowsky, T. (2013). Estimación de estados funcionales en procesos complejos con base en agrupamiento difuso. *Información Tecnológica*, 2(24), pp. 79-98.
- Shatnawi, Y., Al-khassaweneh, M. (2014). Fault diagnosis in internal combustion engines using extension neural network. *IEEE Transactions on Industrial*, 61 (3), pp. 1434-1443.
- Soualhi, A., Clerc, G., Razik, H. (2013). Detection and Diagnosis of Faults in Induction Motor Using an Improved Artificial Ant Clustering Technique. *IEEE Transactions on Industrial Electronics*, 60 (9), pp. 4053-4062.
- Uraikul, V., Chan, C., Tontiwachwuthikul, P. (2007). Artificial intelligence for monitoring and supervisory control of process Systems. *Engineering Applications of Artificial Intelligence* 20, pp. 115–131.

Vasičkaninová, A., Bakošová, M., Kmeťová, J. (mayo, 2014). Fuzzy Control of a Heat Exchanger Using Fuzzy C-Means Clustering Algorithm. 41st International Conference of Ssche, Tatranské Matliare, Slovakia

Worden, K., Staszewski, W., Hensman, J. (2011). Natural computing for mechanical systems research: A tutorial overview. *Mech. Syst. Signal Process.*, 25 (1), pp. 4-111.

Xuewu, D., Zhiwei, G. (2013). From model, signal to knowledge: a data driven perspective of fault detection and diagnosis. *IEEE Transactions on Industrial Informatics*, 9 (4). pp. 2226-2238.

Zarkovic, M., Stojkovic, Z. (2017). Analysis of artificial intelligence expert systems for power transformer condition monitoring and diagnostics. *Electric Power Systems Research*, 149, pp. 125–136.

## **2. Descripción de los procesos de prueba**

### **Resumen**

En este capítulo se describen los procesos de prueba sobre los cuales se implementó el diagnóstico basado en IA. Uno de los procesos está conformado por una planta, en la cual se regula la presión en un tanque de almacenamiento mediante una estructura de control realimentado. El otro proceso comprende un sistema de producción de aire medicinal. Para ambos procesos se describen sus componentes, así como la respuesta gráfica de las variables que intervienen en cada uno de ellos. El conocimiento del proceso por parte del experto es fundamental durante el diseño del diagnóstico inteligente, en especial en la descripción cualitativa de estados funcionales.

### **2.1 Introducción**

Una contribución significativa para planear acciones de mantenimiento está relacionada con el conocimiento de los componentes que conforman los procesos. Cualquier información obtenida de fichas técnicas, pruebas experimentales o de procesos con dinámicas similares, es importante para adquirir experticia por parte del operador. El desconocimiento de la estructura del proceso genera consecuencias negativas que involucran una programación ineficiente de las acciones de mantenimiento. Las condiciones de operación, regiones de saturación, periodos de adquisición de datos, entre otros, brindan información, la cual es utilizada por el operador del proceso para adquirir experiencia. No obstante, la misma estructura de los procesos, establecida por la conexión de diversos instrumentos, hace que los procesos sean complejos (González-Miranda, *et al.*, 2014); con dinámicas no lineales y ocultas en transiciones de estados funcionales difícilmente observables por el operador. Por lo tanto, debe existir una fusión entre el experto del proceso y el mecanismo de la IA que permita detectar patrones extraños en la dinámica de los sistemas para la posterior intervención con acciones preventivas.

Por otro lado, la competitividad del sector productivo, ocasionada por la globalización, ha desencadenado altos niveles de producción donde se aprovechan al máximo los recursos, minimizando costos y manteniendo a su vez un alto nivel de seguridad (Arbildo, 2011). Lo anterior ha obligado a la articulación de sistemas de diagnóstico inteligente con los sistemas de control automático, creando una combinación que permite la detección temprana de fallas a la vez que se cumplen los objetivos impuestos por el diseñador del controlador (Ramírez, 2016).

Independientemente de la estrategia de control y del sistema de diagnóstico a implementar, se requiere del conocimiento del proceso; conocimiento que es aportado por el operador y que dota al sistema de diagnóstico con características cualitativas, reflejadas en estados funcionales resultantes de la implementación de esquemas de clasificación de patrones. Es así como el éxito de los sistemas de diagnóstico inteligente de procesos se debe en gran medida al aporte de la experticia del operador.

En este capítulo se describen los dos procesos de prueba utilizados para la implementación del diagnóstico inteligente basado en predicción con RNAs y clasificación difusa. El capítulo se divide en tres secciones. En la primera sección se describe un proceso conformado por una planta en la cual se regula la presión de aire en un tanque de almacenamiento. En la segunda sección se describe un proceso de producción de aire medicinal. Finalmente, en la última sección se presentan las principales conclusiones derivadas del capítulo.

## 2.2 Planta de Presión

El primer proceso de prueba corresponde a una planta de presión construida en el Politécnico Colombiano Jaime Isaza Cadavid y documentada en (Ramírez & Sarmiento, 2014). 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* (Ramírez, et al., 2014), (Ramírez, 2017). 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 Figura 7).

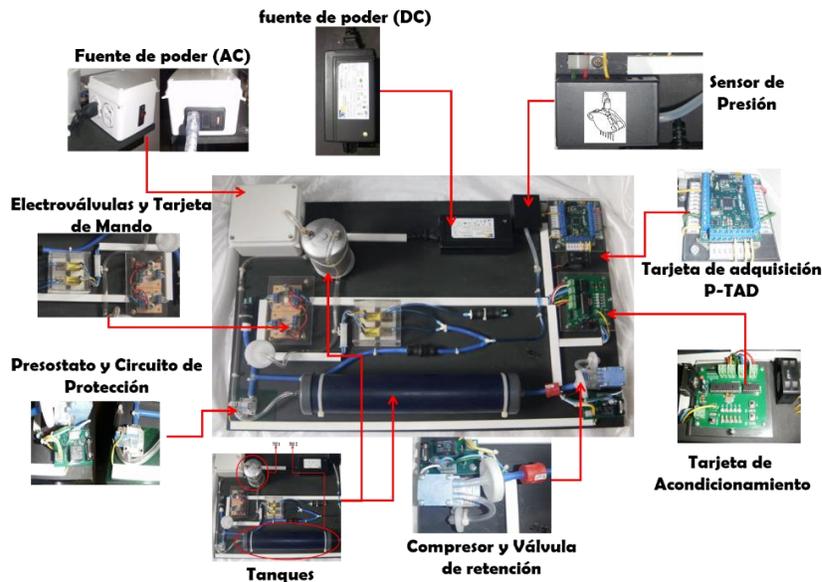


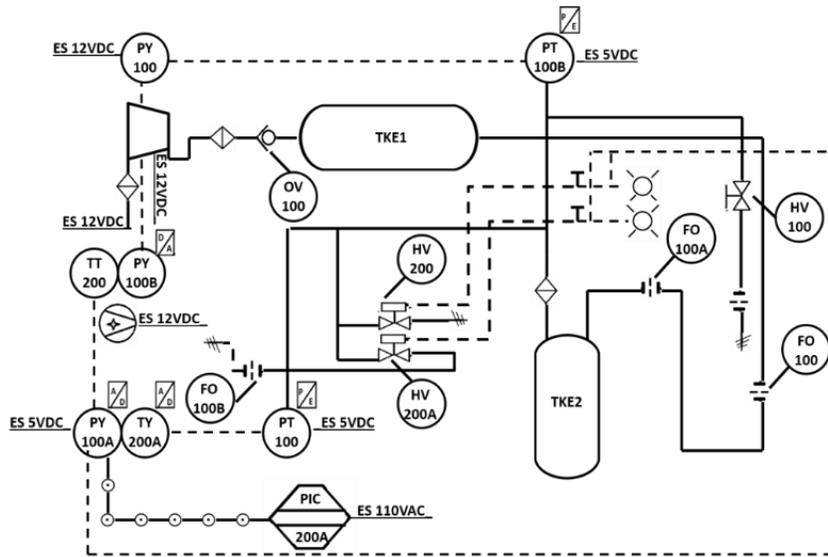
Figura 7. Planta didáctica para la implementación de algoritmos de control, métodos de supervisión y técnicas de agrupamiento.

Fuente: Elaboración propia

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, modificando los coeficientes del controlador como acción preventiva, o activando una alarma antes de la transición hacia una falla inminente.

### 2.2.1 Descripción de la planta de presión

La Figura 8 muestra el diagrama de proceso de la planta de presión. La operación de la planta se describe a continuación. Un compresor recibe una señal PWM (*Pulse Width Modulation*) previamente acondicionada por un circuito de conversión. El circuito convierte la señal análoga proveniente del controlador en una señal equivalente PWM, permitiendo modificar la velocidad del motor del compresor; y, por lo tanto, el caudal de aire enviado a los tanques. En la salida del compresor se encuentra una válvula unidireccional que evita el retorno del aire. Un tanque (TKE1) instalado de forma horizontal sirve como sistema de distribución. La salida del TKE1 cuenta con un sistema de filtrado y restricciones de paso. Cuando la presión en el TKE1 ha superado las restricciones de paso, el aire se distribuye hacia un tanque de almacenamiento (TKE2). La presión en el TKE2 es medida por un sensor de presión con salida lineal. Una salida continua de aire permite mantener la presión en el TKE2 de acuerdo al punto de operación deseado durante la sintonización de estrategias de control. Para registrar información, el sistema cuenta con una tarjeta de adquisición compatible con el software LabVIEW™.



Planta Didáctica para la implementación de algoritmos de control, métodos de supervisión y Técnicas de Agrupamiento.	
Fecha	31/1/2018
Responsable	Jhon Alexander Ramírez

Figura 8. Diagrama de proceso de la planta didáctica para la implementación de algoritmos de control, métodos de supervisión y técnicas de agrupamiento.

Fuente: Elaboración propia

La planta de presión dispone de una electroválvula (HV200) que permite purgar los tanques y llevar el sistema a condiciones iniciales iguales a cero. Otra electroválvula (HV200A) se encuentra disponible en la planta para generar perturbaciones. Además, se dispone de una válvula de cierre manual (HV100) capaz de ocasionar obstrucción completa en las líneas de distribución. Como sistema de protección, la planta cuenta con un sensor lógico de presión, previamente calibrado para evitar sobrepresiones en el sistema.

Un *driver* permite acoplar el sistema lógico de baja tensión con el compresor. Para efectos de monitoreo, la planta, cuenta con un sensor de temperatura instalado sobre la superficie del *driver* para registrar su temperatura. En caso de temperaturas elevadas, se puede activar un ventilador para refrigerar el *driver* mientras se verifica la posible falla sobre la planta.

De la planta y con la ayuda de una aplicación en LabVIEW™ se pueden adquirir y almacenar las siguientes variables:

- Referencia (Set Point)
- Estado del sensor lógico (0 o 5) v
- Presión en el tanque de almacenamiento
- Temperatura en el *driver*
- Error de seguimiento
- Ley de control

Adicionalmente, es posible registrar y almacenar otras variables con modificaciones menores en la aplicación en LabVIEW™. Por ejemplo, se puede guardar el comportamiento en el tiempo de variables como: cambio en la salida, cambio en el error y cambio en la ley de control. La necesidad de incluir más variables se definirá por el experto del proceso durante el diseño del clasificador; y por el análisis multivariable de las señales y las clases obtenidas.

### **2.2.2 Modelo matemático de la planta de presión**

La sintonización de controladores convencionales y avanzados requiere de un modelo matemático de la dinámica de la planta sobre la cual se implementarán los algoritmos de control. La mayoría de las estrategias de control convencional PID están fundamentadas en modelos matemáticos aproximados a sistemas tipo POR (2), (Ogata, 2010) (Johson, et al., 2006) (Garcia, 2012) (Aström, et al., 2003).

$$G(s) = \frac{ke^{-\theta s}}{\tau s + 1} \quad (2)$$

Donde:

$k$ : Ganancia de la planta

$\tau$ : Constante de tiempo

$\theta$ : Retardo o tiempo muerto

$s$ : Variable compleja

Para determinar zonas lineales y definir los puntos de operación de la planta de presión, se construyó una recta de linealidad. Para graficar la recta se aplicaron estímulos de tipo escalón sobre la planta con el controlador en lazo abierto. Para cada cambio en el escalón se almacenó el valor en estado estable de la salida; en este caso la presión en el TKE2. La Figura 9 muestra la curva de linealidad del proceso, en la gráfica se observan dos regiones de saturación, y dos zonas lineales para modelación. Aunque existe linealidad, es evidente que la dinámica completa de la planta es no lineal al requerir de modelos variantes en el tiempo para cada zona de operación. Las regiones de saturación permitieron definir la región de operación de la planta comprendida entre los cambios de tipo escalón del 15% al 45%, generando presiones en estado estable desde 0% hasta 65%.

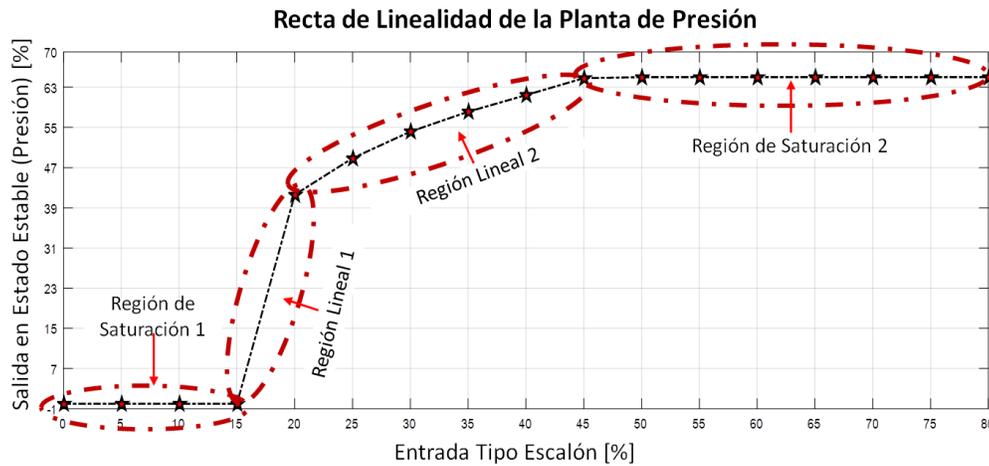


Figura 9. Recta de linealidad de la planta de presión  
Fuente: Elaboración propia

Los modelos en el tiempo continuo y discreto para las zonas lineales se muestran en (3) y (4). Para discretizar los modelos se utilizó el criterio de la constante de tiempo equivalente del modelo continuo con un período de muestreo  $T = 3s$  (Ogata, 1996), (García, 2012).

$$G(s) = \frac{2.0142e^{-0.3s}}{20.8574s + 1} \xrightarrow[T = 3s]{z} HGp(z) = \frac{0.23727z + 0.033412}{z^2 - 0.86558z} \quad (3)$$

$$G(s) = \frac{0.62404e^{-0.3s}}{24.4762s + 1} \xrightarrow[T = 3s]{z} HGp(z) = \frac{0.67825z + 0.006725}{z^2 - 0.88054z} \quad (4)$$

### 2.2.3 Modo control de la planta de presión

Mediante un esquema de control digital como el mostrado en la Figura 10 y utilizando sintonización por Modelo Interno de la Planta (IMC) (Qiu, *et al.*, 2016), se implementaron los

controladores para cada zona modelada de la planta. La función de transferencia de cada controlador implementado es dada por (5) y (6).

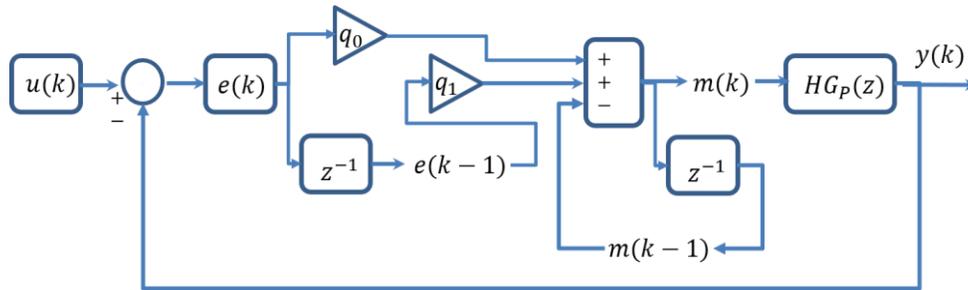


Figura 10. Sistema de control digital realimentado implementado en la planta de presión  
Fuente: Tomada de García, 2012

$$G_c(z) = \frac{M(z)}{E(z)} = \frac{0.4723z - 0.4424}{z - 1}; \quad \text{Región de operación } 15\% - 20\% \quad (5)$$

$$G_c(z) = \frac{M(z)}{E(z)} = \frac{1.47z - 1.39}{z - 1}; \quad \text{Región de operación } 25\% - 45\% \quad (6)$$

La implementación se llevó a cabo en el software LabVIEW™ mediante la ecuación en diferencias mostrada en 7.

$$m(k) = q_0 e(k) + q_1 e(k - 1) + p_1 m(k - 1) \quad (7)$$

Donde:

$m$  : Corresponde a la ley de control.

$e$  : Corresponde al error de control.

Las Figuras 11,12 y 13 muestran la salida del sistema controlado. En cada gráfica se puede observar el comportamiento en el tiempo de la ley de control, salida controlada y *Set Point*. De acuerdo a las respuestas gráficas obtenidas, se evidencia el seguimiento de la referencia deseada sin saturación del elemento final de control. De igual forma, se observa una dinámica variante entre el comportamiento de cada punto de operación, variaciones que se pueden percibir en el tiempo de establecimiento, sobreimpulso y comportamiento de la energía suministrada al compresor en cada controlador implementado.



Figura 11. Respuesta gráfica de la implementación de controlador sobre la planta de presión (punto de operación 25%)  
Fuente: Elaboración propia



Figura 12. Respuesta gráfica de la implementación de controlador sobre la planta de presión (punto de operación 45%)  
Fuente: Elaboración propia



Figura 13. Respuesta gráfica de la implementación de controlador sobre la planta de presión (punto de operación 55%)  
Fuente: Elaboración propia

En la Figura 14 se ilustra de forma detallada la respuesta de la planta ante diferentes dinámicas, como: cambio en el punto de operación, presencia de perturbaciones, temperatura elevada en el driver de potencia del elemento final de control (EFC), fuga considerable en el sistema, saturación del EFC y comportamiento en el tiempo del error de seguimiento (*Set Point – Variable Controlada*). En la Figura 14 se puede observar la diversidad de dinámicas en el sistema, las cuales, sumadas a las variaciones de respuesta temporal de cada controlador implementado, indican que la planta de presión es un sistema complejo, caracterizado por no linealidades, y dinámicas variantes en el tiempo (Sarmiento, 2013).

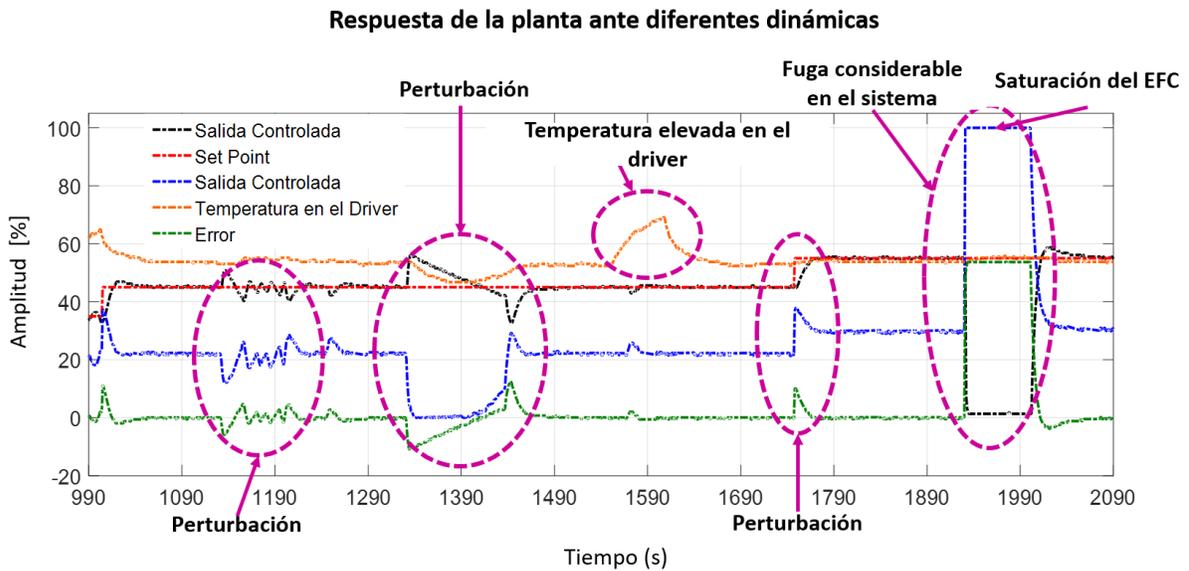


Figura 14. Respuesta gráfica de la planta de presión ante diferentes dinámicas  
Fuente: Elaboración propia

### 2.3 Sistema de Producción de Aire Medicinal

La producción de aire medicinal es el proceso mediante el cual el aire captado del ambiente es comprimido. La compresión del aire se produce mediante un sistema que modifica la presión y flujo a partir de los requerimientos de consumo. El sistema 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 a 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.

### 2.3.1 Descripción del sistema de producción de aire medicinal

El segundo proceso de prueba sobre el cual se implementará el diagnóstico mediante IA, es un sistema de producción de aire medicinal de una entidad hospitalaria. El sistema está compuesto por una serie de elementos encargados en conjunto de producir aire bajo normas y BPM. La función principal de este sistema es la generación de aire de forma uniforme y controlada de acuerdo con los estándares de calidad apropiados para el uso médico al que está dirigido. La Figura 15 muestra el diagrama de entradas/salidas y los subsistemas que participan en la producción de aire medicinal. El sistema cuenta con un compresor de dos cabezotes encargado de comprimir el aire captado del ambiente. El aire comprimido es almacenado en un tanque pulmón. La salida de aire del tanque pulmón es sometida a una etapa de enfriamiento para disminuir el calentamiento del aire ocasionado por efectos termodinámicos. Finalmente, el aire es direccionado a una etapa de triple filtrado y luego al sistema de monitoreo para registrar las VPCPAM en el instante  $k$  de la medición. Si el aire cumple con los estándares de calidad y de BPM, se entrega al paciente para su consumo por medio de la red de distribución; de lo contrario, el suministro es interrumpido para realizar el análisis del lote producido y efectuar las intervenciones de mantenimiento que permitan llevar el proceso a su estado normal de funcionamiento (Ramírez, *et al.*, 2017).

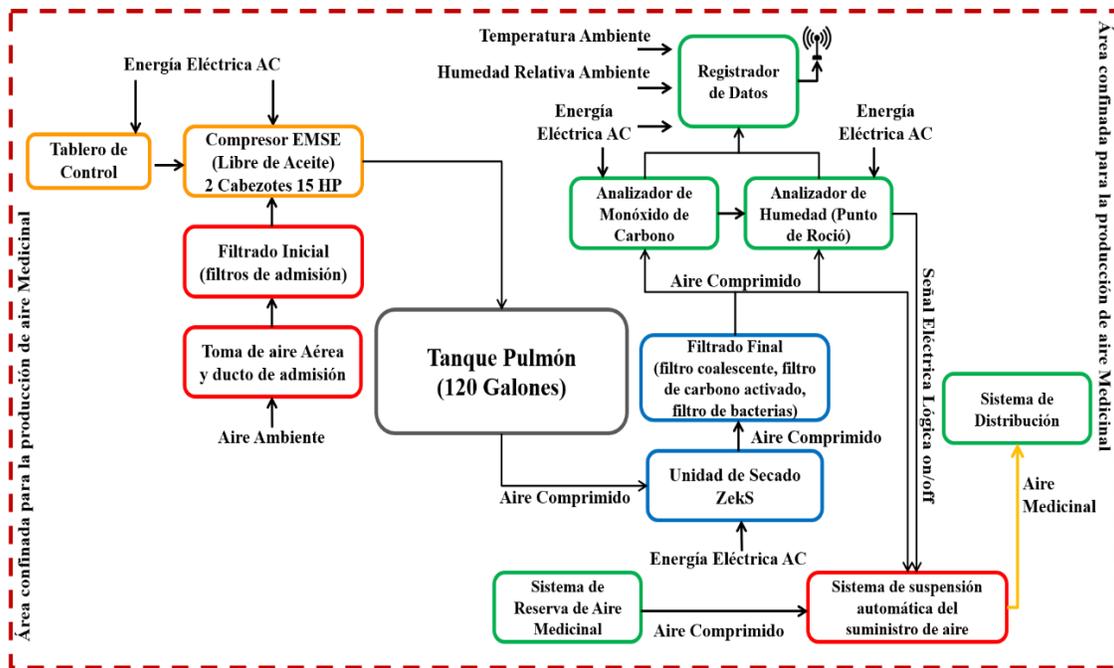


Figura 15. Diagrama de entradas/salidas y subsistemas del sistema de producción de aire medicinal  
Fuente: Elaboración propia

La definición de funciones de cada subsistema que en conjunto conforman los procesos, es una tarea que permite adquirir conocimiento y experticia al operador para la programación de acciones de mantenimiento, interpretación de información adquirida por sistemas de monitoreo e inclusive la selección de variables guiadas por el conocimiento adquirido del experto (Uribe, et al., 2012). A continuación, se describen las funciones de cada subsistema del sistema de producción de aire medicinal.

Tabla 2. Subsistema 1: Toma de aire aérea.

Nombre del subsistema	Funciones
Toma de Aire Aérea	Adquirir aire del ambiente mediante un tubo de admisión ubicado sobre el nivel del tejado a una distancia de 3,0 m. Impedir el ingreso de partículas de gran tamaño como insectos, pájaros o aguas lluvia.

Tabla 3. Subsistema 2: Filtrado Inicial.

Nombre del subsistema	Funciones
Filtrado Inicial	Impedir el paso de partículas que puedan ser succionadas del aire ambiente.

Tabla 4. Subsistema 3: Tablero de Control.

Nombre del subsistema	Funciones
Tablero de Control	Suministrar fluido eléctrico a los motores a un voltaje mínimo de 208 Vac y máximo 230 Vac a una corriente máxima de 41A y mínima de 38A. Establecer la secuencia de encendido/apagado de cada uno de los dos motores dependiendo del valor de la presión almacenada en el tanque pulmón (<70 psi, encendido) (>90 psi, apagado). Proteger los motores ante la presencia de sobre-picos de corriente o temperaturas elevadas. Indicar el tiempo de funcionamiento de los dos motores del compresor en horas y minutos. Drenar automáticamente mediante la activación de una válvula solenoide los condensados precipitados en el tanque pulmón.

Tabla 5. Subsistema 4: Compresor de Aire.

Nombre del subsistema	Funciones
Compresor de Aire	Generar el movimiento del pistón mediante el eje del motor a una velocidad nominal de 1760 RPM. Comprimir el volumen de aire que ingresa a la cámara de compresión mediante el desplazamiento positivo del pistón. Enviar el aire discontinuo y comprimido hacia el tanque pulmón hasta alcanzar una presión entre 70psi a 90psi y 57 SCFM. Reducir la temperatura mediante el paso del fluido de la cámara de compresión al tanque pulmón.

**Tabla 6. Subsistema 5: Tanque pulmón.**

<b>Nombre del subsistema</b>	<b>Funciones</b>
Tanque Pulmón	Almacenar aire para ocasiones de máxima demanda a una presión de 90 psi y a una capacidad de 120 gal.
	Descargar la presión almacenada en el tanque si supera los 200psi activando la válvula mecánica de alivio.
	Absorber las pulsaciones inherentes al sistema de compresión recíprocante mediante el paso del fluido de la cámara de compresión al tanque pulmón.

**Tabla 7. Subsistema 6: Unidad de secado.**

<b>Nombre del subsistema</b>	<b>Funciones</b>
Unidad de Secado	Refrigerar el aire comprimido hasta alcanzar una temperatura de 7°F de manera que el vapor de agua se condense y se precipite.

**Tabla 8. Subsistema 7: Filtrado final.**

<b>Nombre del subsistema</b>	<b>Funciones</b>
Filtrado Final	Impedir el paso de objetos que superen el tamaño del poro de 5um (micras) del filtro de partículas.
	Impedir el paso de partículas que superen el tamaño del poro de 0.01um del filtro coalescente.
	Impedir el paso de partículas sólidas, aerosoles, sabores, olores y vapores orgánicos mediante carbón activado.
	Impedir el paso de bacterias que superen un tamaño de 0.02um equivalente al tamaño del poro del filtro bacteriológico.

**Tabla 9. Subsistema 8: Sistema de monitoreo.**

<b>Nombre del subsistema</b>	<b>Funciones</b>
Sistema de Monitoreo	Registrar las partes por millón de la salida final del aire medicinal
	Registrar la temperatura de punto de rocío de la salida final del aire medicinal
	Registrar la temperatura ambiente y humedad relativa del área de producción de aire medicinal.
	Trasmitir inalámbricamente las variables partes por millón, temperatura de punto de rocío, temperatura ambiente y humedad relativa del sistema de producción de aire medicinal.
	Transmitir al módulo maestro las alarmas por desconexión de los monitores o alarmas por alteración de las variables partes por millón, temperatura de punto de rocío, temperatura ambiente y humedad relativa del sistema de producción de aire medicinal.
	Activar alarmas locales por alteración de las variables partes por millón, temperatura de punto de rocío, temperatura ambiente y humedad relativa del sistema de producción de aire medicinal.

Tabla 10. Subsistema 9: Sistema de reserva.

Nombre del subsistema	Funciones
Sistema de Reserva	Mantener la reserva de aire medicinal con una capacidad de 156.0 m3.
	Activar la reserva en casos de corte del suministro de aire medicinal por parte de compresor
	Activar la alarma en caso de corte de suministro de aire medicinal por parte del compresor.

Tabla 11. Subsistema 10: Sistema de suspensión automática del suministro de aire medicinal.

Nombre del subsistema	Funciones
Sistema de Suspensión Automática del Suministro de Aire Medicinal	Cortar el suministro de aire medicinal producido por el compresor y que no cumple especificaciones de calidad.
	Cortar el suministro de aire medicinal por parte del sistema de reserva cuando la producción de aire por parte del compresor cumple con las especificaciones de calidad. Impedir el retorno de aire medicinal del compresor hacia el sistema de reserva.

Tabla 12. Subsistema 11: Sistema de distribución de aire medicinal.

Nombre del subsistema	Funciones
Sistema de Distribución de Aire Medicinal	Transportar el aire comprimido por tubería de cobre de 1 pulgada desde el área de producción hasta los servicios donde se requiere para su consumo, a una presión de 60psi y conservando la calidad del aire. Permitir la interrupción del flujo de aire por tramos de tubería mediante el cierre de válvulas de paso.

## 2.4 Monitoreo de las VPCPAM

Obtener un modelo matemático del sistema de producción de aire medicinal es una tarea desafiante y costosa. En primer lugar, la cantidad de componentes que integran el sistema hace que la modelación sea compleja (Lara, 2007). La ausencia de sensores de flujo y presión imposibilitan el cálculo de constantes generadas durante las hipótesis y definición de relaciones *input/output* del sistema. Sumado a lo anterior, la necesidad de mantener la producción continua de aire para su consumo en pacientes críticos hace que la disponibilidad del aire sea del 100%, inhabilitando tiempos de paro del proceso para la ejecución de procedimientos experimentales que se requieran en el modelado. Sin embargo, entre los subsistemas que conforman el sistema de producción de aire medicinal, se encuentra el sistema de monitoreo encargado de registrar y almacenar el comportamiento dinámico de las VPCPAM, entregando el valor presente ( $k$ ) de la medición; y un histórico de información almacenado previamente en una matriz de datos donde cada fila está conformada por el vector dado por (8). El sistema de monitoreo permite visualizar el comportamiento en el tiempo de las VPCPAM y alertar al

operador en caso de desviaciones de las variables frente a los rangos especificados en las BPM del proceso.

$$x_{i(k)} = [PPMCO_{(k)} \quad TPR_{(k)} \quad HR_{(k)} \quad TA_{(k)}]; \quad k: \text{ instante de medición} \quad (8)$$

La Figura 16 muestra una gráfica detallada del comportamiento dinámico de las VPCPAM. Se tomó un tramo con diversos comportamientos del histórico de datos. En la gráfica se pueden observar incrementos y decrementos de las variables, así como el estado normal de funcionamiento (VPCPAM dentro de los rangos por las BPM). En la respuesta de cada variable se evidencian variaciones y transiciones dinámicas. Lo anterior sumado a la cantidad de componentes que conforman el sistema y a las variaciones ambientales del aire captado, hacen que el sistema de producción de aire medicinal sea considerado como un sistema complejo.

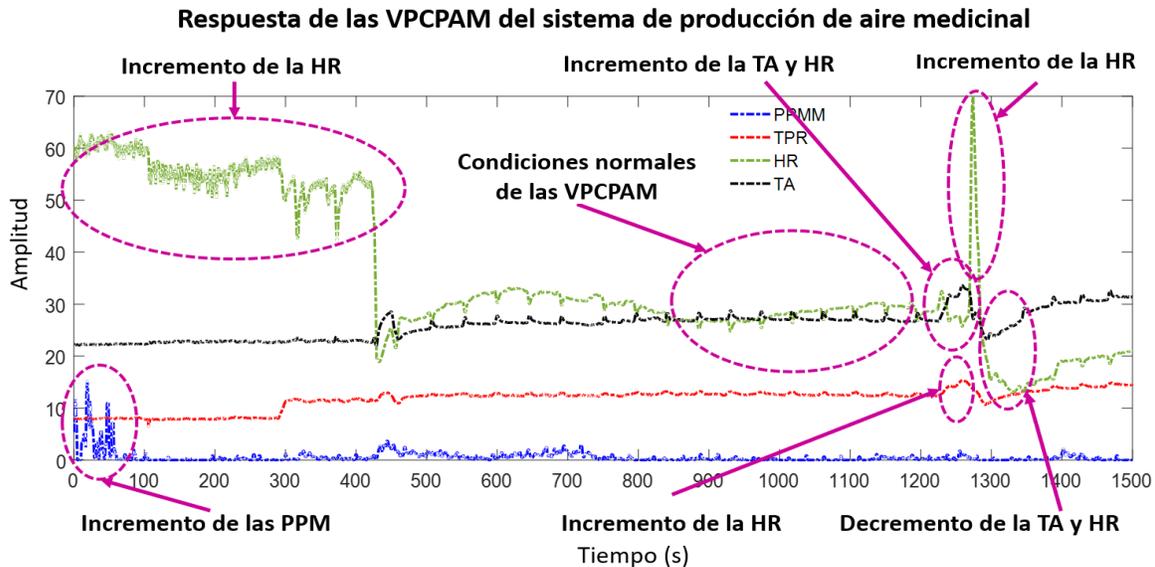


Figura 16. Respuesta gráfica de las VPCPAM del sistema de producción de aire medicinal  
Fuente: Elaboración propia

## 2.5 Conclusiones

Se describieron los dos sistemas de prueba que serán utilizados para implementar el diagnóstico inteligente propuesto. Se realizó una definición general de las funciones de los componentes de cada proceso. Desde la perspectiva de control se describió la planta de presión y se mostraron los resultados del sistema controlado, incluidas respuestas con perturbaciones. Se realizó una descripción del proceso de producción de aire medicinal desde la funcionalidad de cada subsistema que lo conforma, mostrando además una gráfica del comportamiento dinámico de las VPCPAM.

La descripción de los procesos industriales dota al operador de experticia para la interpretación de información y análisis de resultados. La participación del operador experto es fundamental

en el diseño de sistemas de diagnóstico, en especial en la definición cualitativa de estados funcionales durante el diseño de sistemas de diagnóstico inteligente de procesos.

En la descripción de cada proceso se demostró su complejidad asociada a la variación dinámica de las variables, no linealidades y situaciones de difícil manejo, como cambios en las condiciones ambientales. Ambos procesos fueron considerados como sistemas complejos para ser implementados en el diagnóstico basado en Inteligencia artificial.

## **2.6 Referencias bibliográficas**

Ogata, K. (2010). “Ingeniería de Control Moderna”. 5a Ed. Pearson Educación, S.A, Madrid.

Ogata, K. (1996). “Sistemas de Control en Tiempo Discreto”. 2a Ed. Prentice Hall Hispanoamericana, S.A.

Johnson, M., Moradi, A. (2005). “PID Control New Identification and Design Methods”. pringer-Verlag London Limited, London.

Aström, K.J., Häggglund, T. (2003). “Advanced PID Control”.

García, L. (2012). “Control Digital. Teoría y Práctica”, 3a ed, Politécnico Colombiano Jaime Isaza Cadavid, Colombia.

Arbildo, A., (2011). El control de procesos industriales y su influencia en el mantenimiento. Ingeniería Industrial, no. 29, pp. 35-49.

González-Miranda, O., Cerrada-Lozada, M., (2014). Diagnóstico de Sistemas de Eventos Discretos Controlados: Un Enfoque Basado en Crónicas y Análisis Modular Usando Modelos de Autómatas. Revista Iberoamericana de Automática e Informática industrial, no. 1, pp. 191–201.

Instituto Nacional de Vigilancia de Medicamentos y Alimentos-INVIMA, “Resolución No. 2011012580 del 25 de abril de 2011. Colombia 2011.

Lara, O. J. (2007). Nuevas metodologías no invasivas de diagnóstico de defectos incipientes en rodamientos de bola. PH.D. tesis, Universidad Carlos III de Madrid, Madrid, España.

Qiu, M., Santillo, J., Mrdjan J. (2016). Enhanced Composite Adaptive IMC for Boost Pressure Control of a Turbocharged Gasoline Engine Zeng American Control Conference (ACC) Boston Marriott Copley Place July 6-8, 2016. Boston, MA, USA. pp. 3286-3291.

Ramírez J., Posada N. (2014). Construcción de una Planta de Presión Didáctica y Portable para Implementación de Algoritmos de Control, Memorias, VIII Congreso de Ingeniera Mecánica, Cuenca-Ecuador, 1160-1165.

Ramírez J, A. (2016). Diagnóstico Inteligente de las Variables para el Control de Calidad de la Producción de Aire Medicinal del Hospital Manuel Uribe Ángel. Monografía para obtener título de Especialista en Gerencia de Mantenimiento, Universidad de Antioquia, Medellín, Colombia.

Ramírez, J., Posada, N. (2016). Aplicación de diseño, simulación, identificación de sistemas e implementación de controladores PID-DIGITROL. *Revista Politécnica*. 23, pp. 27-37.

Ramírez, J., Sarmiento, H., López J. (2017). Diseño de un Clasificador Difuso para el Establecimiento de los Estados Funcionales de un Sistema de Producción de Aire Medicinal. *Revista Información Tecnológica*, 28(6), pp. 147-160.

Ramírez, J., Sarmiento, H., López J. (2014). “Planta Didáctica Portable para la Implementación de Algoritmos de Control y de Técnicas para Monitoreo (Supervisión) de Procesos”. Fondo Editorial Politécnico.

Sarmiento, H. (2013). Metodología para el establecimiento y ponderación automática de conexiones entre estados funcionales de un proceso como herramienta para el diagnóstico y la predicción de fallos. (Tesis de Doctorado), Departamento de Ingeniería, Universidad de Antioquia, Medellín, Colombia.

Uribe, C., Isaza, C., (2012). Expert knowledge-guided feature selection for data-based industrial process monitoring. *Revista Facultad de Ingenierías Universidad de Antioquia*. 5, pp. 112-125.

### **3. Predicción de variables mediante estructuras MRNAs autorregresivas NAR/NARX**

#### **Resumen**

En este capítulo se presenta la predicción de variables mediante IA a partir de redes neuronales multicapa autorregresivas no lineales MRNAs-NAR/NARX. Para cada sistema de prueba se define la estructura neuronal de acuerdo al histórico de datos. Para el sistema de producción de aire medicinal se implementan estructuras MRNAs-NAR dado que solo se conoce el comportamiento de la variable a predecir. Para la planta de presión se proponen estructuras MRNAs-NARX, dado que se conoce además de la variable a predecir, la variable exógena que afecta su comportamiento. El registro de ambos sistemas se plantea como una serie de tiempo para obtener los modelos de predicción. Para entrenar las redes se utiliza información relevante de cada proceso de prueba, con estados que reflejan transiciones abruptas. Los modelos obtenidos en este capítulo serán utilizados como la etapa de predicción de los estados funcionales generados por el esquema de clasificación difusa, dentro del diagnóstico propuesto.

#### **3.1 Introducción**

Predecir el comportamiento dinámico de las variables en los procesos, es una tarea que ha tomado interés en diversas áreas de la ingeniería. 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 (Corrales, *et al.*, 2013).

Dentro de las arquitecturas de las RNAs, se encuentran las MRNAs, 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 (Ponce, 2017), (Sánchez, 2012) (Fernández, 2008), (Villada, *et al.*, 2012). 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.

Los modelos de predicción no lineal mediante MRNAs, se pueden obtener a partir del registro histórico periódico (serie de tiempo) de las variables. Uno de los modelos de predicción está basado en el registro histórico de la variable a predecir sin necesidad de conocer la variable de entrada que afecta la serie. Este modelo es conocido como MRNA-NAR. Cuando se tiene registro de la variable que afecta la serie de tiempo, esta se puede utilizar como entrada al modelo de predicción, convirtiéndolo a la forma MRNA-NARX. A continuación, se describen algunos trabajos donde se han implementado estructuras MRNAs NAR/NARX para la predicción, y que soportan la elección de dicha técnica para la predicción de variables en el diagnóstico propuesto.

Las MRNAs-NAR han tenido una influencia relevante en la predicción de la demanda eléctrica. En (Moreno, *et al.*, 2012), se muestra la implementación de una MRNA-NAR, para la predicción del consumo eléctrico colombiano. La predicción permite obtener el valor futuro del consumo mensual de una serie no lineal, como lo es la serie de demanda de energía colombiana. En el trabajo resaltan la dificultad de predecir series no lineales por medio de modelos convencionales, presentando las MRNAs-NAR como una estrategia sólida para la predicción no lineal de variables. Un predictor NAR basado en MRNAs, se expone en (Rodríguez, 2016), el predictor propuesto se basa en la rugosidad de la serie para establecer el proceso de ajuste de la topología de la red, además del predictor, también se propone una metodología de predicción basada en submuestreos a partir del filtrado con estructuras MRNAs-NAR. Las metodologías se implementan sobre series de lluvia caracterizadas por admitir modelos dinámicos no lineales, caóticos e incluso estocásticos. Los resultados del pronóstico se utilizan para la toma de decisiones en el sector agrícola. En la investigación se demuestra como las MRNAs tienen la capacidad de predecir cualquier tipo de serie temporal real con cambios abruptos, generando resultados más confiables comparados con los obtenidos por métodos de predicción estadística convencional. La importancia de las MRNAs como estructura de predicción se evidencia en (Velázquez, *et al.*, 2014), donde se hace una descripción de las principales funciones de una aplicación diseñada para la predicción mediante MRNAs autorregresivas. Con la aplicación se pueden ejecutar pronósticos de una serie no lineal, además resaltan la efectividad del contraste estadístico no lineal de los modelos obtenidos por MRNAs y autorregresivos neuronales MRNAs-NAR. Pucheta, *et al.* 2010, muestran los resultados de la implementación de un filtro predictor basado en una estructura MRNA-NAR, con adaptación topológica de la red en cada

etapa de tiempo. El resultado principal del trabajo muestra buen desempeño de la estructura autorregresiva neuronal, aplicada a series de tiempo de precipitación acumulada mensual, superando el desempeño del filtrado convencional de las series pronosticadas.

En Villazón-Bustillos, *et al.*, (2016), se presenta una investigación con el objetivo principal de predecir el próximo evento de sequía en el noroeste de un estado mexicano. En la investigación se implementan dos estructuras inteligentes basadas en MRNAs para la predicción. La conclusión más relevante del trabajo es que la estructura MRNA-NARX presenta menor error y por lo tanto mejor desempeño en la predicción en comparación con una estructura neuronal ARIMA. La predicción del ancho de banda mediante una MRNA-NARX se muestra en (Capizzi, *et al.*, 2017), estimación que permite reconfigurar los pesos del mecanismo de equilibrio de carga, generando un ancho de banda adaptativo. Los resultados resaltan que se puede estimar el ancho de banda a partir del conocimiento pasado de características de tráfico. En Menezes, *et al.*, 2008, se expone la evaluación de la predicción de series de tiempo a largo plazo con MRNAs-NARX. En el trabajo se hace una evaluación que permite concluir que el enfoque MRNAs-NARX supera el desempeño de otras estructuras neuronales para la predicción. El enfoque es utilizado en un sistema caótico, y se proyecta para nuevas predicciones en el variante sistema financiero y en el procesamiento de señales, entre otros. La predicción de la vida útil de rodamientos por medio de la implementación de una MRNA-NARX se muestra en (Ray, *et al.*, 2017). Para determinar la vida útil remanente del rodamiento se utiliza un mecanismo adicional que separa el ruido antes de la extracción de características. Los resultados sugieren que el método propuesto puede predecir efectivamente la vida útil remanente de rodamientos con un grado aceptable de precisión, superando indicadores auto organizados basados en mapas y técnicas tradicionales para la inferencia de la vida útil. La predicción MRNA-NARX de una serie no lineal se presenta en (Kim, 2015). La estructura neuronal se entrenó a partir del análisis de elementos finitos no lineales de un mecanismo marino implementado para la medición del oleaje, sometido bajo olas estocásticas simuladas por un ruido blanco. Los resultados indican buen desempeño de la MRNA-NARX para la predicción de sistemas complejos con componentes aleatorias. La metodología neuronal propuesta se puede extender además para cubrir múltiples componentes a diferentes frecuencias, para predecir con precisión la respuesta de la serie de tiempo bajo excitación aleatoria arbitraria.

El éxito de la predicción mediante estructuras MRNAs-NAR/NARX, reportado en las investigaciones, fue factor fundamental para la elección de las estrategias neuronales como método de predicción. En el esquema diagnóstico propuesto, la predicción estará a cargo de MRNAs-NAR/NARX.

En este capítulo se describen las bases teóricas de las estructuras MRNAs aplicadas a la predicción de variables; posteriormente se muestran los resultados de la implementación de las MRNAs-NAR/NARX sobre los sistemas de prueba, y los modelos de predicción obtenidos. Se utilizan métricas relacionadas con el error para evaluar los modelos, y se presentan los resultados

gráficos y numéricos de cada variable predicha. Por último, se presentan las conclusiones derivadas del capítulo.

### 3.2 Redes Neuronales Artificiales (RNAs)

Las RNAs son estructuras conexionistas inspiradas en la neurona biológica. Las RNA imitan la forma de procesamiento humano, tanto en su estructura como en la capacidad de procesamiento paralelo y aprendizaje (Gómez, *et al.*, 2017), (Santa Cruz & Correa, 2017). Los primeros intentos por crear la analogía entre una neurona biológica y una neurona artificial dieron como resultado una red simple, denominada perceptrón. La figura 17 muestra las partes de un perceptrón y su analogía frente a una neurona biológica. Las entradas, al igual que en el sistema neuronal biológico, corresponden a los estímulos percibidos por el entorno. Cada estímulo es ponderado por un peso sináptico para luego ser sumados en un nodo de suma. La salida de la red neuronal es la consecuencia de la percepción de las entradas, incluido el umbral de excitación. Entre la entrada y la salida, existe un elemento que adiciona no linealidad a la RNA, y es denominado función de activación (Astray, *et al.*, 2017), (Ponce, 2010).

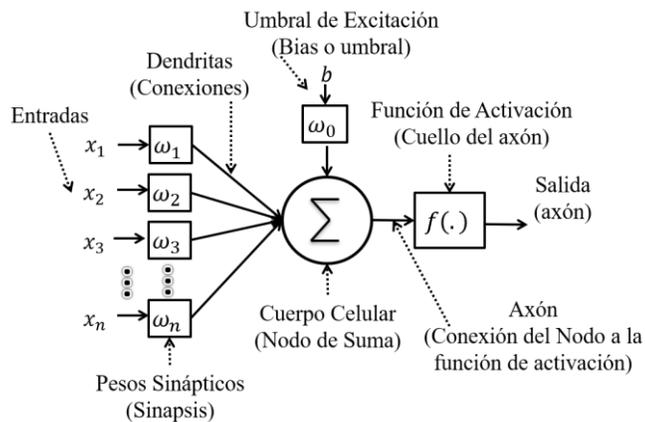


Figura 17. Analogía entre un perceptrón y una neurona biológica  
Fuente: Adaptada de (Ponce, 2010).

Dependiendo de la tarea a ejecutar por las RNAs, se elige la función de activación de cada neurona. Para tareas de decisión binaria o de separación lineal de patrones se utilizan funciones de activación de tipo escalón o limitador duro. En el caso de aproximación de funciones no lineales, clasificación de patrones limitados por superficies irregulares convexas y no convexas, control e identificación de sistemas; o predicción de variables, se utilizan funciones diferenciables de tipo sigmoideal, tangente hiperbólica, o la combinación de ambas, incluida la función de activación lineal. La función de activación es un factor determinante en el desempeño de la red, por lo tanto, su elección es fundamental durante el diseño de la estructura neuronal (Castellano, 2009).

Las limitaciones del perceptrón simple, en especial su capacidad de discriminar patrones solo linealmente separables, provocaron investigaciones que generaron RNAs con estructuras

complejas como las Redes Neuronales Artificiales Multicapa (MRNA). Una RNA conformada por una sola unidad funcional, es por si misma débil para solucionar tareas complejas, generando divergencia en los algoritmos de aprendizaje. En la medida que se adicionan capas ocultas y neuronas en una RNA, se incrementa la capacidad de aprender ejemplos asociados a problemas complejos (Sánchez, 2012). La figura 18 muestra los elementos de una MRNA.

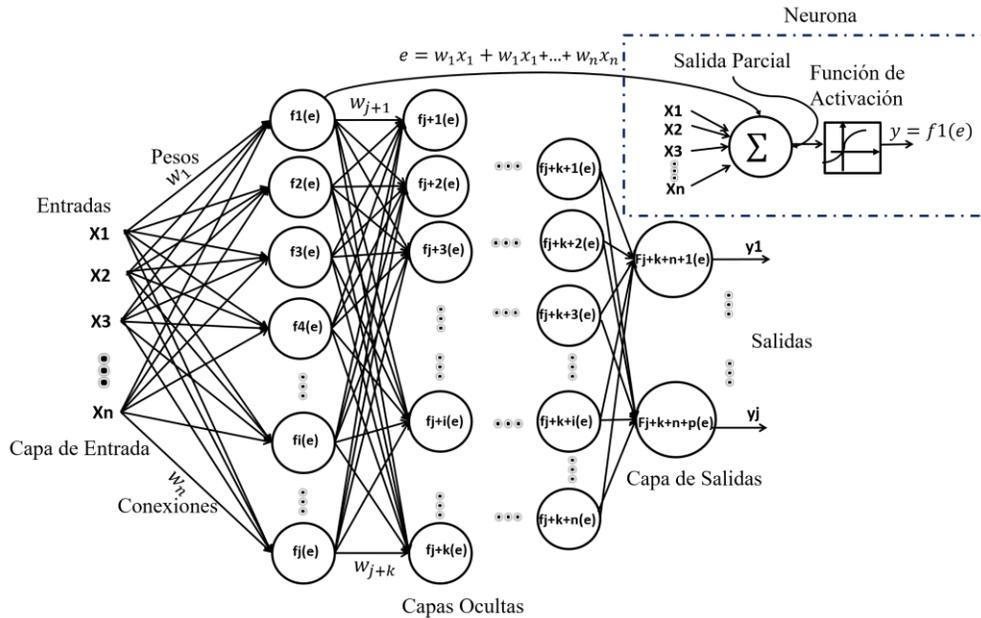


Figura 18. Estructura detallada de una MRNA.  
Fuente: Elaboración propia

La RNA mostrada en la figura 18, es denominada Red Neuronal Artificial *Bacpropagation* (RNABP), el nombre es debido 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. Las conexiones de la RNABP son hacia adelante (*feddforward*), es decir que la información se trasfiere desde la capa de entrada hasta las capas ocultas, y de las capas ocultas hasta la capa de salida (Orozco, *et al.*, 2015), (Wang, *et al.*, 2015), (Hassan, *et al.*, 2016).

### 3.2.1 Entrenamiento de la MRNA

Para que una RNA produzca las salidas deseadas establecidas por el diseñador, requiere de un proceso de entrenamiento iterativo. El aprendizaje hace parte del entrenamiento de las RNAs y se divide en aprendizaje supervisado y no supervisado. En el aprendizaje supervisado, una serie de ejemplos se le presentan a la RNA, los ejemplos se caracterizan por tener para cada conjunto de entrada(s) las respectiva(s) salida(s) deseada(s). Para obtener las salidas deseadas existe un componente algorítmico intermedio, que permite actualizar los pesos sinápticos de la RNA en función de algún criterio de minimización. En el aprendizaje no supervisado, el entrenamiento busca encontrar rasgos estadísticos, o ajustar un modelo en función de observación del conjunto de entradas.

En el diseño de una RNA, el histórico de datos se divide en tres subconjuntos, denominados *set* de entrenamiento, *set* de validación y *set* de prueba. El *set* de entrenamiento debe ser lo suficientemente diverso y significativo para entrenar la RNA, no se recomienda el uso de todo el histórico de datos durante el proceso de entrenamiento. Lo anterior podría ocasionar sobreentrenamiento de la RNA, con incapacidad de generalizar su desempeño ante entradas no presentadas en el aprendizaje. El *set* de validación se utiliza para elegir el mejor modelo y el *set* de prueba se utiliza para verificar el verdadero desempeño de la red y el valor real del error.

Al tratar de minimizar un criterio de diseño, el entrenamiento de las RNAs se convierte en un problema numérico de optimización no lineal sin restricciones, en el que se deben encontrar los pesos óptimos de la RNA. (Sánchez, 2012). Una de las estrategias basada en aprendizaje supervisado más utilizada para el entrenamiento de MRNA *feedforward*, es el algoritmo de retropropagación del error *Backpropagation* (BP) (Orozco, *et al.*, 2015), (Sánchez, 2012), (Suliman, *et al.*, 2015). El algoritmo de retropropagación del error busca encontrar iterativamente los pesos sinápticos óptimos de la MRNA en dirección descendente de la función del error. Para lo anterior, el algoritmo utiliza el gradiente negativo y la derivada de las funciones de activación de las neuronas de cada capa de la MRNA. La regla del gradiente descendente (ver Figura 19) considera el Error Cuadrático Medio (ECM) dado por la ecuación (9). El ECM, permite omitir signos negativos facilitando trabajar con el error acumulativo en cada época del entrenamiento. Una época se define como el mecanismo que permite presentar todo el conjunto de datos de entrada y sus respectivas salidas deseadas, para la posterior actualización de los pesos de la MRNA.

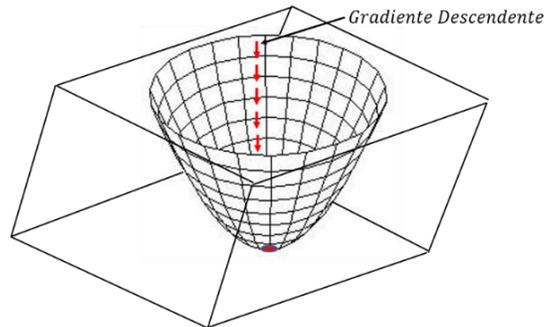


Figura 19. Gradiente descendente en una superficie parabólica.  
Fuente: Elaboración propia

$$e^M = \frac{1}{2} \sum_{k=1}^n e^2 = \frac{1}{2} \sum_{k=1}^n (T(k) - y(k))^2; \quad T \rightarrow \text{Salida Deseada} \quad (9)$$

Considere la función sigmoide mostrada en (10):

$$f(x) = \frac{1}{1 + e^{-x}} \quad (10)$$

La cual corresponde a la función de activación de la *neurona<sub>i</sub>* mostrada en la Figura 20:

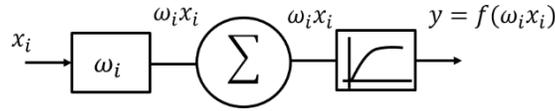


Figura 20. RNA simple con función de activación sigmoide  
Fuente: Elaboración propia

La salida de la red estará dada por:

$$y = f(\omega_i x_i) = \frac{1}{1 + e^{-\omega_i x_i}} \quad (11)$$

Derivando la ecuación (10) en función de la entrada, se obtiene:

$$\frac{\partial f}{\partial x} \left( \frac{1}{1 + e^{-x}} \right) = \frac{e^{-x}}{(1 + e^{-x})^2} \quad (12)$$

La ecuación (12) se puede reescribir como:

$$\frac{\partial f}{\partial x} \left( \frac{1}{1 + e^{-x}} \right) = \frac{1}{1 + e^{-x}} \left( 1 - \frac{1}{1 + e^{-x}} \right) = f(1 - f) \quad (13)$$

La ecuación (13) resulta de gran utilidad para cálculos iterativos, ya que permite evaluar la derivada de la función sigmoide por medio de la función original.

El valor deseado depende del gradiente del error con respecto a los pesos:

$$\frac{\partial e^M}{\partial \omega} = \frac{\partial e^M(k)}{\partial y(k)} \frac{\partial y(k)}{\partial \omega_i} \quad (14)$$

Considere la función sigmoide, la cual evalúa la entrada  $x_i$ :

$$f = f(\cdot) = f(\omega_i x_i); \text{ Donde } f = \text{sigmoide} \quad (15)$$

La derivada del error cuadrático medio instantáneo es:

$$\frac{\partial e^M(k)}{\partial x(k)} = \frac{1}{2} \frac{\partial (T_s - f)^2}{\partial x(k)} = -(T_s - f) \frac{\partial f}{\partial x(k)}(f) \quad (16)$$

Remplazando la ecuación (13) en la ecuación (16):

$$\frac{\partial e^M(k)}{\partial x(k)} = -(T_s - f) f(1 - f) \quad (17)$$

Si se tiene en cuenta la salida lineal, se tiene:

$$y(k) = \sum_{i=1}^n x_i \omega_i \quad (18)$$

La derivada de  $y(k)$  en función de  $\omega_i$ ; es:

$$\frac{\partial y(k)}{\partial \omega_i} = x \quad (19)$$

Reemplazando la ecuación (17) y (19) en (14), se obtiene que:

$$\frac{\partial e^M}{\partial \omega} = -(T_s - f)f(1 - f)x \quad ; \text{ Donde } (T_s - f) = e \quad (20)$$

Los cambios en los pesos  $\omega$  son proporcionales al producto del negativo del error y la derivada de la función de activación. Se hace necesario avanzar en el sentido descendente respecto a la parábola del error. De esta forma, la actualización de pesos se puede hacer empleando la siguiente ecuación:

$$\Delta\omega = \omega(k + 1) = \omega(k) + \eta x(k)e(k)f(1 - f) \quad (21)$$

En la ecuación (21),  $\eta$  es un coeficiente positivo denominado tasa de aprendizaje. Se considera que valores de  $\eta > 1$  ocasionan convergencia prematura, mientras que valores pequeños asignados a  $\eta$ , producen incrementos considerables en los pasos para la convergencia del algoritmo. Por lo tanto  $0 < \eta < 1$ . (Sánchez, 2012), (Flores, 2011), (Ponce, 2010).

El algoritmo BP inicia con el cálculo de la salida  $f_i(e)$  de cada neurona de la capa de entrada. La salida  $f_i(e)$  corresponde a la entrada de cada neurona de la primera capa oculta; a su vez, la salida  $f_{i+j+k}(e)$  de las neuronas en la *capa<sub>k</sub>* son las entradas de cada neurona en la  $n - \text{ésima}$  capa oculta. Finalmente, las salidas  $f_{i+j+k+n}(e)$  de la  $n - \text{ésima}$  capa oculta constituyen las entradas de la capa de salida. Cada salida  $y_j$  de la MRNA es comparada con el objetivo (salida deseada)  $T_j$ , la comparación permite determinar el error  $\delta_j$ , el cual es retro-propagado desde la capa de salida hasta la capa de entrada sobre cada neurona. Cuando el error ha sido propagado hasta la capa de entrada, se utiliza la regla de aprendizaje (21) para actualizar los pesos  $w_{i+j+k+n}$  de la MRNA. El ECM se minimiza iterativamente mediante la actualización de los pesos. El algoritmo finaliza cuando se ha superado el número de épocas, o cuando se ha cumplido el valor de tolerancia del error preestablecido y permitido por el usuario.

Si bien el algoritmo BP es una de las estrategias más populares dentro del entrenamiento de las MRNAs, su rendimiento tiende a disminuir cuando la superficie del error es compleja y contiene múltiples mínimos locales, como consecuencia de dinámicas no lineales. Lo anterior incrementa la dificultad de converger a un óptimo global durante la ejecución del algoritmo, generando soluciones que varían entre cada implementación durante la etapa de entrenamiento (Sánchez, 2010). Para solucionar el problema de convergencia hacia soluciones de mejor calidad dentro del entrenamiento de la MRNA, han surgido múltiples mejoras que incluyen modificaciones del algoritmo *Backpropagation*, una de ellas es el algoritmo de *Levenberg-Marquardt* (LM).

El algoritmo LM corresponde a una técnica iterativa basada en el algoritmo BP, que localiza el mínimo de una función que se expresa como la suma de los cuadrados de funciones no lineales (Gonzales, *et al.*, 2012), (Salvador, *et al.*, 2015); además se combina con una parada temprana evitando sobre-entrenamiento de la MRNA a partir de la finalización automática del proceso de entrenamiento (Muñoz, *et al.*, 2015).

Otra de las decisiones importantes, además de la elección del algoritmo de entrenamiento, es la configuración de la MRNA. La cantidad de neuronas y número de capas ocultas es todavía un tema de investigación. Sin embargo, una de las alternativas para configurar la MRNA está fundamentada en el teorema de *Kolmogorov*, el cual indica que, a partir de una capa de entrada, una oculta y una capa de salida, se puede aproximar cualquier función hasta un nivel deseado (Gonzales, *et al.*, 2012), (Sánchez, 2010).

### 3.2.2 Predicción de variables mediante MRNA autorregresivas

Una de las aplicaciones más importantes de las MRNA, es la predicción de variables. Con algunas configuraciones en la estructura de una MRNA y aprovechando su capacidad de interpolación, se puede 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  $y_{k-1}, y_{k-2}, y_{k-3}, \dots, y_{k-m}$  (22); con posibilidad de incluir entradas exógenas  $(\mu_k, \mu_{k-1}, \mu_{k-2}, \mu_{k-3}, \dots, \mu_{k-m})$  en el modelo de predicción (23).

$$\hat{y}_{k+m} = f(y_k, y_{k-1}, y_{k-2}, y_{k-3}, \dots, y_{k-m}); \quad f(.) \text{ función no lineal} \quad (22)$$

$$\hat{y}_{k+m} = f(\mu_k, \mu_{k-1}, \mu_{k-2}, \dots, \mu_{k-m}, y_k, y_{k-1}, y_{k-2}, y_{k-3}, \dots, y_{k-m}); \quad f(.) \text{ función no lineal} \quad (23)$$

Las observaciones pasadas de las variables durante el entrenamiento, ingresan a la MRNA NAR/NARX por medio de vectores extendidos de las entradas 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 figura 21. Lo anterior presenta la ventaja de permitir trabajar con una estructura directa *feedforward*, y entrenamiento estático mediante algoritmos convencionales BP. 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 (Montserrat, 2013).

Después de definir el modelo de predicción mediante la estructura MRNA, la salida predicha  $\hat{y}_{t+k}$  puede ser utilizada como una nueva entrada a la red. Lo anterior permite obtener MRNAs autorregresivas, implementadas para la modelación predictiva iterada en series de tiempo no lineales; donde la componente tendencial y estacional, e inclusive la componente aleatoria, no representan un problema, en comparación con el análisis estocástico convencional de las series de tiempo.

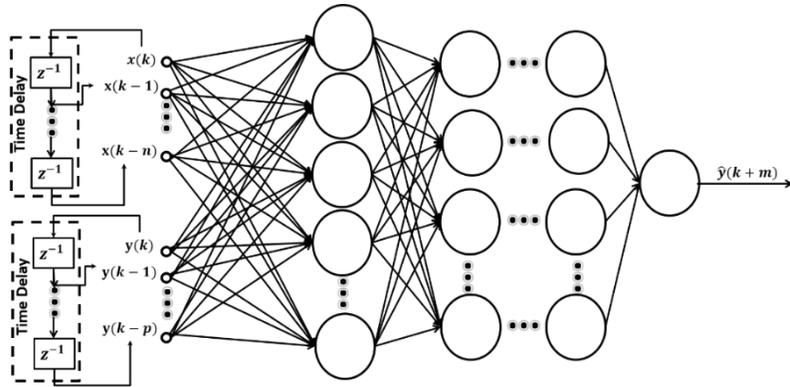


Figura 21. Arquitectura MRNA Serie-Paralelo.  
Fuente: Elaboración propia

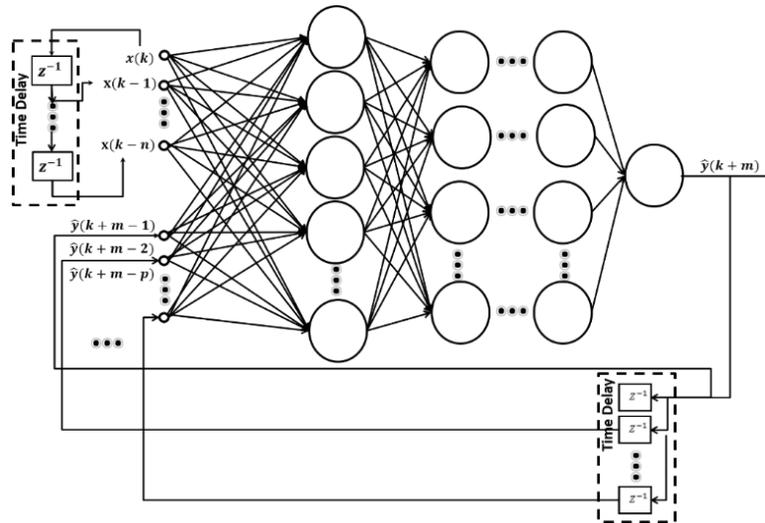


Figura 22. Estructura MRNA-NARX  
Fuente: Elaboración propia

La evaluación de los modelos de predicción basados en MRNA NAR/NARX, se puede obtener a partir de métricas convencionales relacionadas con el error (Sánchez, 2012), como:

Error Cuadrático Medio, (*Mean Squared Error, MSE*).

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (24)$$

Coefficiente de determinación  $R^2$

$$R^2 = \frac{\sum_{i=1}^n e_i^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (25)$$

Raíz del Error Cuadrático Medio,  
(*Root Mean Squared Error, RMSE*).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (26)$$

Error Medio Absoluto (*Mean Absolute Error, MAE*).

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (27)$$

Porcentaje del Error Medio Absoluto  
(*Mean Absolute Percentage Error, MAPE*).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|e_i|}{|y_i|} \quad (28)$$

### 3.3 Resultados

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. Para entrenar las MRNAs se utilizó la herramienta *nntool* del *software* Matlab®, el algoritmo LM y una sola capa oculta en la configuración de la red, de acuerdo con la fundamentación matemática dada por *Kolmogorov* (Gonzales, *et al.*, 2012), (Sánchez, 2010). El procedimiento de diseño y los resultados se muestran a continuación.

#### 3.3.1 Predicción de las VPCPAM mediante MRNA-NAR

Los datos del comportamiento dinámico de las VPCPAM se registraron en una base de datos de 99750 muestras para las 4 variables (matriz [99750 x 4]), a un período de adquisición de datos de 2 minutos; de acuerdo con la normatividad aplicada para la producción de aire medicinal en sitio por compresor. 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 x 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.

$$x_{i(k)} = [PPMCO_{(k)} \quad TPR_{(k)} \quad HR_{(k)} \quad TA_{(k)}]; \quad k: \text{ instante de medición}; \quad (29)$$

En el *software* Matlab®, y con la ayuda de un *script*, se individualizó y normalizó cada variable 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 13 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. En las Figuras 23-26 se muestran los resultados de cada predicción de las VPCPAM, permitiendo observar la aproximación gráfica entre la salida esperada y la generada por cada estructura

neuronal. Los gráficos fueron construidos a partir de cada MRNA-NAR, superponiendo el registro histórico de cada salida real versus la respuesta de cada red.

Tabla 13. 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	$2,10 \times 10^{-4}$
TA	4 – $f(.)$ Sigmoide	0,9994	$1,10 \times 10^{-5}$

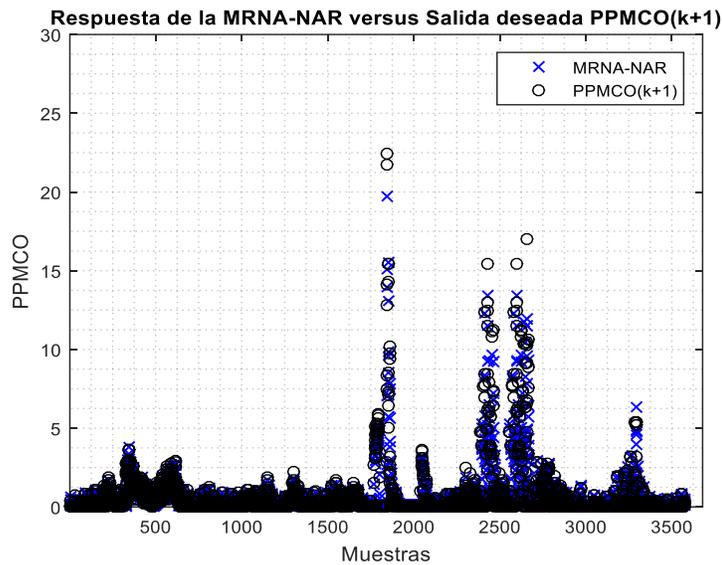


Figura 23. Resposta gráfica de la estructura MRNA-NAR entrenada para la predicción de las PPMCO  
Fuente: Elaboración propia

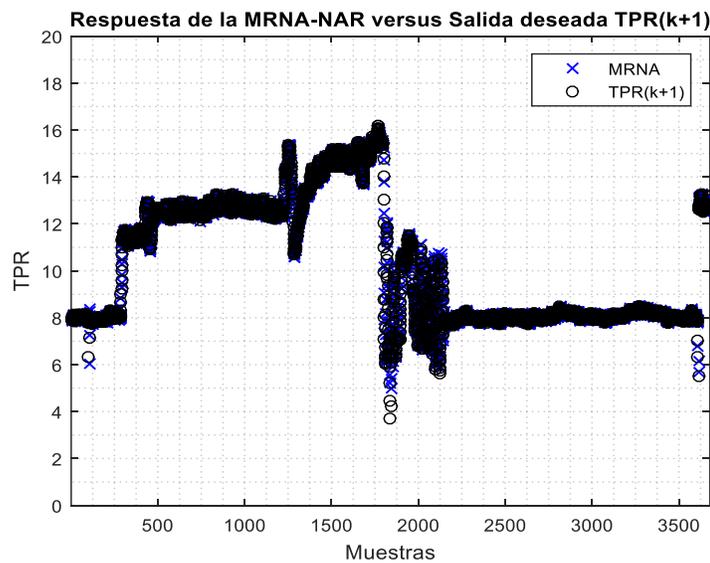


Figura 24. Resposta gráfica de la estructura MRNA-NAR entrenada para la predicción de la TPR  
Fuente: Elaboración propia

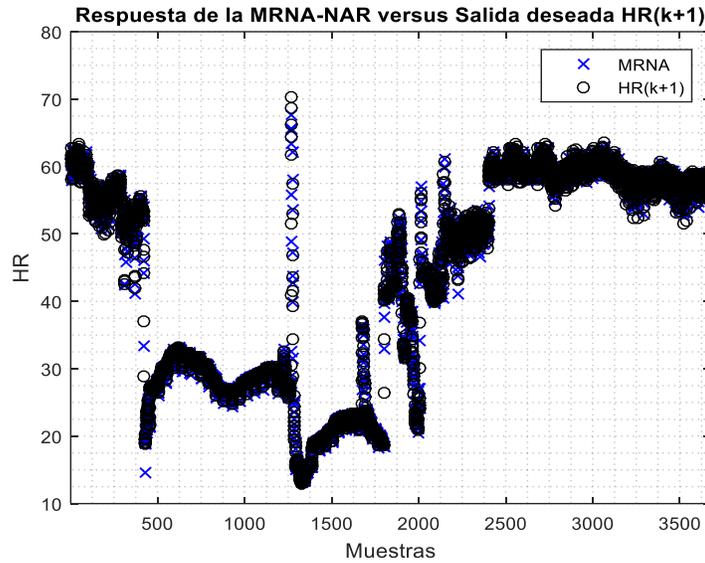


Figura 25. Respuesta gráfica de la estructura MRNA-NAR entrenada para la predicción de la HR  
Fuente: Elaboración propia

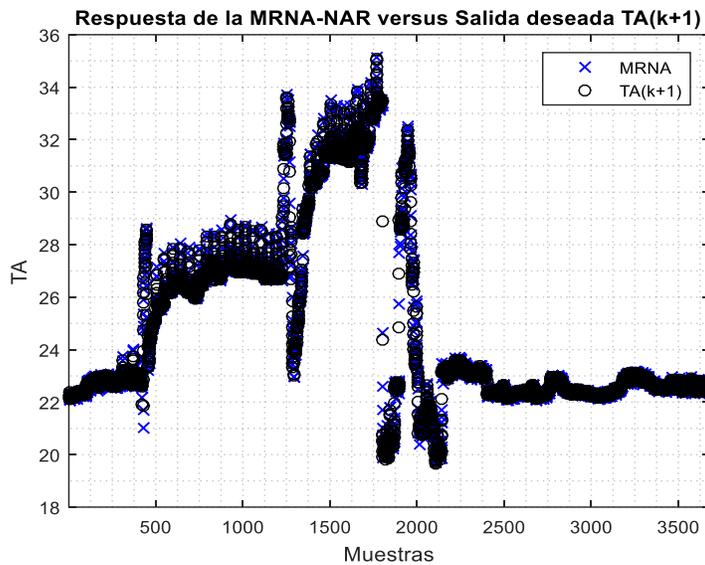


Figura 26. Respuesta gráfica de la estructura MRNA-NAR entrenada para la predicción de la TA  
Fuente: Elaboración propia

Una de las alternativas para evaluar los modelos de predicción, consiste en utilizar información con datos fuera de muestra. Lo anterior permite verificar la verdadera capacidad de generalización del modelo, a partir de información no utilizada por la MRNA en el proceso de aprendizaje. Los resultados numéricos generados asociados al error son evaluados, en especial el MAPE. Se considera que un MAPE menor al 10%, indica que el modelo es confiable presentando un buen desempeño en la generalización (Béjar, *et al.*, 2016).

La Tabla 14 muestra los resultados numéricos obtenidos a partir de la evaluación con datos fuera de muestra, de los modelos de predicción de las VPCPAM. Se observa en general que el  $R^2$  supera el 97% de relación lineal, en los modelos evaluados con el 100% de los datos de entrenamiento, a la vez que supera el 95% de relación lineal en la evaluación con los datos fuera de muestra. Sumado a lo anterior se observa que las métricas MSE, RMSE y MAE se mantuvieron en valores cercanos a cero, el MAPE en especial presentó un valor menor al 0.1% en cada estructura, demostrando que los modelos se consideran confiables.

Tabla 14. Resultados numéricos de las MRNA-NAR para la predicción de las VPCPAM.

Variable VPCPAM		$R^2$	MSE	RMSE	MAE	MAPE
PPMCO	Modelo	0,9749	$1,013 \times 10^{-10}$	$2,132 \times 10^{-5}$	$5,472 \times 10^{-7}$	$4,610 \times 10^{-5}$
	Evaluación	0,9543	$6,235 \times 10^{-7}$	$1,552 \times 10^{-3}$	$2,810 \times 10^{-5}$	$2,650 \times 10^{-4}$
TPR	Modelo	0,9963	$4,827 \times 10^{-9}$	$8,835 \times 10^{-5}$	$8,597 \times 10^{-7}$	$5,209 \times 10^{-7}$
	Evaluación	0,9799	$3,240 \times 10^{-8}$	$2,362 \times 10^{-7}$	$1,371 \times 10^{-5}$	$3,429 \times 10^{-6}$
HR	Modelo	0,9955	$2,754 \times 10^{-8}$	$8,50 \times 10^{-5}$	$6,359 \times 10^{-7}$	$2,470 \times 10^{-6}$
	Evaluación	0,9711	$2,373 \times 10^{-8}$	$1,00 \times 10^{-4}$	$9,365 \times 10^{-7}$	$2,529 \times 10^{-6}$
TA	Modelo	0,9977	$1,235 \times 10^{-9}$	$4,310 \times 10^{-5}$	$6,656 \times 10^{-7}$	$2,791 \times 10^{-7}$
	Evaluación	0,9970	$1,053 \times 10^{-8}$	$3,292 \times 10^{-5}$	$1,469 \times 10^{-6}$	$1,719 \times 10^{-6}$

### 3.3.2 Predicción de variables de la planta de presión mediante MRNA-NARX

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  $[4105 \times 4]$ ); 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 la ecuación (30) 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).

$$x_{i(k)} = [VC_{(k)} \quad EC_{(k)} \quad TD_{(k)} \quad LC_{(k)}]; \quad k: \text{instante de medición}; \quad (30)$$

Cada variable fue individualizada y normalizada. Para configurar las entradas a la MRNA-NARX se generaron 2 retrasos, además del valor actual en la variable de salida y entrada exógena (ver ecuación 31). 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.

$$y = [y_{(k-1)} \quad y_{(k-2)} \quad y_{(k)} \quad u_{(k)} \quad u_{(k-1)} \quad u_{(k-2)}]; \quad \text{Vector de 6 elementos} \quad (31)$$

La tabla 15 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  $6.95 \times 10^{-4}$ , en el caso del modelo de predicción del EC, hasta  $5.17 \times 10^{-5}$  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. En las Figuras 23-26 se muestran los resultados de cada predicción de las VPCPAM, permitiendo observar la aproximación gráfica entre la salida esperada y la generada por cada estructura neuronal. Los gráficos fueron contruidos a partir de cada MRNA-NAR, superponiendo el registro histórico de cada salida real versus la respuesta de cada red.

Tabla 15. 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	$5,17 \times 10^{-5}$
EC	8 – $f(.)$ Sigmoide	0,990	$6,95 \times 10^{-4}$
TD	8 – $f(.)$ Sigmoide	0,998	$1,36 \times 10^{-5}$

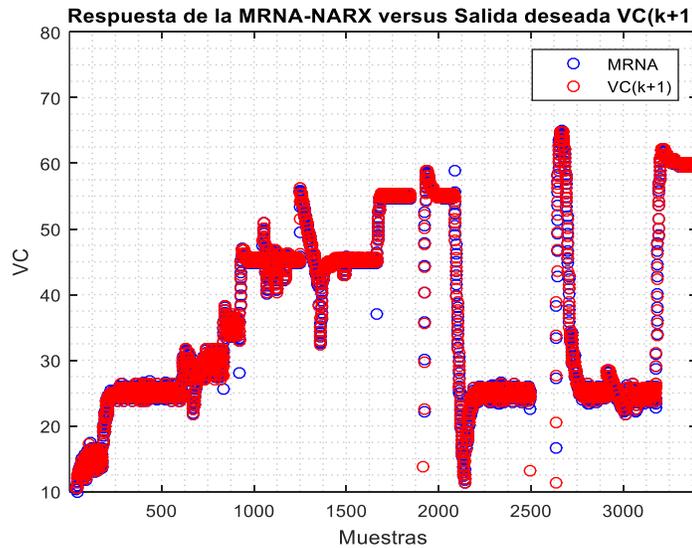


Figura 27. Respuesta gráfica de la estructura MRNA-NARX entrenada para la predicción de la VC  
Fuente: Elaboración propia

La Tabla 16 muestra los resultados numéricos obtenidos a partir de la evaluación con datos fuera de muestra, de los modelos de predicción para las variables VC, EC y TD de la planta de presión. Se observa en general que el  $R^2$  supera el 99% de relación lineal, en los modelos evaluados con el 100% de los datos de entrenamiento, a la vez que supera el 97% de relación lineal en la evaluación con los datos fuera de muestra. Sumado a lo anterior se observa que las métricas MSE, RMSE y MAE se mantuvieron en valores cercanos a cero, el MAPE en especial presentó un valor menor al 0.1% en cada estructura, demostrando que los modelos se consideran confiables.

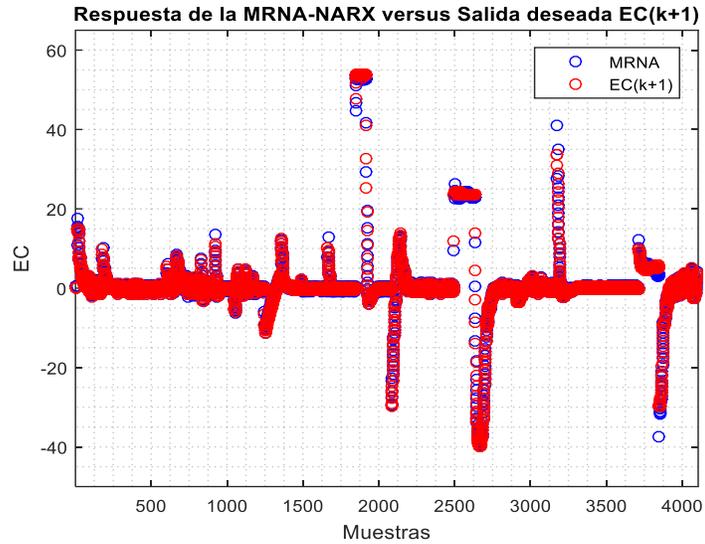


Figura 28. Respuesta gráfica de la estructura MRNA-NARX entrenada para la predicción de la EC  
Fuente: Elaboración propia

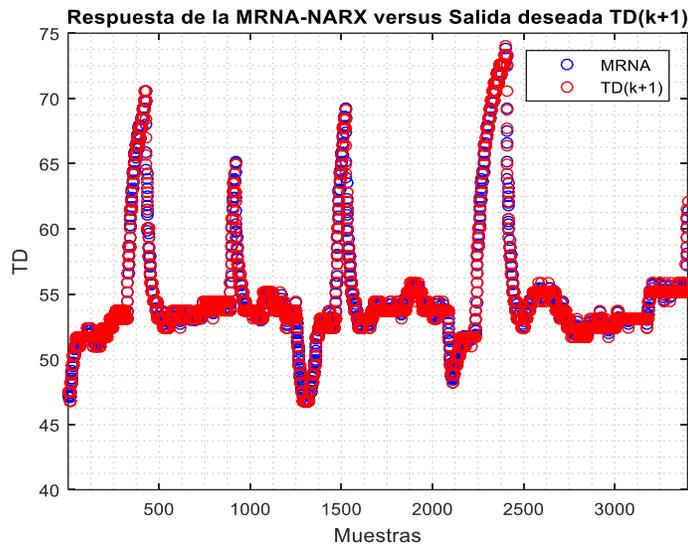


Figura 29. Respuesta gráfica de la estructura MRNA-NARX entrenada para la predicción de la TD  
Fuente: Elaboración propia

Tabla 16. Resultados numéricos de las MRNA-NARX para la predicción de las variables en la planta de presión.

Variable		$R^2$	$MSE$	$RMSE$	$MAE$	$MAPE$
VC	Modelo	0,9989	$2,246 \times 10^{-8}$	$1,498 \times 10^{-4}$	$8,544 \times 10^{-7}$	$6,031 \times 10^{-2}$
	Evaluación	0,9960	$2,011 \times 10^{-12}$	$1,714 \times 10^{-5}$	$4,585 \times 10^{-7}$	$5,552 \times 10^{-7}$
EC	Modelo	0,9801	$3,604 \times 10^{-11}$	$3,272 \times 10^{-5}$	$8,393 \times 10^{-7}$	$2,918 \times 10^{-5}$
	Evaluación	0,9714	$1,310 \times 10^{-7}$	$6,534 \times 10^{-5}$	$1,224 \times 10^{-6}$	$2,553 \times 10^{-4}$
TD	Modelo	0,9977	$3,43 \times 10^{-12}$	$1,479 \times 10^{-4}$	$7,750 \times 10^{-7}$	$4,020 \times 10^{-6}$
	Evaluación	0,9969	$8,361 \times 10^{-9}$	$6,869 \times 10^{-5}$	$2,120 \times 10^{-7}$	$3,193 \times 10^{-7}$

### **3.4 Conclusiones**

En este capítulo se presentó la predicción mediante IA de variables de los sistemas de prueba, a partir de redes RNAs. Para la elección de las estructuras neuronales se realizó una revisión sobre la predicción de variables mediante MRNAs NAR/NARX. En las implementaciones encontradas se logró evidenciar la capacidad de las MRNAs para la predicción no lineal de series de tiempo, con resultados que superaron los métodos convencionales.

Se construyeron los modelos de predicción para cada variable de los sistemas de prueba. Para el sistema de producción de aire medicinal se eligieron estructuras MRNAs-NAR debido a que solo se tenía registro histórico de las VPCPAM. Para la planta de presión se eligieron redes MRNAs-NARX, ya que se tenía registro histórico de las variables de salida, así como registro de la variable exógena. Las variables fueron individualizadas y normalizadas para luego ser utilizadas como entradas a las MRNAs en la etapa de entrenamiento.

Los registros históricos de ambos sistemas de prueba fueron divididos para construir y evaluar los modelos de predicción. 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. Los resultados anteriores se utilizaron como parámetros de aceptación de los modelos.

### **3.5 Referencias bibliográficas**

Astray, G., Cid, A., Moldes, O., Mejuto, J. (2017). Influence of Amphiphiles on Percolation of AOT-Based Microemulsions Prediction Using Artificial Neural Networks. Open access peer-reviewed chapter. Chapter 8. May 24. pp. 155-173. [dx.doi.org/10.5772/66766](https://doi.org/10.5772/66766).

Béjar, W., Valeriano, k., Ilachoque, J., Torres, J. (2016). Predicción de caudales medios diarios en la cuenca del Amazonas aplicando redes neuronales artificiales y el modelo neurodifuso ANFIS. *Research in Computing Science* 113 (2016). pp. 23–35.

Corrales, L., Ramírez, A. (2013). Clasificación de fallas con redes neuronales para grupos electrógenos. *Ingeniería Energética* Vol. 34, No. 2, pp. 137-150.

Capizzi, g., Lo Sciuto, g., Beritelli, F., Scaglione, f., Połap, D., Książek, K., Woźniak, M., (2017). Available Bandwidth Estimation in Smart VPN Bonding Technique based on a NARX Neural Network. *Computer Science and Information Systems*. Vol 11. pp. 601–606. DOI: 10.15439/2017F401

Castellano, M. (2009). Modelización estadística con redes neuronales. Aplicación a la hidrología, aerobiología y modelización de procesos. (Tesis Doctoral). Departamento de Matemáticas, Universidade da Coruña. La Coruña, España.

Fernández, F. (2008). Aproximación funcional mediante redes de funciones de base radial, una alternativa para la predicción en el proceso de reducción de mineral de la tecnología caron de producción de níquel. (Tesis Doctoral). Departamento de Arquitectura y Tecnologías de Computadores. Escuela Superior de Ingeniería Informática. Universidad de Granada. Granada. España.

Flores, U. (2011). Identificación de sistemas no lineales mediante las estructuras NARX y Hammerstein-Wiener. (Tesis de Maestría). Departamento de Ingeniería Electrónica, Centro Nacional de Investigación y Desarrollo Tecnológico. Cuernavaca, Morelos, México.

Gómez, Julieth., Simancas, J., Acosta, M., Meléndez, F., Vélez, J. (2017). Algoritmo de reconocimiento de comandos de voz basado en técnicas no-lineales. Revista Espacios. Vol. 38, Número 17, Pág. 4.

Gonzales, L., Guerrero, A., Delvastro, A., Ernesto, A. (2012). Exploración con redes neuronales artificiales para estimar la resistencia a la compresión, en concretos fibroreforzados con acero. Ciencia e Ingeniería Neogranadina, Vol. 22, No. 1, pp. 1-14.

Hassan, M., Hamada, M. (2016). Performance Comparison of Featured Neural Network Trained with Backpropagation and Delta Rule Techniques for Movie Rating Prediction in Multi-criteria Recommender Systems. Informática 40 (2016), pp. 409–414.

Kim, Y. (2015). Prediction of the dynamic response of a slender marine structure under an irregular ocean wave using the NARX-based quadratic Volterra series. Applied Ocean Research. Vol. 49 (2015), pp. 42–56

Montserrat, M. (2013). Sistemas Inteligentes para el ajuste de Modelos Hidrológicos. Aplicación al Río Paraná. (Tesis Doctoral). Facultad de Ciencias. Departamento de Matemática Aplicada y Ciencias de la Computación. Universidad de Cantabria. Santander, España.

Moreno, C., Pedraza, L., Rivas, E., (2012). Predicción de la demanda de energía eléctrica basado en análisis Wavelet y un modelo neuronal auto-regresivo no lineal NAR. Tecnura, Vol. 16, Edición Especial, pp. 86 – 99.

Muñoz, E., Seijas, C. (2015). Análisis comparativo de ajuste en entrenamiento de redes neuronales artificiales a partir de las librerías Open NN y ALGLIB. La Granja: Revista de ciencias de la vida. Vol. 21, No. 1, pp. 49-60.

Orozco, L., Lomeli, G., Moreno, G., Perea, M. (2015). Identification Inverted Pendulum System Using Multilayer and Polynomial Neural Networks. IEEE LATIN AMERICA TRANSACTIONS, Vol. 13, NO. 5, pp 1569-1576.

Ponce, J., (2017). Comparación entre varios métodos de pronóstico basados en series de tiempo para predecir la demanda de placas digitales en empresas del sector grafico Quiteño desde el año 2009 hasta el año 2015 (Tesis de Maestría). Facultad de Ciencias Administrativas, Escuela Politécnica Nacional. Quito. Ecuador.

Ponce, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería*. Alfaomega, 1° Edición, México.

Pucheta, J., Rodríguez, C., Herrera, M., Salas, C., Patiño, D., Kuchen, B. (2010). A Feed-Forward Neural Networks-Based Nonlinear Autoregressive Model for Forecasting Time Series. *Computación y Sistemas*. Vol 14. No. 4. pp. 423-435.

Rai, A., Upadhyay, S. (2017). The use of MD-CUMSUM and NARX neural network for anticipating the remaining useful life of bearings. *Measurement*. Vol. 111 (2017). pp. 397–410

Rodríguez, C. (2016). *Modelos no lineales de pronóstico de series temporales basados en inteligencia computacional para soporte en la toma de decisiones agrícolas*. (Tesis Doctoral). Facultad de Ciencias Exactas, Físicas y Naturales. Universidad Nacional De Córdoba. Córdoba. Argentina.

Sánchez, P. (2010). Problemas de investigación en la predicción de series de tiempo con redes neuronales artificiales. *Revista Avances en Sistemas e Informática*. Vol. 7, No. 3, pp. 67-73.

Sánchez, P. (2012). *Una nueva metodología de entrenamiento de redes neuronales y sus implicaciones en la selección de modelos*. (Tesis de Doctorado), Facultad de Minas, Escuela de Sistemas Doctorado en Ingeniería –Sistemas. Universidad Nacional de Colombia. Medellín, Colombia.

Santa Cruz R., Correa, C. (2017). Intermittent demand forecasting with time series methods and artificial neural networks: A case study. *Revista DYNA*, 84(203), pp. 9-16.

Suliman, A., Zhang, Y. (2015). A Review on Back-Propagation Neural Networks in the Application of Remote Sensing Image Classification. *Journal of Earth Science and Engineering* 5(2015), pp 52-65 doi: 10.17265/2159-581X/2015. 01. 004.

Velázquez, J., Zambrano, C., Vélez, L., (2011). ARNN: Un paquete para la predicción de series de tiempo usando redes neuronales autorregresivas. *Revista Avances en Sistemas e Informática*. Vol. 8. No. 2. Pp. 177-181.

Villada, F., Muñoz, N., García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información Tecnológica* Vol. 23(4), pp. 11-20.

Villazón-Bustillos, D., Rubio-Arias, H., Ortega-Gutiérrez, J., Rentería-Villalobos, M., González-Gurrola, C., Pinales-Munguía, A. (2016). Time series analysis to forecast drought in the northwest side of Chihuahua, Mexico. *Ecosistemas y Recursos Agropecuarios*. 3(9), pp.307-315.

Wang, J., Yang, G., Liu, S., Zurada, J. (2015). Convergence analysis of multilayer feedforward networks trained with penalty terms: a review. *JACSM* 2015, Vol. 7, No. 2, pp. 89-103.

## **4. Estimación de estados funcionales de procesos a partir de clasificación difusa de patrones**

### **Resumen**

En este capítulo se presenta el establecimiento de los estados funcionales de los sistemas de prueba a partir de la clasificación difusa de patrones. La implementación de la lógica difusa en el esquema de clasificación permite que un objeto pueda pertenecer, mediante un grado de pertenencia, a múltiples clases previamente definidas en la sintonización del clasificador. Se parte del histórico de datos de los procesos y se hace un preprocesamiento de la información eliminando información redundante. La información pre-procesada es utilizada para sintonizar el clasificador difuso de cada proceso. Las clases obtenidas son sometidas a un análisis gráfico multivariable. El análisis es además soportado por la experticia de los operadores del proceso para establecer los estados funcionales del sistema de producción de aire medicinal y de la planta de presurización de aire. El establecimiento de estados funcionales a partir de la clasificación difusa se presenta como una alternativa de la inteligencia artificial para la programación de acciones en la ingeniería de mantenimiento a partir del diagnóstico en los procesos.

### **4.1 Introducción**

Una de las alternativas para mantener la función de cualquier tipo de equipo o proceso es el monitoreo de sus variables críticas. Variables como la temperatura, corriente, voltaje, humedad u otras son monitoreadas constantemente en las plantas de procesos. Los datos en los sistemas de monitoreo son adquiridos por sensores instalados en puntos estratégicos. La instalación se hace fuera de línea para luego ejecutar pruebas en línea llevando el proceso a diferentes estados para diseñar la estrategia de diagnóstico o mejorar su desempeño cuando éste ya se encuentra implementado (Chuei y Chang, 2016). Cuando no se cuenta con sensores, la información puede ser extraída por modelos del proceso (Sarmiento, 2013). Los resultados del monitoreo son utilizados para apoyar la planeación del mantenimiento de las máquinas mediante acciones de tipo preventivas y predictivas, derivadas de los estados funcionales del sistema (Campuzano-Martínez, 2016). Las acciones correctivas no son programadas a partir del análisis de los valores de la medición de las variables críticas; el mantenimiento correctivo está asociado a la reparación de los equipos en el momento en que estos han fallado (Olarte *et al.*, 2010); por lo tanto, si se ha activado una acción correctiva ha sido porque en los resultados del monitoreo no se lograron definir los suficientes estados del proceso que anunciaran la falla. En consecuencia, el equipo operó hasta la pérdida de su función provocando tiempo de paro en el proceso.

La ingeniería ha permitido la optimización de las máquinas en cuanto a tamaño, costo y efectividad. Esta última en relación con la función para la que han sido diseñadas. Para esto, algunas máquinas en la industria cuentan con sistemas sofisticados de control. Sin embargo, el sistema de control se encarga solo de mantener la(s) salida(s) del proceso bajo un objetivo impuesto por el diseñador o el operador de la planta (Aguilar-Martín, 2007), menospreciando el nivel de monitoreo y diagnóstico del proceso (Gentil *et al.*, 2007), el cual permite establecer acciones de mantenimiento eficientes con el objetivo de mantener la funcionalidad del equipo. Por lo tanto, un buen sistema de control debe estar diseñado de manera que las variables controladas y manipuladas se mantengan en el punto de operación deseado y que además verifique que la función se cumple adecuadamente, incluido el diagnóstico de toda la maquinaria del proceso. Lo anterior a su vez debe estar asociado con el alcance que definen las organizaciones en relación con las estadísticas de CMD (Confiablez, Mantenibilidad y Disponibilidad) que finalmente se reflejan en disminución de gastos por mantenimiento y un alto nivel de seguridad en la producción (Mora, 2016).

El diagnóstico a partir de la clasificación se plantea como una herramienta para evaluar la aplicación de mantenimiento preventivo antes de la ocurrencia de un fallo (Corrales y Vázquez, 2013). En la clasificación de estados en grandes volúmenes de información los datos del proceso son clasificados y agrupados de acuerdo a la semejanza entre ellos. La lógica difusa combinada con la minería de datos genera clasificadores difusos. Esta combinación hace posible la clasificación de patrones, los cuales pertenecerán parcialmente a una o varias clases de acuerdo con un grado de pertenencia permitiendo de esta manera manejar el concepto de incertidumbre en la discriminación de los objetos a clasificar (Sarmiento, 2013). Las clases generadas en la agrupación de patrones adquieren propiedades cualitativas. Las propiedades son generalmente construidas por el operador experto de acuerdo con la clasificación. Las clases con su respectiva descripción cualitativa se transforman en estados funcionales del proceso. En el diagnóstico basado en clasificadores el operador define tantos estados como clases se obtengan y que tengan un significado válido en la dinámica del proceso. De esta manera, se definen estados de falla y estados intermedios que pueden brindar conocimiento del proceso y que se obtienen del historial de datos (Sarmiento *et al.*, 2013). En ese sentido, Hernández *et al.*, (2014) presentan una estrategia para el monitoreo inteligente de una planta de tratamiento de agua a partir de la aplicación de la lógica difusa, la clasificación no supervisada y las redes neuronales artificiales. Mediante la estrategia propuesta se obtienen los estados funcionales y un modelo no lineal del proceso. Los resultados indican mejoras en la calidad del agua para las siguientes etapas en la planta de producción de agua potable. En (Uribe e Isaza, 2012) los autores utilizaron la clasificación difusa y el conocimiento del experto para guiar la selección de variables en procesos industriales. La selección guiada permite reducir el conjunto de variables necesarias para representar la estructura intrínseca de los datos históricos del proceso necesitando solo de algunas variables para definir los estados funcionales del sistema. Sarmiento *et al.*, (2013) proponen la estimación de los estados funcionales de sistemas complejos con base en clasificación difusa. La estimación de estados funcionales es combinada con valores de

probabilidad y posibilidad permitiendo obtener un sistema predictor capaz de estimar el siguiente estado del proceso.

En este capítulo se usa la lógica difusa aplicada a la clasificación de patrones para la estimación de los estados funcionales de los procesos de prueba: sistema de producción de aire medicinal y planta de presurización de aire. Lo anterior es realizado a partir del histórico de las respuestas de ambos procesos, almacenado en bases de datos en formato (.txt). El capítulo se divide en las siguientes etapas: En la primera se describe la clasificación de patrones utilizada como estrategia en los esquemas de diagnóstico automático de procesos. En la segunda se describen las bases teóricas de la clasificación difusa. En la tercera se diseñan los clasificadores difusos a partir del agrupamiento de datos para los procesos de prueba. En la cuarta etapa se verifica el desempeño de los clasificadores, vía simulación del proceso a partir del clasificador diseñado y con histórico de datos no utilizados en la etapa de entrenamiento. En la quinta etapa se establecen los estados funcionales de los procesos de prueba. Finalmente se presentan las conclusiones derivadas del capítulo.

## **4.2 La clasificación en el diagnóstico automático de procesos**

Dentro de las técnicas útiles para realizar la tarea de diagnóstico automático, se tienen en cuenta los métodos que identifican estados funcionales por medio de técnicas de clasificación o agrupamiento (Sarmiento, 2013), (Rojas *et al*, 2008). La clasificación puede verse como una actividad que ocurre en dos etapas. La primera consiste en el entrenamiento y aprendizaje, mientras en la segunda se decide si un nuevo objeto es un posible miembro de una clase a partir de propiedades comunes (Lara, 2007). La clasificación permite discriminar estados funcionales y detectar estados normales de funcionamiento, estados de alarma y estados de falla en el diagnóstico del proceso (Ramírez, 2016).

### **4.2.1 Entrenamiento y reconocimiento**

En la etapa de entrenamiento o aprendizaje la selección de variables para el clasificador, al igual que la descripción e interpretación de las clases resultantes, pueden ser definidas con el apoyo del experto en el proceso. La selección de parámetros del clasificador se define en un proceso de ajuste de valores con base en el desempeño del clasificador ante los datos de entrenamiento, y fundamentalmente ante los datos de prueba (muestras no utilizadas en el entrenamiento) y de validación si se dispone de ellos. El análisis de las señales o variables frente a las clases obtenidas permite definir los estados funcionales del proceso a partir del conocimiento del experto. La eficiencia del clasificador depende del aprendizaje y puede ser evaluada mediante simulación, ingresando muestras conocidas (patrones de prueba) por el experto y que no fueron utilizadas durante el proceso de entrenamiento. La segunda etapa es denominada etapa de reconocimiento y tiene como objetivo reconocer la clase en la cual se ubica cada nueva muestra, y de acuerdo con ello el estado funcional actual del proceso. La Figura 30 muestra el esquema de diagnóstico utilizando esta técnica de clasificación.

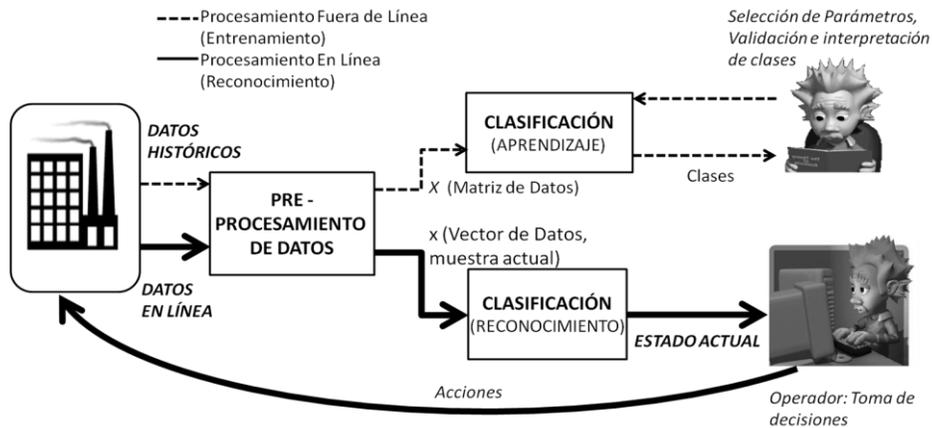


Figura 30. Esquema de diagnóstico con base en clasificadores.  
Fuente: (Sarmiento, 2013)

El principio del monitoreo de un proceso dinámico basado en clasificadores es el de determinar para cada muestra tomada su pertenencia a una de las clases obtenidas. A estas clases previamente les fue asociado un estado funcional o situación del sistema según el criterio y conocimiento del experto (operario de mantenimiento). Para la implementación (entrenamiento) del clasificador orientado al monitoreo se requieren los datos históricos disponibles representativos del proceso. Posteriormente, ante nuevos datos éste debe “decidir” a qué clases (estados funcionales) pertenecen (Sarmiento, 2013).

Los diferentes algoritmos de agrupamiento son clasificados, en lo que se referencia como la forma clásica, en dos principales tipos: algoritmos particionales/jerárquicos y algoritmos de pertenencia exclusiva/no exclusiva. Estos algoritmos de pertenencia exclusiva/no inclusiva, son también denominados de agrupamiento concreto/difuso. Los algoritmos de agrupamiento estricto o concreto son aquellos donde un objeto o muestra sólo puede pertenecer a un conjunto o clase (*Hard clustering*), y agrupamiento borroso o difuso (*Fuzzy clustering*) donde los objetos o muestras pueden pertenecer a más de un conjunto con un grado de pertenencia a cada partición.

Cuando un clasificador determina la clase de la muestra presentada en el instante ( $k$ ) se produce un diagnóstico a partir del análisis del estado funcional del proceso y de su descripción cualitativa previamente definida por el experto (Ramírez, *et al.*, 2017). Cualquier método de agrupamiento seleccionado deberá contar con información relevante del proceso. Para garantizar información representativa se debe realizar una optimización de datos de manera que se genere una nueva matriz de información a partir del preprocesamiento (Prada, 2009). Un esquema que representa la supervisión de procesos con base en clasificadores es presentado en la Figura 31.

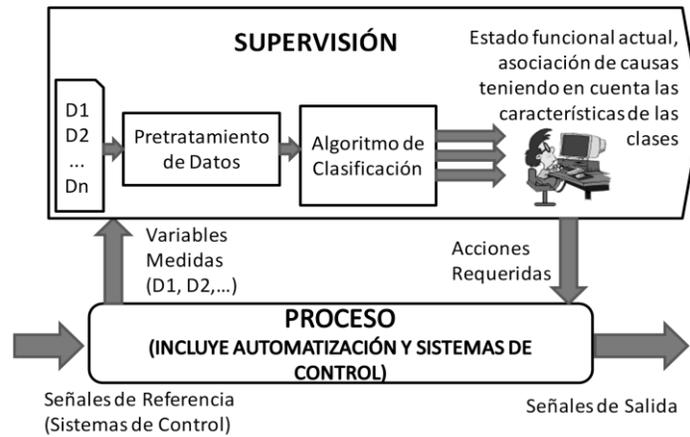


Figura 31. Esquema de supervisión con base en clasificadores.  
Fuente: (Sarmiento, 2013)

#### 4.2.2 Preprocesamiento de los datos

La matriz de datos históricos  $\mathbb{X}$ , dada por la ecuación (32) está conformada por  $n$  filas y  $m$  columnas. Cada fila  $n$  corresponde a un objeto  $x_i$ , el cual contiene los atributos (valores de las variables de los procesos) que diferencian cada fila de la matriz de datos. En general, un objeto es una muestra o patrón de las variables del proceso observadas en un instante  $k$  y almacenadas en el vector  $x_i(k)$ . El vector de datos  $x_i$  debe contener el conjunto de atributos o variables seleccionadas capaces de caracterizar cada objeto de la base de datos. Este vector también es conocido como vector característico (Lückeheide *et al.*, 2007).

$$\mathbb{X} = \begin{bmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,m} \\ a_{2,1} & a_{2,2} & \dots & a_{2,m} \\ \vdots & \vdots & \dots & \vdots \\ a_{i,1} & a_{i,2} & \dots & a_{i,m} \\ a_{n,1} & a_{n,2} & \dots & a_{n,m} \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_i \\ x_n \end{bmatrix} ; \rightarrow x_1 = [a_{1,1} \ a_{1,2} \ \dots \ a_{1,m}] \quad (32)$$

Una de las estrategias para pre-procesar el conjunto de datos se basa en el conocimiento y la experiencia del operador del proceso. La experiencia adquirida por el experto le da la capacidad para centrarse en un conjunto de datos en especial y eliminar información que resulte redundante. Otra estrategia consiste en la normalización de los datos. La normalización se sugiere para procesos en los cuales las magnitudes de las variables varían considerablemente, lo que puede hacer que las de mayor magnitud les resten importancia a otras de menor magnitud (Cuadrado, 2002; Lückeheide *et al.*, 2007). Una de las formas de llevar los datos a un rango reducido es mediante la normalización “*Min-Max*”, la cual consiste en transformar los datos a un rango entre  $[0,1]$ . Lo anterior se lleva a cabo aplicando la ecuación (33).

$$\mathbb{X}_{(j,i)} = \frac{\mathbb{X}_{(j,i)} - \text{Mínimo}(i)}{\text{Máximo}(i) - \text{Mínimo}(i)} \quad (33)$$

En esta ecuación,  $X_{(j,i)}$  es el atributo de la matriz de datos en la columna  $j$  y fila  $i$ ;  $Máximo(i)$  es el valor máximo del atributo de la fila ( $i$ ), y  $Mínimo(i)$  es el valor mínimo del atributo de la fila ( $i$ ). La ecuación (31) puede ser implementada en un ciclo iterativo que permita normalizar cada uno de los atributos de los objetos de la matriz de datos ( $X$ ). La matriz de datos resultante de la normalización puede ser utilizada para el entrenamiento del clasificador. Una vez los problemas asociados al escalamiento son eliminados, los atributos se trabajan en la nueva matriz en un mismo nivel de posibilidad para cada objeto de la base de datos adquirida del proceso.

### 4.2.3 Clasificación concreta (*Hard clustering*)

La clasificación concreta forma parte de los métodos que utilizan una función objetivo para discriminar los datos y agruparlos en una clase caracterizada por un punto central denominado centroide (Ghosh y Kumar, 2013). Durante el proceso iterativo cada elemento del arreglo de datos es evaluado minimizando la función objetivo. Existe una gran cantidad de algoritmos de agrupamiento con función objetivo del tipo concreto. Cada uno corresponde a una técnica de optimización diferente entre las que se encuentran: algoritmos iterativos, mapas auto organizados y algoritmos evolutivos, entre otros. En este caso se describe uno de los más representativos denominado *C-means*.

*C-means* (también con conocido como *K-means*) es un algoritmo iterativo en el cual un objeto  $x_i$  de la matriz de datos  $X$  solo puede pertenecer a una clase  $C_j$  limitada por un centroide  $c_j$  como se muestra en la Figura 32. Este clasificador concreto tiene como función objetivo minimizar la suma cuadrática de la distancia euclidiana, dada por la ecuación (34), entre los puntos y un prototipo o valor medio del conjunto (Bora y Gupta 2014; Rojas *et al.*, 2008).

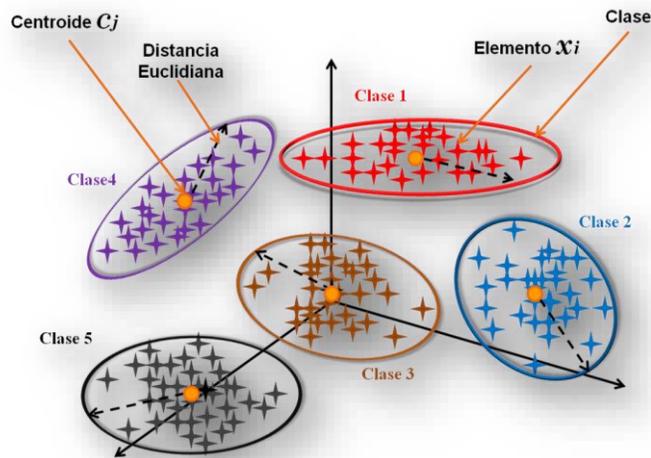


Figura 32. Representación gráfica de un clasificador C-means.  
Fuente: Elaboración propia.

$$J(U, v) = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - c_j\|^2 \quad (34)$$

Donde:

$J$  = Función Objetivo;  $U$  = Matriz de particiones (de valores binarios)

$v$  = vector de centro de las clases

$x_i^j$  = Muestra de los datos a evaluar (*fila* <sub>$i$</sub>  de la matriz de datos ( $\mathbb{X}$ ))

$c_j$  = Centroide de la clase

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

El diagrama de flujo para la implementación del algoritmo C means se muestra en la Figura 33 (Ghosh *et al.*, 2013), (Ponce, 2010). La condición  $2 \leq C \leq n$  permite definir más de una clase. Sí  $C = 1$  se asume que todos los datos pertenecen a un solo conglomerado y por lo tanto el algoritmo tendrá convergencia en una sola iteración. Los parámetros de entrada del algoritmo corresponden al número de clases que se desean encontrar a lo largo de la clasificación las cuales deben ser definidas para dar inicio al algoritmo (Ghosh *et al.*, 2013), (Rojas, 2008). Si bien el algoritmo C-means es uno de los más representativos, éste presenta algunos inconvenientes en la discriminación de patrones para casos específicos en los que  $n$  patrones diferentes de la matriz de datos  $\mathbb{X} = [x_1, x_2, x_3 \dots x_n]$  se ubiquen a una misma distancia del centroide ( $c_j$ ). En estos casos no existen criterios de desempate establecidos durante la ejecución del algoritmo y su convergencia estaría limitada sobre mínimos locales más que en un mínimo global. Lo anterior demuestra la principal desventaja del clasificador C-means; sin embargo, su aplicación fortaleció el estudio de alternativas que permitieran un grado de ambigüedad en la discriminación de patrones.

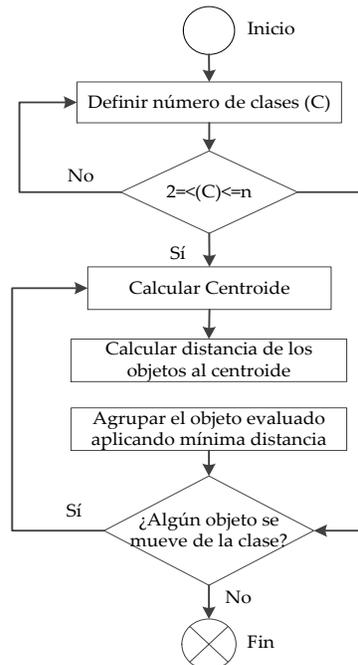


Figura 33. Diagrama de flujo del algoritmo *C-means*.

Fuente: Elaboración propia.

#### **4.2.4 Clasificación borrosa o difusa (*fuzzy clustering*)**

La lógica borrosa (también conocida como lógica difusa) es una propuesta que busca incorporar en los sistemas de ingeniería el conocimiento expresado en términos lingüísticos o expresiones verbales. De esta manera la lógica borrosa pretende emular la forma de razonamiento humano (Escalona *et al.*, 2013), en especial el grado de incertidumbre que trae consigo la descripción de percepciones humanas expresadas lingüísticamente por términos que carecen de exactitud y que permiten un grado de pertenencia entre diferentes clases. Mientras que en la lógica convencional un elemento  $A$  solo puede pertenecer mediante un grado de pertenencia  $\mu = \{0, 1\}$ ; (indicando solo dos valores de pertenencia mutuamente exclusivos, falso o verdadero) a un único conjunto  $X$ , en la lógica borrosa el elemento  $A$  puede pertenecer simultáneamente a los conjuntos  $X$  y  $Y$  de una colección de objetos  $U$ , mediante un grado de pertenencia  $\mu_{X(A)} = [0,1]$  y  $\mu_{Y(A)} = [0,1]$ . El grado de pertenencia  $\mu$  se encuentra en todo el intervalo continuo  $[0,1]$  (Jantzen, 2007) y se extiende en general para  $n$  elementos y  $m$  conjuntos mediante funciones de pertenencia. Una función de pertenencia se define como aquella aplicación que asocia a cada elemento de un conjunto borroso el grado con que pertenece al valor lingüístico asociado (Aguilar-Martín, 2007). Lo anterior permite expresar la pertenencia del elemento  $A$  a los conjuntos  $X$  y  $Y$  mediante la definición mostrada en la ecuación (35).

$$X = \{(A, \mu_{X(A)}) | A \in U\}; Y = \{(A, \mu_{Y(A)}) | A \in U\}; (\mu_{X(A)}) = [0,1]; (\mu_{Y(A)}) = [0,1] \quad (35)$$

En general, la lógica borrosa se estructuró a partir de la combinación de la lógica convencional y del razonamiento humano para establecer procedimientos durante su aplicación, la teoría de conjuntos, funciones de pertenencia, operaciones y demás requerimientos para su implementación se pueden encontrar en (Ponce, 2010; Jantzen, 2007; Aguilar-Martín, 2007; Espinosa *et al.*, 2005; Ojeda, 2010; Palma *et al.*, 2008). La lógica borrosa ha permitido la generalización de la lógica convencional o bivalente para admitir el razonamiento impreciso o bajo incertidumbre proporcionando un medio efectivo para concebir la naturaleza aproximada e imprecisa del mundo real (Gondres *et al.*, 2007).

La lógica borrosa ha conseguido en menos de medio siglo revolucionar la tecnología e impulsar la inteligencia artificial mediante la conjunción de los fundamentos matemáticos, la lógica y el razonamiento humano (Ojeda, 2010). El aporte de la lógica borrosa a la ingeniería de mantenimiento ha sido significativo, una muestra de sus aplicaciones se encuentra en diversos trabajos e investigaciones, *e.g.* (Sierra, *et al.*, 2013; Gondres *et al.*, 2007; Escalona *et al.*, 2003; Otero *et al.*, 2011; Ponce *et al.*, 2016; Ramírez *et al.*, 2007; Hernández *et al.*, 2015; Leiva, 2010, Niraj *et al.*, 2011; Felecia 2014).

La clasificación borrosa 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,

(Ojeda, 2010; Sarmiento, 2013). 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  $c_j$  como se muestra en la Figura 34. Lo anterior hace posible extender el espacio de búsqueda sujeto a pocas restricciones que permite mayor flexibilidad en la clasificación (Lara, 2007). Entre los algoritmos utilizados para la clasificación borrosa y que hacen uso de una función objetivo se encuentra el algoritmo *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 (36).

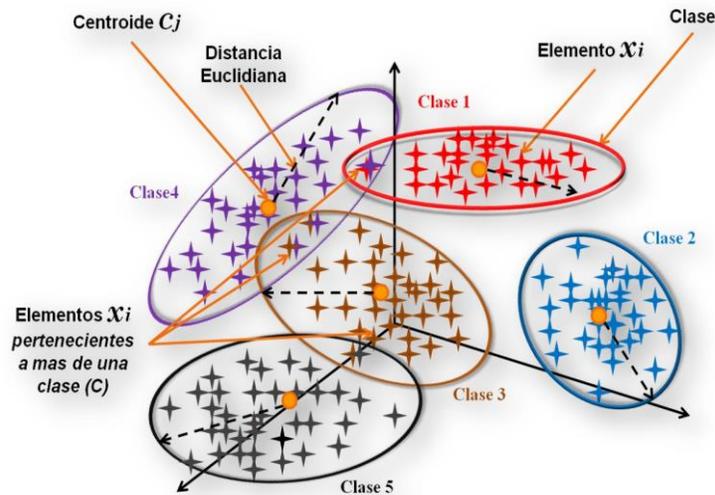


Figura 34. Representación gráfica de un clasificador *Fuzzy C-means*.  
Fuente: Elaboración propia.

$$J_m(U, v) = \sum_{i=1}^N \sum_{j=1}^C \mu_{ij}^m \|x_i - c_j\|^2 \quad (36)$$

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.

$\mu_{ij}$  = 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*  $i$ .

Los centroides de cada clase se calculan como se muestra en la ecuación (37).

$$c_j = \frac{\sum_{i=1}^N \mu_{ij}^m * x_i}{\sum_{i=1}^N \mu_{ij}^m} \quad (37)$$

Como el FCM es un algoritmo iterativo, la actualización de la matriz de particiones para cada iteración se calcula mediante la ecuación (38). 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 la ecuación (39).

$$u_{ij} = \frac{1}{\sum_{j=1}^c \left( \frac{\|x_i - c_j\|}{\|x_i - c_j\|} \right)^{\frac{2}{m-1}}} \quad (38)$$

$$\|U^{k+1} - U^k\| < e \quad (39)$$

El parámetro  $m$  es conocido como grado de fusividad y se le pueden asignar valores en el intervalo  $(0 \leq m \leq \infty)$ ; sin embargo, se recomiendan valores en el intervalo  $[0, 2]$  (Celemín, *et al.*, 2013). El diagrama de flujo para la implementación del algoritmo FCM se ilustra en la Figura 35 (Ghosh y Dubey, 2013; Ponce, 2010).

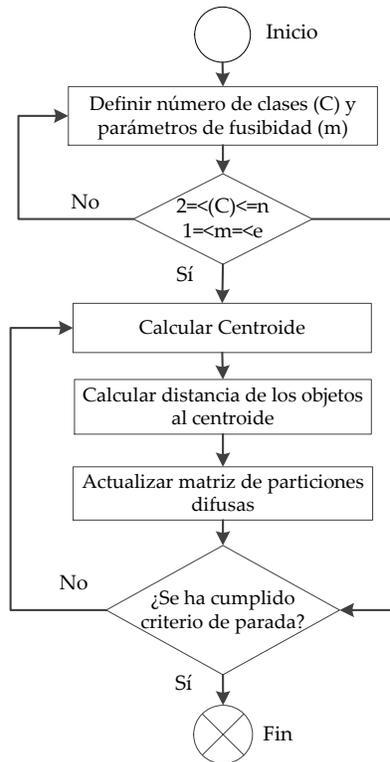


Figura 35. Diagrama de flujo del algoritmo FCM.  
Fuente: Elaboración propia.

En el diagnóstico automático de procesos implementando clasificadores, cada clase resultante de la convergencia del algoritmo es interpretada por un experto 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 sintonización de los clasificadores para los sistemas de prueba se realizó por medio de la aplicación *U-MeanS* (ver Figura 36) programada en Matlab® y diseñada por (Ramírez U., Jhon A); más información sobre el aplicativo se puede encontrar en (Ramírez, 2016).

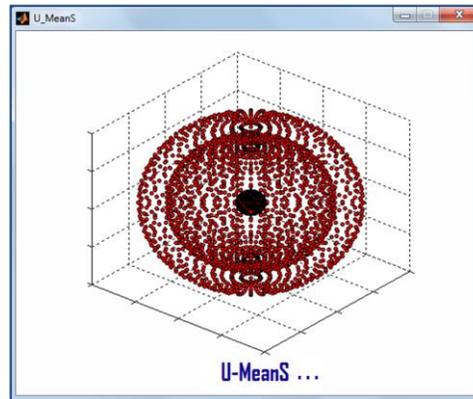


Figura 36. *About*, aplicación, *U-MeanS*  
Fuente: Elaboración propia.

### 4.3 Sintonización del clasificador FCM y establecimiento de los estados funcionales del sistema de producción de aire medicinal.

Para establecer los estados funcionales del sistema de producción de aire medicinal se sintonizó un clasificador FCM. Con el fin de mantener la relación con la predicción de la dinámica de las VPCPAM, se utilizó la misma base de datos empleada para la construcción de los modelos de predicción MRNAs-NAR; es decir, 5609 muestras (matriz [5609 x 4]), disponiendo de esta el 66% de datos para entrenamiento (3679 muestras) y el 34% de datos para prueba (1930 muestras). El objeto (vector característico) de la matriz de datos se muestra en la ecuación (40) y está conformado por la medición en el instante  $k$  de las VPCPAM. Cada variable medida corresponde a un atributo del objeto  $x_i$  como se indica en la ecuación (41).

$$x_{i(k)} = [PPMCO_{(k)} \quad TPR_{(k)} \quad HR_{(k)} \quad TA_{(k)}]; \quad k: \text{instante de medición}; \quad (40)$$

$$\text{Atributos}_{(k)} = PPMCO_{(k)}; TPR_{(k)}; HR_{(k)}; TA_{(k)} \quad (41)$$

En la ecuación (42) se pueden observar los 5 primeros objetos de la matriz de datos normalizada del sistema de producción de aire medicinal.

$$\mathbb{X} = \begin{bmatrix} 0.2404 & 0.3456 & 0.8234 & 0.1663 \\ 0.5490 & 0.3344 & 0.7897 & 0.1685 \\ 0.3769 & 0.3368 & 0.8135 & 0.1641 \\ 0.3086 & 0.3336 & 0.7716 & 0.1663 \\ 0.000 & 0.3368 & 0.8274 & 0.1641 \end{bmatrix} = \begin{bmatrix} \text{objeto normalizado } x_1 \\ \text{objeto normalizado } x_2 \\ \text{objeto normalizado } x_3 \\ \text{objeto normalizado } x_4 \\ \text{objeto normalizado } x_5 \end{bmatrix} \quad (42)$$

En el entrenamiento del clasificador, los centros fueron elegidos a priori para un total de 6 particiones en las que se encuentran los diversos estados funcionales asociados a cada clase y de acuerdo con el conocimiento de los expertos (operadores e ingeniero de mantenimiento) sobre el sistema de producción de aire medicinal. El esquema utilizado para el diseño del clasificador se muestra en la Figura 37.

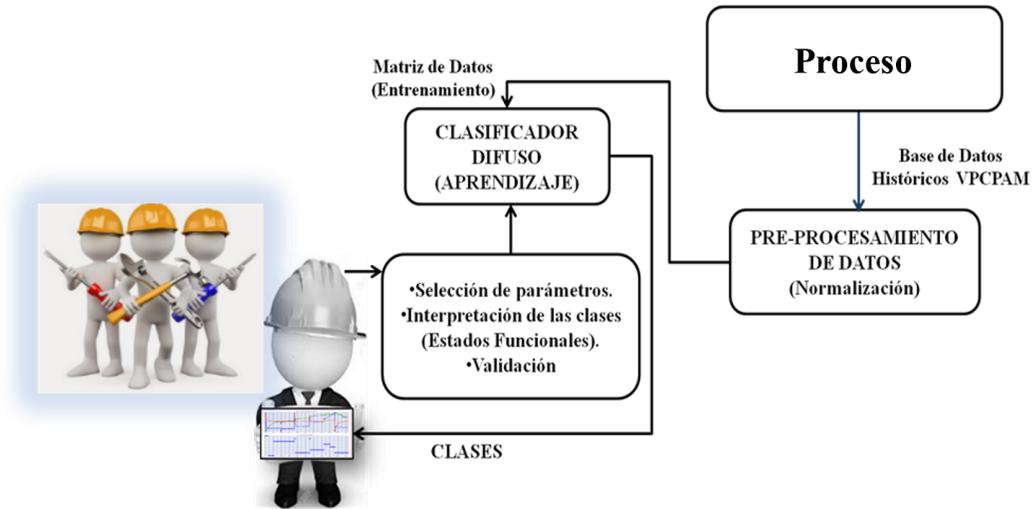


Figura 37. Esquema utilizado para entrenar el clasificador del sistema de producción de aire medicinal. Fuente: Elaboración propia.

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. En la figura 38 se ilustra la respuesta del histórico de datos y el comportamiento del clasificador sintonizado. 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 17.

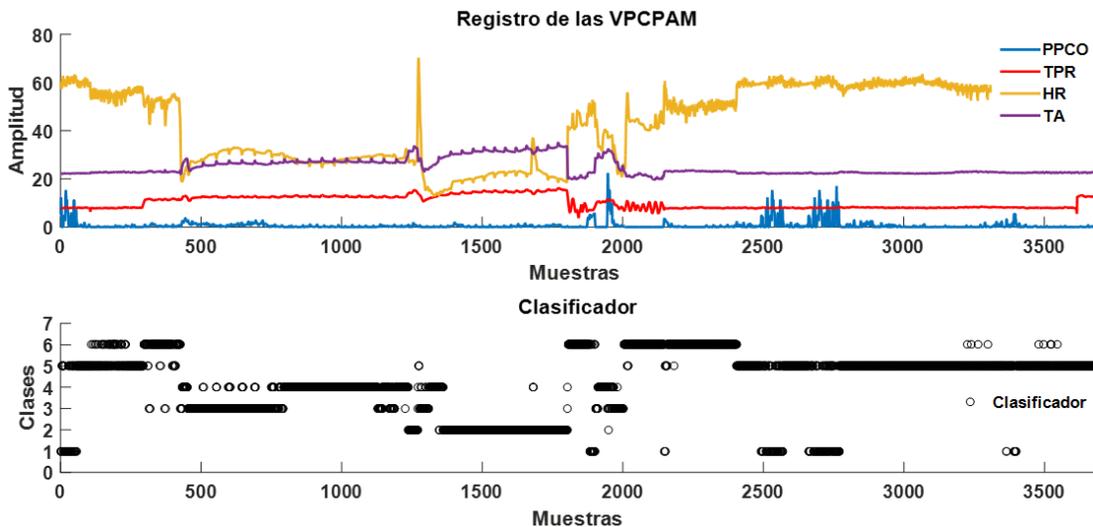


Figura 38. Respuesta gráfica de las VPCPAM y del clasificador sintonizado (entrenamiento) para el sistema de producción de aire medicinal.  
Fuente: Elaboración propia.

Tabla 17. 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.

Una ampliación de la respuesta del clasificador, entre las muestras 0 a 120 y 2400 a 2540 se presentan en las Figuras 39,40. En la Figura 39 se puede observar la transición entre clases, en este caso se muestra una transición entre la clase 1 y la clase 5, la cual se da al inicio de las muestras. Posteriormente, se evidencian varias transiciones entre la clase 5 y la clase 1, definidas respectivamente como estados de alarma y falla del sistema. Después de la muestra 58 se puede observar nuevamente una transición de la clase 1 a la clase 5, continuando después de la muestra 109 con una transición hacia la clase 6 (operación normal de las VCPAM). Por otro lado, en la Figura 40 se presenta una transición de la clase 6 a la clase 5 después de la muestra 2404, y transiciones posteriores entre las clases 5,1 y 1,5 como consecuencia de incrementos considerables en PPMCO y en la HR del sistema de producción de aire medicinal.

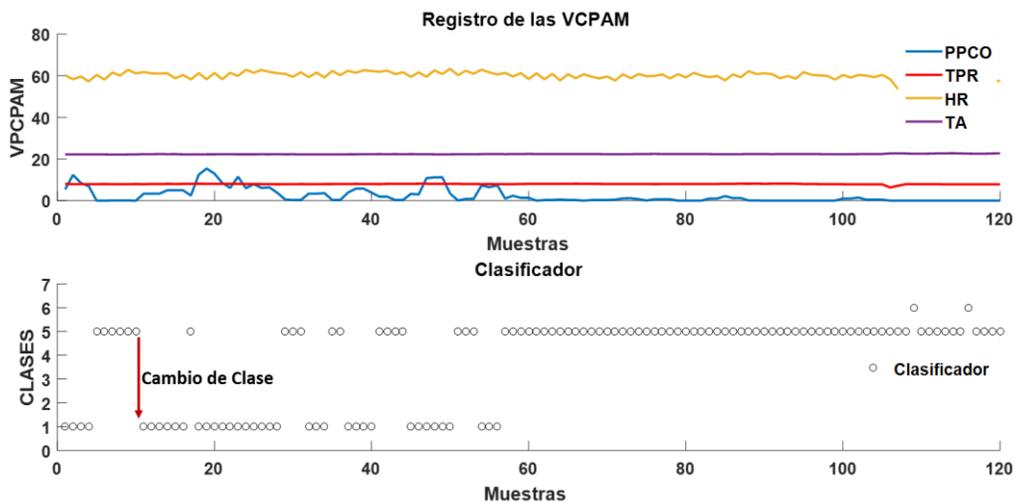


Figura 39. Respuesta gráfica de las VPCPAM y del clasificador sintonizado (entrenamiento) para el sistema de producción de aire medicinal. Ampliación entre 0 a 120 muestras.  
Fuente: Elaboración propia.

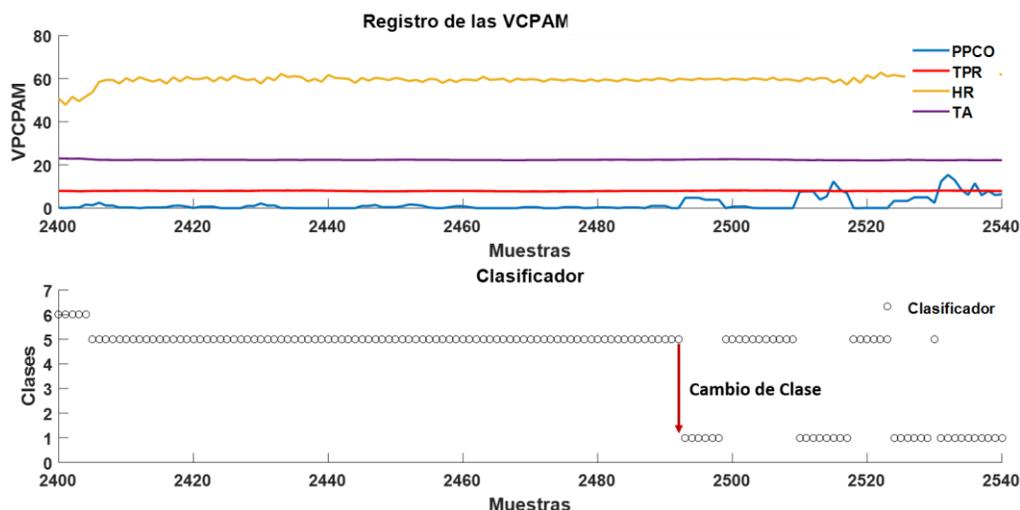


Figura 40. Respuesta gráfica de las VPCPAM y del clasificador sintonizado (entrenamiento) para el sistema de producción de aire medicinal. Ampliación entre 2400 a 2540 muestras.  
Fuente: Elaboración propia.

### 4.3.1 Validación de clases (estados funcionales) del sistema de producción de aire medicinal.

Se realizaron medidas de validez de las clases para la partición obtenida. Para ello se usaron el Coeficiente de Partición (*Partition Coefficient- PC*) y la Entropía de la Partición (*Partition Entropy – PE*) dados mediante las ecuaciones (43) y (44), respectivamente. Donde  $c$  es el número de clases,  $N$  el número de muestras y  $\mu$  el grado de pertenencia (Xie y Beni, 1991), (Villazana, *et al.*, 2012). Los resultados obtenidos de estos índices (presentados en la Tabla 18), 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).

$$PC(c) = 1/N \sum_{i=1}^c \sum_{j=1}^N \mu_{ij}^2 \quad (43)$$

$$PE(c) = -1/N \sum_{i=1}^c \sum_{j=1}^N \mu_{ij} \log_2(\mu_{ij}) \quad (44)$$

Tabla 18. Medidas de validez de partición difusa

Índice de Validación	Resultado	Mínimo Posible	Máximo Posible
Coeficiente de Partición	0,667	$Min = \frac{1}{c}$	1

		0,1667	
Entropía de la Partición	0,9796	0	$\frac{Max = \text{Log}_2(c)}{2,585}$

### 4.3.2 Evaluación del clasificador

La evaluación tiene como objetivo determinar el grado de generalización del clasificador obtenido ante muestras no utilizadas durante el entrenamiento. Durante esta etapa se presentan los datos de prueba al clasificador (1930 muestras), se analiza la clasificación generada a partir de la matriz final de centros obtenida en el entrenamiento dada por la ecuación (45); y se discrimina el objeto presentado  $x_i$  del instante  $k$  en una de las seis clases  $C_j = 1, 2, 3, 4, 5, 6$ .

$$v = \begin{bmatrix} 0.2580 & 0.0156 & 0.0395 & 0.0117 & 0.0124 & 0.0107 \\ 0.3562 & 0.8831 & 0.6893 & 0.7126 & 0.3506 & 0.3539 \\ 0.8085 & 0.1539 & 0.3073 & 0.2599 & 0.7944 & 0.6230 \\ 0.1779 & 0.7923 & 0.4236 & 0.4867 & 0.1879 & 0.2006 \end{bmatrix} \quad (45)$$

En la Figura 41 se ilustra la respuesta gráfica de la evaluación del clasificador, en una ampliación de las muestras 1590 a 1700. En la respuesta se muestra reconocimiento de todas las clases de acuerdo con el estado cualitativo asociado: estado de falla 1 con transición hacia el estado de alerta 3 y 4, y transiciones entre el estado 3 y el estado funcional 6, este último correspondiente a la operación normal del sistema de producción de aire. Mediante la observación y análisis detallado de las variables dinámicas del proceso se verificó la acertada clasificación de todos los estados funcionales presentes, es decir un desempeño de clasificador del 100% en las 1930 muestras.

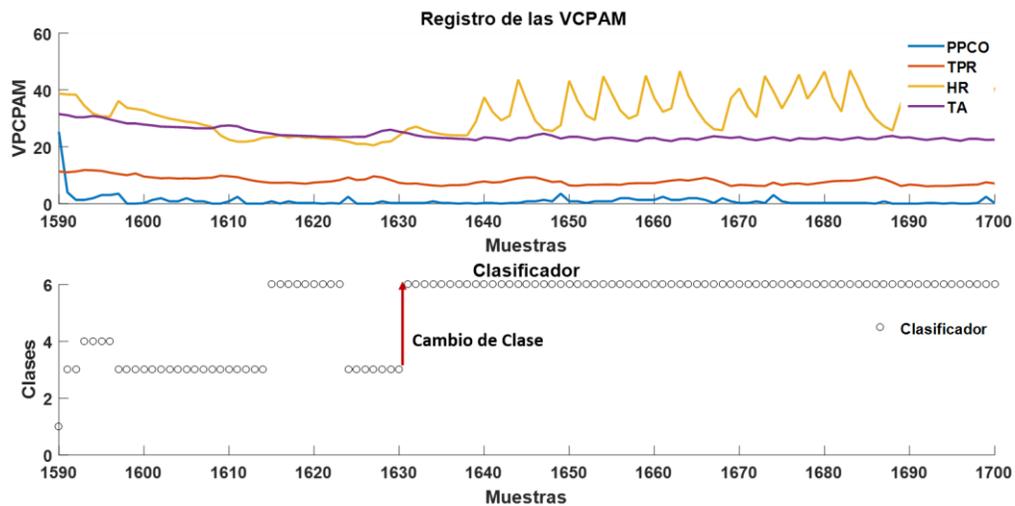


Figura 41. Respuesta gráfica de prueba del clasificador, ampliación entre 1590 a 1700 muestras.  
Fuente: Elaboración propia.

#### **4.4 Sintonización del clasificador FCM y establecimiento de los estados funcionales de la planta de presión**

Para sintonizar el clasificador, se utilizó la base de datos implementada durante la construcción de los modelos de predicción, eliminando la columna correspondiente a la variable exógena (LC) de las demás variables de la planta de presión. Los datos utilizados se organizaron en una matriz de 4105 muestras por 3 columnas; disponiendo de esta del 80% de datos (3400 muestras) para entrenamiento y el 19% de datos para evaluación (805 muestras). El vector característico de la matriz de datos se muestra en la ecuación (46). Cada variable medida corresponde a un atributo del objeto  $x_i$  como se indica en la ecuación (47).

$$x_{i(k)} = [VC_{(k)} \quad EC_{(k)} \quad TD_{(k)}]; \quad k: \text{instante de medición}; \quad (46)$$

$$\text{Atributos}_{(k)} = VC_{(k)} \quad EC_{(k)} \quad TD_{(k)} \quad (47)$$

En la ecuación (48) se pueden observar los 5 primeros objetos de la matriz de datos normalizada de las variables de la planta de presión. En el entrenamiento del clasificador, los centros fueron elegidos a priori para un total de 6 particiones en las que se encuentran los diversos estados funcionales asociados a cada clase y de acuerdo con el conocimiento del experto sobre la planta de presión. El esquema utilizado para el diseño del clasificador fue el mismo implementado para el establecimiento de los estados funcionales del sistema de producción de aire medicinal.

$$\mathbb{X} = \begin{bmatrix} 0 & 0.4253 & 0 \\ 0 & 0.4253 & 0.0196 \\ 0 & 0.4253 & 0.0196 \\ 0 & 0.4253 & 0.0196 \\ 0 & 0.4253 & 0.0196 \end{bmatrix} = \begin{bmatrix} \text{objeto normalizado } x_1 \\ \text{objeto normalizado } x_2 \\ \text{objeto normalizado } x_3 \\ \text{objeto normalizado } x_4 \\ \text{objeto normalizado } x_5 \end{bmatrix} \quad (48)$$

Los estados funcionales de la planta de presión se obtuvieron a partir del análisis de los resultados gráficos del clasificador. En la Figura 42 se ilustra la respuesta del histórico de datos y el comportamiento del clasificador sintonizado. El análisis gráfico multivariable y la experticia del operador del proceso permitieron establecer los estados funcionales reportados en la Tabla 19.

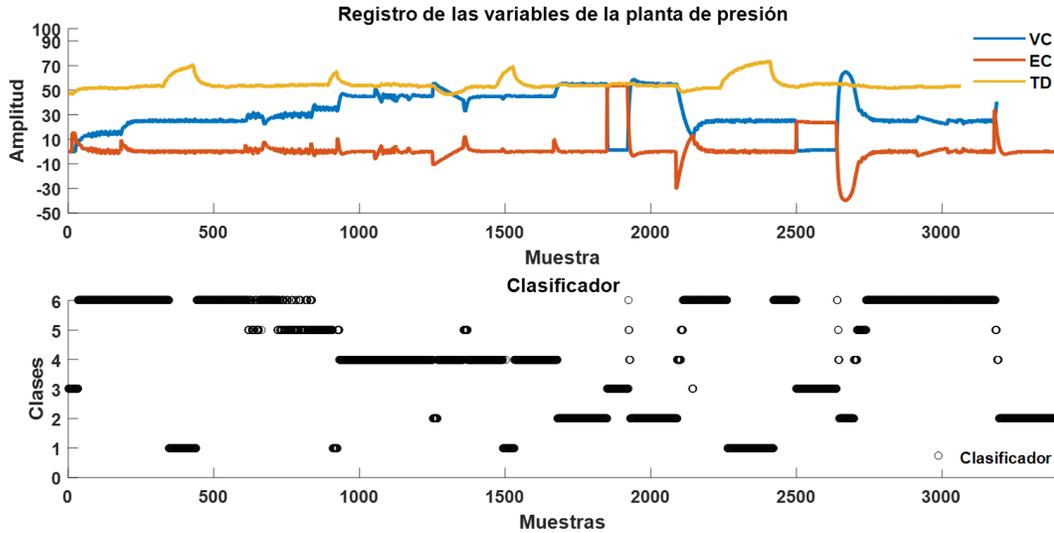


Figura 42. Respuesta gráfica de las variables de la planta de presión y del clasificador sintonizado (entrenamiento).

Fuente: Elaboración propia.

Tabla 19. 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 <i>driver</i> 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 ( <i>Set Point</i> : 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 ( <i>Set Point</i> : 15% a 25%)

En las Figuras 43-44 se ilustra la respuesta gráfica del histórico de datos y el comportamiento del clasificador sintonizado, en una ampliación de las muestras 345 a 638 y 1845 a 2000 respectivamente. En la Figura 43 se pueden observar transiciones entre la clase 6 y la clase 1. Posteriormente, se evidencian varias transiciones entre las clases 6 y 5. Por otro lado, en la Figura 42 se presenta una transición de la clase 2 a la clase 3 después de la muestra 1850, y transiciones posteriores entre las clases 3,6,5,4 y 2, como consecuencia de la recuperación del controlador, después de estar en estado de falla desde la muestra 1851 hasta 1892, con fuga considerable reflejada en despresurización total del tanque de almacenamiento.

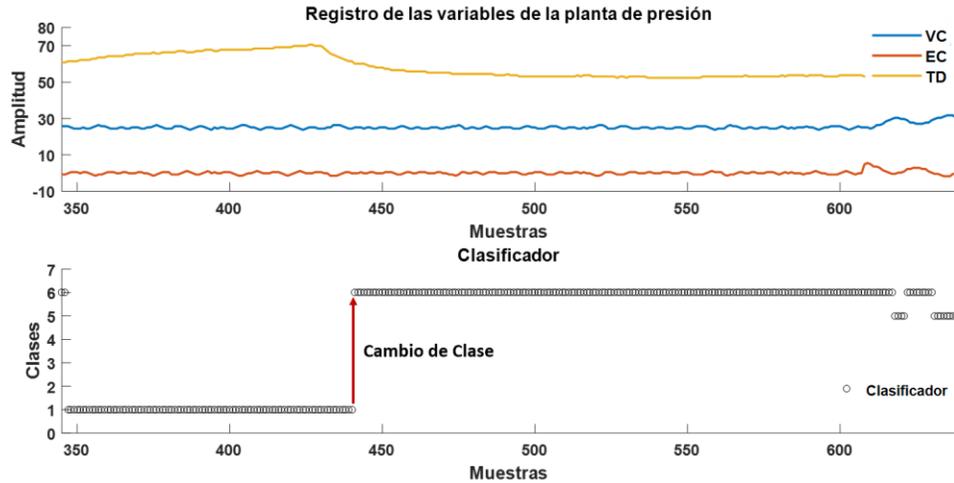


Figura 43. Respuesta gráfica de las variables de la planta de presión y del clasificador sintonizado (entrenamiento). Ampliación entre 345 a 638 muestras.  
Fuente: Elaboración propia.

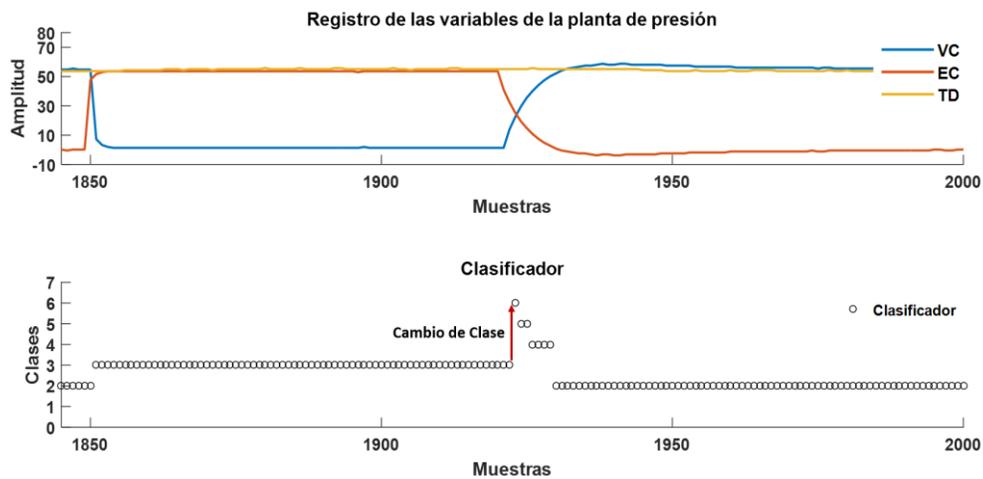


Figura 44. Respuesta gráfica de las variables de la planta de presión y del clasificador sintonizado (entrenamiento). Ampliación entre 1845 a 2000 muestras.  
Fuente: Elaboración propia.

#### 4.4.1 Validación de clases (estados funcionales) de la planta de presión.

Los resultados obtenidos de los índices PC y PE se presentan en la Tabla 20, donde los valores obtenidos dan cuenta del número válido y acertado de clases (C1 a C6).

Tabla 20. Medidas de validación de partición difusa

Índice de Validación	Resultado	Mínimo Posible	Máximo Posible
Coefficiente de Partición	0,746	$\frac{1}{c}$ 0,1667	1

Entropía de la Partición	1,127	0	$\frac{Max = Log_2(c)}{2,585}$
--------------------------	-------	---	--------------------------------

#### 4.4.2 Evaluación del clasificador

Para evaluar el clasificador se utilizaron 805 muestras equivalentes al 19% de datos fuera de muestra. Se implementó la matriz final de centros obtenida en el entrenamiento dada por la ecuación (49) y se discriminó cada objeto presentado  $x_i$  del instante  $k$  en una de las seis clases  $C_j = 1, 2, 3, 4, 5, 6$ .

$$v = \begin{bmatrix} 0.4392 & 0.9029 & 0.0321 & 0.6973 & 0.5249 & 0.3756 \\ 0.4254 & 0.4245 & 0.7154 & 0.4192 & 0.4221 & 0.4309 \\ 0.6367 & 0.2406 & 0.2130 & 0.1994 & 0.2086 & 0.1717 \end{bmatrix} \quad (49)$$

En la Figura 45 se ilustra la respuesta gráfica de la evaluación del clasificador, en una ampliación de las muestras 120 a 350. En la respuesta se muestra reconocimiento de las clases de acuerdo con el estado cualitativo asociado, en este caso transiciones entre estado de alerta (clase 2) y estados de falla (clase 3). Mediante la observación y análisis detallado de las variables dinámicas del proceso se verificó la acertada clasificación de todos los estados funcionales presentes, es decir un desempeño de clasificador del 100% en las 805 muestras.

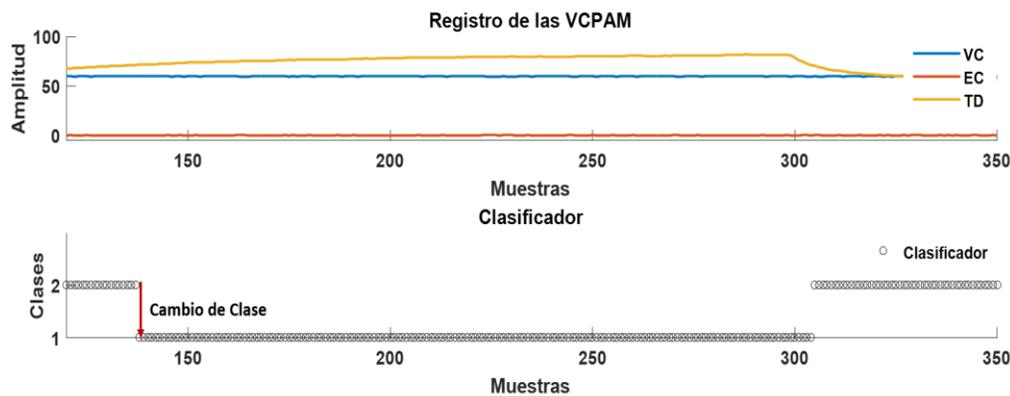


Figura 45. Respuesta gráfica de prueba del clasificador, ampliación entre 120 a 350 muestras.  
Fuente: Elaboración propia.

#### 4.5 Conclusiones

En este capítulo se presentó la estimación de los estados funcionales de los procesos de prueba a partir de la clasificación difusa de patrones. Los clasificadores fueron diseñados integrando la lógica difusa y el historial de datos de los procesos, y se validaron mediante índices como el coeficiente de la partición y entropía de la partición. Ambos índices validaron los clasificadores de acuerdo con el máximo y mínimo permitido por cada coeficiente.

La etapa de evaluación de los clasificadores entrenados permitió determinar el grado de generalización del clasificador ante objetos no utilizados en la etapa de entrenamiento. Los resultados en la etapa de evaluación mostraron reconocimiento de todas las clases de acuerdo con el estado cualitativo asociado. Lo anterior sumado a la verificación de los índices de validación, se utilizó como criterio de aceptación de los clasificadores diseñados, para la estimación de los estados funcionales de los sistemas de prueba.

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.

#### **4.6 Referencias bibliográficas**

Aguilar-Martín J. (2007). Inteligencia artificial para la supervisión de procesos industriales, 1ª edición, ULA, Mérida-Venezuela.

Bora, D. y A. Gupta. (2014). "A comparative study between fuzzy clustering algorithm and hard clustering algorithm," International Journal of Computer Trends and Technology (IJCTT), 2(10), pp. 108-113.

Celemín, C.; H. Martínez y M. Melgarejo. (2013). Sintonización de clasificadores difusos por medio de algoritmos genéticos inicializados en FCM, Ingeniería y Competitividad, 1(5), pp. 9-20.

Chuei W. C., Chang T. (2016). "Timed-automata based method for synthesizing diagnostic tests in batch processes," Computers & Chemical Engineering, Vol. 84, no 4, pp. 12–27.

Corrales, L., y Vázquez, A. R., (2013). Clasificación de fallas con redes neuronales para grupos electrógenos," Ingeniería Energética, Vol. 34, no 2/2013, pp. 137-150.

Escalona, L.W.; C.J. Jiménez; A.J. Ferrera y F.J. Arteaga. (2013). Diseño de un sistema para la detección de fallas en planta compresora con mantenimiento centrado en confiabilidad usando lógica difusa, Ingeniería UC, 1(10), pp. 1-9.

Espinosa, J., Vandewalle, J., Wertz, V. (2005). "Fuzzy logic, Identification and Predictive control," Springer, Verlag, London.

Felecia. (2014). Fuzzy Logic Reliability Centered Maintenance. Jurnal Teknik Industri/JTI, Vol. 16, no. 2, pp. 121-126.

Ghosh, S. y S.K. Dubey, *Comparative Analysis of K-means and Fuzzy C-means Algorithms*, International Journal of Advanced Computer Science and Applications, 4(4), 35-40 (2013).

Gentil S., Celse B., Charbonnier S., Cocquempot V., Hamelin F., Lesecq S., Maquin D., Montmain J., Ragot J. y Sauter D. (2007). *Supervision des Procédés Complexes*, Lavoisier.

Gondres, I., Lajes, S., Rodríguez N., y Serpa, A. del C. (2007). Utilización de la lógica difusa en la gestión del mantenimiento: caso de estudio. Universidad Tecnológica de Pereira, *Scientia et Technica*, no 34, pp. 25-30.

Jantzen, J. (2007). *Foundation of fuzzy control*, John Wiley & Sons Ltd., Chichester, England.

Hernández, H.R. ; J.L. Camas ; A. Medina ; M. Perez y V. Le Lann. (2014). *Fault Diagnostic by Lambda methodology applied to drinking water plant*, IEEE Latin America Transactions, 12(6), pp. 985-990.

Lara, O. J. (2007). Nuevas metodologías no invasivas de diagnóstico de defectos incipientes en rodamientos de bola. PH.D. tesis, Universidad Carlos III de Madrid, Madrid, España.

Leiva, J. (2010). Sistema experto “KALMA” para el mantenimiento preventivo correctivo en la red telefónica peruana. MSc tesis. Universidad Nacional de Ingeniería, Lima, Perú.

Lückeheide, S., Velásquez, J., y L. Cerda. (2007). Segmentación de los contribuyentes que declaran IVA aplicando Herramientas de Clustering. *Revista Ingeniería de Sistemas*: 21, pp. 87-110.

Mora, A., “Mantenimiento industrial efectivo,” Edición 2016, Editorial COLDI LTDA., mayo, 2016.

Niraj, M., Kumar, P. (2011). Selection of maintenance practice through fuzzy logic based simulation in TPM. *International Journal of Scientific & Engineering Research*, Vol.2, no. 8, pp. 1-5.

Ojeda, B., (2010). Aportación a la extracción de conocimiento aplicada a datos mediante agrupamiento y sistemas difusos, Tesis de Doctorado, Escuela Técnica Superior de Ingenieros de Telecomunicación, Universidad Politécnica de Madrid, Escuela Técnica Superior de Ingenieros de Telecomunicaciones, Madrid, España.

Olarte, W., Botero, M., y B. Cañón, (2010). Técnicas de mantenimiento predictivo utilizadas en la industria. *Scientia et Technica*: 45, pp. 223-226.

Palma, J., Marín, R. (2008). “Inteligencia artificial,” Mc Graw Hill, 1º Edición, Madrid- España

Ramírez J, A. (2016). Diagnóstico Inteligente de las Variables para el Control de Calidad de la Producción de Aire Medicinal del Hospital Manuel Uribe Ángel. Monografía para obtener título de Especialista en Gerencia de Mantenimiento, Universidad de Antioquia, Medellín, Colombia.

Ramírez, J., Sarmiento, H., López J. (2017). Diseño de un Clasificador Difuso para el Establecimiento de los Estados Funcionales de un Sistema de Producción de Aire Medicinal. Revista Información Tecnológica, 28(6), pp. 147-160.

Rojas, J., Chavarro, J., Moreno, R. (2008). Técnicas de lógica difusa aplicadas a la minería de datos,” Universidad Tecnológica de Pereira, *Scientia et Technica*, Vol. 3, no 40, pp. 1-6.

Ponce, P. (2010). Inteligencia artificial con aplicaciones a la ingeniería. Alfaomega, 1° Edición, México.

Prada, M. (2009). Técnicas de extracción del conocimiento basadas en data mining visual para la supervisión de procesos industriales. Análisis de la dinámica basado en mapas auto-organizados. PH. D tesis, Universidad de León, España.

Sarmiento, H. (2013). Metodología para el establecimiento y ponderación automática de conexiones entre estados funcionales de un proceso como herramienta para el diagnóstico y la predicción de fallos. (Tesis de Doctorado), Departamento de Ingeniería, Universidad de Antioquia, Medellín, Colombia.

Sarmiento, H., Isaza, C., Kempowsky, T. (2013). Estimación de estados funcionales en procesos complejos con base en agrupamiento difuso. Información Tecnológica, 2(24), pp. 79-98.

Sierra, E., Lajes, S., Filiberto, Y., Barrios, F. (2013). Modelo difuso para la determinación del período de mantenimiento de redes eléctricas, a partir de los datos de celaje. Revista Dyna, Vol. 80, no 181, pp. 1-15.

Uribe, C. y C. Isaza. (2012). Selección de variables guiada por conocimiento del experto para el monitoreo basados en datos de procesos industriales. Revista Facultad de Ingeniería Universidad de Antioquia, 65, pp. 122-125.

Xie, X.L. y G.A., Beni. (1991). *Validity measure for fuzzy clustering*, IEEE Trans. PAMI, 3(8), pp. 841-846.

Villazana, S., Arteaga, F., Seijas, C., Rodríguez, O. (2012). Estudio Comparativo entre Algoritmos de Agrupamiento Basado en SVM y C-medios Difuso-Aplicados a Señales Electrocardiográficas Arrítmicas. Revista Ingeniera UC, Vol. 19, No. 1, pp. 16-25.

## **5. Predicción de estados funcionales de procesos mediante MRNAs NAR/NARX y clasificación difusa**

### **Resumen**

En este capítulo se presentan los resultados del esquema de supervisión inteligente propuesto para los dos sistemas de prueba. Se describe como se combinó la predicción mediante MRNAs-NAR/NARX con el clasificador difuso para obtener la predicción de los estados funcionales del proceso. Se muestran los resultados gráficos, los análisis respectivos y la programación de acciones de control y mantenimiento a partir de la predicción de los estados funcionales.

### **5.1 Introducción**

Para intervenir los procesos, antes de la ocurrencia de una falla se hace necesario diseñar estrategias predictivas apoyadas en la experticia de los operadores. La IA se presenta como una alternativa que permite adicionar el conocimiento de los operadores en esquemas de diagnóstico automático de procesos. Dentro de la IA la clasificación difusa y las MRNAs son estrategias que se diseñan bajo la experiencia y el registro histórico de la dinámica de los procesos, a la vez que admiten las no linealidades y la incertidumbre presente en las variables de los procesos.

En este trabajo la clasificación difusa se utilizó para establecer los estados funcionales de los sistemas de prueba dentro de un esquema de supervisión. Además, se implementaron MRNAs NAR/NARX para la predicción de variables. Corresponde ahora combinar ambas estrategias para predecir los estados funcionales de los sistemas de prueba, con el fin de anticipar la transición de los procesos hacia estados de falla. Predecir el comportamiento dinámico de los procesos presenta dos ventajas. La primera es que se garantizan las condiciones funcionales de las máquinas, manteniendo a su vez la continuidad en los procesos. La segunda ventaja es que, mediante la predicción de estados de falla se pueden generar acciones que brinden seguridad a los operarios, y en general a las organizaciones ante el pronóstico de estados catastróficos.

El capítulo se divide en las siguientes etapas: En la primera se describe el esquema propuesto para la predicción de estados funcionales. En la segunda se presentan los resultados de la implementación del esquema de predicción sobre los procesos de prueba. En la tercera etapa se establecen las acciones de mantenimiento y control a partir de la predicción de los estados funcionales. Finalmente, se presentan las conclusiones derivadas del capítulo.

## 5.1 . Esquema de supervisión inteligente para el diagnóstico automático de procesos mediante MRNAs NAR/NARX y clasificación difusa para la programación de acciones de mantenimiento y control.

La figura 46 muestra el esquema propuesto de supervisión inteligente para el diagnóstico automático de procesos. 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 son analizadas por el grupo de operadores e ingenieros en las industrias, para la posterior programación de acciones de mantenimiento y control que permitan llevar los procesos a las condiciones normales de funcionamiento. Lo anterior permite mantener la confiabilidad del sistema, garantizar la seguridad de los operarios, minimizar los costos por mantenimiento al evitar la transición de los procesos hacia estados de falla; y mantener la producción continua minimizando tiempos de paro.

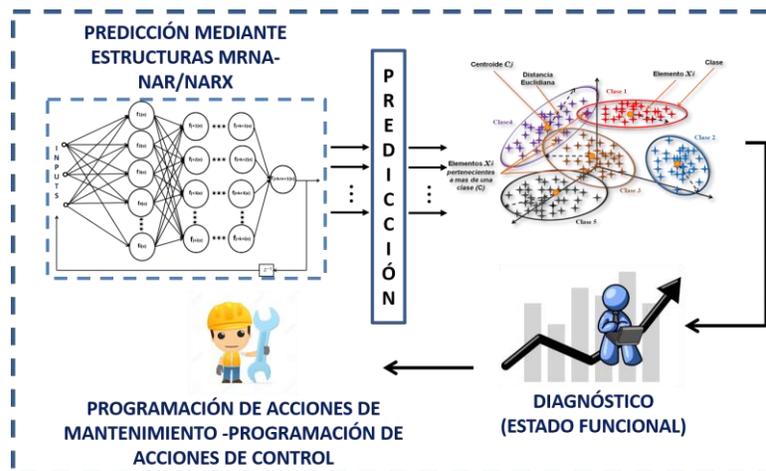


Figura 46. Esquema de supervisión inteligente para el diagnóstico automático de procesos mediante MRNAs y clasificación difusa para la programación de acciones de control y mantenimiento.

Fuente: Elaboración propia.

### 5.1.1 Predicción de estados funcionales y programación de acciones de mantenimiento para el sistema de producción de aire medicinal.

Para la predicción de estados funcionales del sistema de producción de aire medicinal, se implementaron a partir de las estructuras neuronales 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 diseño.

Los resultados obtenidos a partir del esquema de supervisión inteligente para el diagnóstico automático del proceso de producción de aire medicinal se muestran en las Figuras 47-49. A continuación se analizan las respuestas mediante la ampliación de las muestras con dinámicas importantes observadas en los resultados gráficos.

En la Figura 47 se observa entre la muestra 5 a la 8 de la base de datos usada para entrenamiento, el comportamiento del predictor sobre el estado funcional de alerta (clase 5), solo hasta la muestra 9 el clasificador difuso detectó el cambio de clase, es decir que la transición fue predicha acertadamente con 4 muestras atrás. En la muestra 11 el predictor detectó cambio de clase (estado funcional 5 a 6) con tres muestras de anticipación; sin embargo, en la muestra 14 detectó una transición nuevamente a la clase 5 (ver gráfico remarcado con óvalo rojo). En el caso anterior se ganó la predicción un paso por parte del predictor al detectar incremento considerable en las PPMCO, superando el cambio observado por el clasificador en la variable HR, para el mismo instante de muestreo. Caso similar se presentó en la muestra 21 en la que el predictor no cambió hacia la clase 5 (ver óvalo negro). El predictor no detectó un cambio considerable en la HR, pero sí en las PPMCO. En la muestra 26 el predictor detectó transición de la clase 1 a la clase 5, manteniendo la predicción de 7 muestras antes de ser detectadas por el clasificador. En la muestra 34, el predictor nuevamente detectó transición hacia el estado de falla (clase 1) con dos muestras de anticipación, retornando nuevamente a la clase 5 con solo una muestra predicha (ver gráfico remarcado con óvalo verde). Lo anterior fue ocasionado de acuerdo con el rápido comportamiento de las PPMCO. Analizando el registro de las PPMCO entre las muestras 33 a 40, se evidencia que dicha dinámica es ocasionada por la liberación del lote de producción de aire, cada miércoles de cada semana. Día en el cual se inyecta monóxido de carbono para comprobación del sistema de corte de acuerdo con las BPM, situación que se tendrá en cuenta para la programación de actividades de mantenimiento.

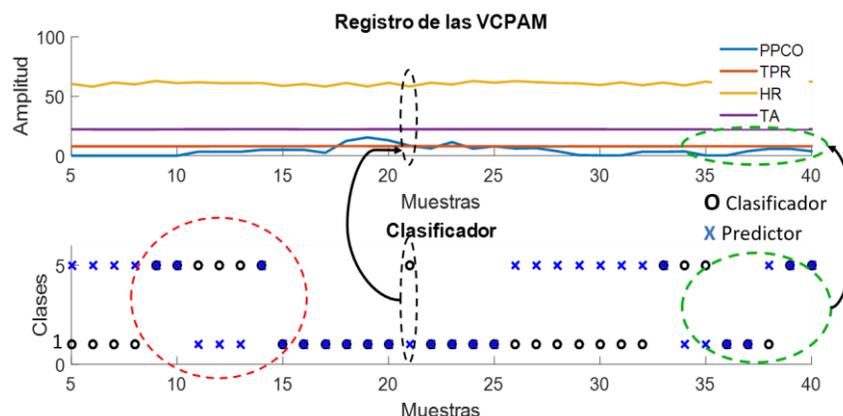


Figura 47. Evolución de los estados funcionales (clases) según clasificador y predictor. Base de datos de entrenamiento, ampliación entre muestras 5 a 40.

Fuente: Elaboración propia.

La figura 48 corresponde a una ampliación de las muestras 355 a 460 de la base de datos usada en el entrenamiento del clasificador, se puede observar como el predictor en la muestra 357 y 367 evita la transición del estado funcional (clase 6) hacia el estado funcional de falla (clase 5) (ver óvalo rojo), al igual que en las muestras 377-378, la transición hacia el estado funcional (clase 3) (ver óvalo verde), ambas clases 5 y 3 asociadas con estados funcionales relacionados con cambios en la HR. Aunque la clasificación no corresponde a la generada por el clasificador entrenado, se observa una cualidad importante detectada hasta ahora en las respuestas de las figuras 46 y 47, y es la capacidad de filtración del predictor y la respuesta ante verdaderos cambios en la humedad relativa (inferiores a 40%HR y superiores 70% HR). Lo anterior se considera 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.

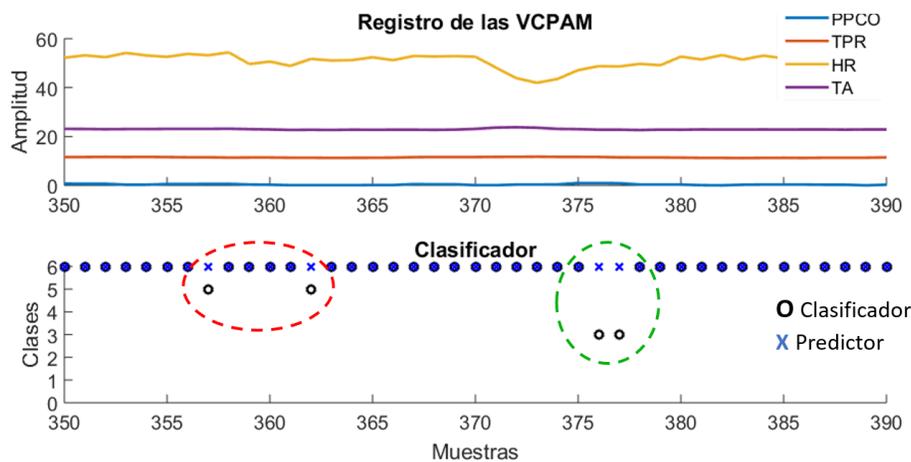


Figura 48. Evolución de los estados funcionales (clases) según clasificador y predictor. Base de datos de entrenamiento, ampliación entre muestras 350 a 390.

Fuente: Elaboración propia

En la Figura 49 se puede observar una ampliación de la respuesta entre las muestras 1264 a 1304 de la base de datos de prueba. 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 (ver óvalo rojo), 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. Existe una transición no detectada por el predictor en la muestra 1275 demostrando nuevamente 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 (ver óvalo verde). 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 con los datos de prueba.

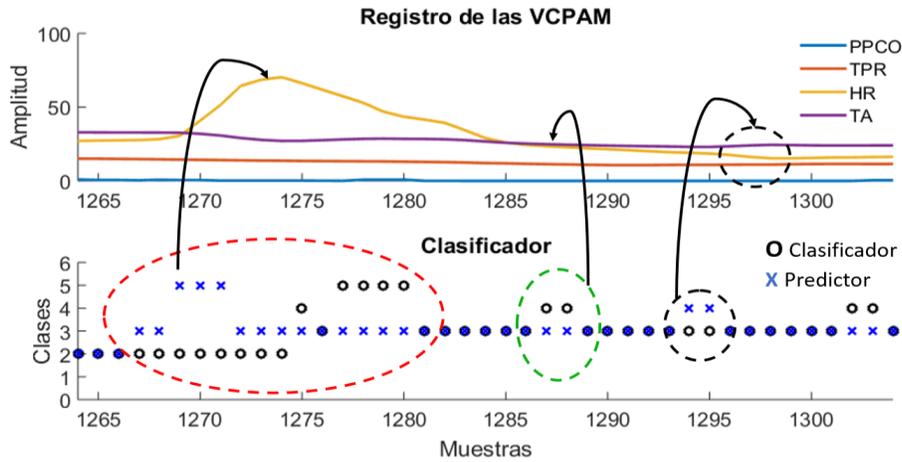


Figura 49. Evolución de los estados funcionales (clases) según clasificador y predictor. Base de datos de prueba ampliación entre muestras 1264 a 1304.

Fuente: Elaboración propia.

### 5.1.2 Programación de acciones de mantenimiento mediante el diagnóstico inteligente del sistema de producción de aire medicinal.

El mantenimiento basado en la condición CBM (*Condition Based Maintenance*) de los estados funcionales, se presenta como una adición al programa anual de mantenimiento del sistema de producción de aire medicinal. El diagrama de flujo propuesto para establecer las acciones de mantenimiento se muestra en la Figura 50; e inicia con la predicción mediante las estructuras MRNAs-NAR de los atributos ( $PPMCO_{(k+h)}$ ;  $TPR_{(k+h)}$ ;  $HR_{(k+h)}$ ;  $TA_{(k+h)}$ ) del objeto ( $\hat{x}_{i(k)}$ ). Luego el objeto predicho es clasificado en alguna de las clases ( $C_j$ ;  $j = 1,2,3,4,5,6$ ) asociada a su respectivo estado funcional en el proceso. Cada clase ( $C_j$ ) se relaciona con un bloque de mantenimiento para programar las acciones de intervención sobre el sistema. Los bloques de mantenimiento nombrados como (1,2,3,4,5 y sin acción) serán a su vez un nuevo diagrama de flujo para establecer condiciones y programar el mantenimiento del elemento constructivo del sistema de producción de aire medicinal.

#### 5.1.2.1 Planificación del mantenimiento para el estado funcional (clase 1).

El monóxido de carbono (CO) es nocivo para la salud de los pacientes; por lo tanto, el incremento de las PPMCO en el aire medicinal es considerado una falla inminente. La inhalación de CO puede ocasionar intoxicación y en el peor de los casos, la muerte. Cuando una persona inhala CO puede sufrir deficiencia respiratoria, dolor en el pecho, deterioro del juicio, pérdida del conocimiento y puede recaer en un estado de coma. El diagrama de flujo mostrado en el Anexo 1 corresponde a la planeación de las acciones de mantenimiento para el estado funcional asociado a la clase 1.

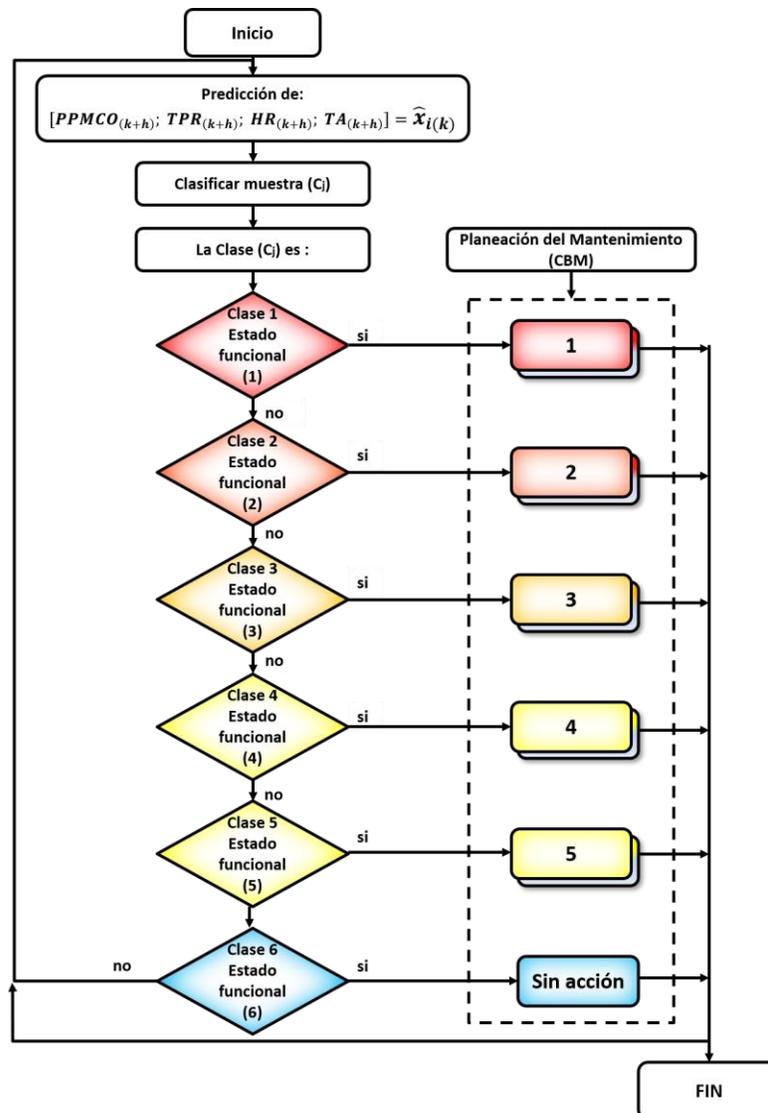


Figura 50. Diagrama de flujo para establecer las acciones de mantenimiento basadas en los estados funcionales (condiciones) del proceso de producción de aire medicinal.

Fuente: Elaboración propia.

### 5.1.2.2 Planificación del mantenimiento para el estado funcional (clase 2).

El incremento de la TA produce sobrecarga en los secadores. Si la TA es elevada el aire producido se calienta por transferencia de calor. Lo anterior altera a su vez la funcionalidad de los dispositivos electrónicos (circuitos integrados y elementos primarios de medición). Las principales causas de incrementos en la TA del área confinada para la producción de aire medicinal están relacionadas con: averías en los secadores, pérdida de la función del aire acondicionado y sobrecalentamiento de los motores de los cabezotes del compresor. En el Anexo 2 se muestra el diagrama de flujo planteado para ejecutar las acciones de mantenimiento en relación con el estado funcional (clase 2).

### **5.1.2.3 Planificación del mantenimiento para el estado funcional (clase 3).**

El estado funcional relacionado con la clase 3 hace referencia al incremento de la TA del sistema de producción de aire medicinal, en este caso la TA no ha superado el límite ( $>25^{\circ}\text{C}$ ); sin embargo, hay un ligero aumento de la temperatura y disminución de la HR ocasionado por alguna fuente en el área confinada para la producción de aire medicinal.

El diagrama de flujo para la planeación del mantenimiento del estado funcional (clase 3) es igual al usado para la planeación del mantenimiento del estado funcional (clase 2, Anexo 2), aunque son iguales, los diagramas se diferencian en la velocidad de flujo que se tiene en las tareas de inspección de los elementos constructivos del sistema de producción de aire.

Al ser el estado funcional (clase 3) un estado de alarma, la convergencia del diagrama de flujo y de sus actividades será mayor que la velocidad de flujo en el diagrama para el estado funcional (clase 2).

La ejecución y análisis del estado funcional (clase 3) será fundamental y de carácter predictivo, además de la predicción de dicho estado por el esquema de supervisión inteligente, para impedir que el sistema de producción de aire medicinal entre en modo falla en dirección al estado funcional (clase 2).

### **5.1.2.4 Planificación del mantenimiento para el estado funcional (clase 4).**

El incremento en la TPR se puede presentar por problemas en los secadores, incremento en la temperatura del aire comprimido en el tanque pulmón, o por problemas en el monitor dedicado a la medición de la TPR. Cualquiera de las causas debe ser intervenida rápidamente debido a que la TPR no puede superar los  $39^{\circ}\text{F}$ . El Anexo 3 muestra el diagrama de flujo propuesto para la intervención del sistema de producción de aire medicinal ante la predicción de la transición del sistema, hacia el estado funcional (clase 4).

### **5.1.2.5 Planificación del mantenimiento para el estado funcional (clase 5).**

Para el estado funcional (clase 5) del sistema de producción de aire se tuvieron en cuenta consideraciones del operario para plantear acciones de validación en la medición. La experiencia ha demostrado falsas alarmas ocasionadas por mediciones contaminadas por ruido y componentes de alta frecuencia. Lo anterior generó la necesidad de filtrar previamente la señal y condicionar el diagrama de flujo bajo acciones de verificación en la medición. La planeación del mantenimiento para el estado funcional (clase 5) se muestra en el Anexo 4.

### **5.1.2.6 Planificación del mantenimiento para el estado funcional (clase 6).**

El estado funcional (clase 6) del sistema de producción de aire medicinal corresponde a la condición normal de funcionamiento (ver Figura 51) en la cual todas las VPCPAM se encuentran dentro de los rangos de operación de acuerdo con la farmacopea, las BPM, y el manual de calidad para la producción de aire medicinal en sitio por compresor. El tono azul en

el diagrama de flujo representa una producción segura y un estado funcional de tranquilidad para el operario.

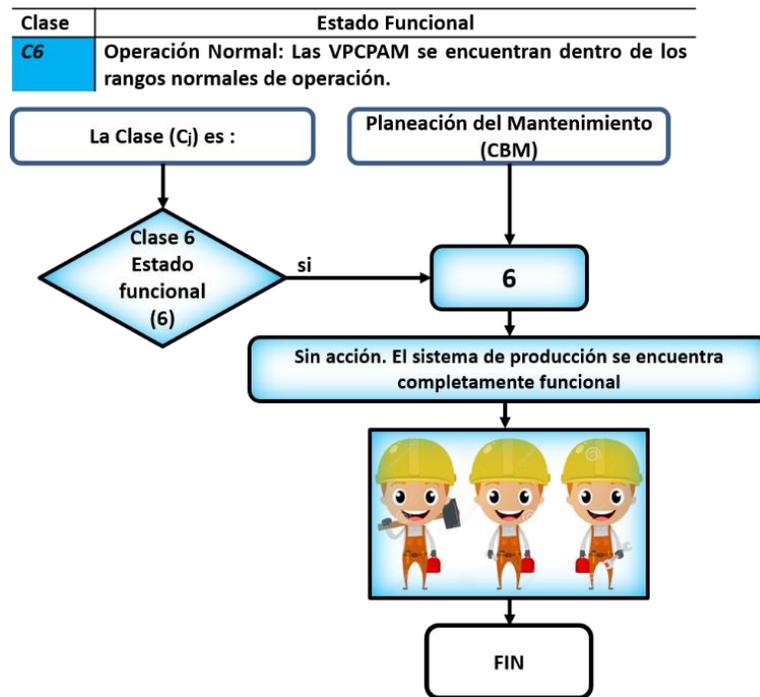


Figura 51. Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 6).

Fuente: Elaboración propia.

### 5.1.3 Predicción de estados funcionales y programación de acciones de control para la planta de presión.

Para la predicción de estados funcionales de la planta de presión, se implementaron a partir de las estructuras neuronales MRNAs-NARX, predicciones iteradas hasta obtener el valor estimado de las variables  $[VC, EC, TD]$  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. Los resultados obtenidos a partir del esquema de supervisión inteligente para el diagnóstico automático de la planta de presión se muestran en las Figuras 52-55. A continuación se analizan las respuestas mediante la ampliación de las muestras con dinámicas importantes observadas en los resultados gráficos.

En la Figura 52 se muestra como el clasificador y el predictor se ubicaron sobre el estado funcional de falla (clase 2, fuga considerable en el sistema, ver gráfico remarcado con óvalo rojo) hasta la muestra 31, momento en el cual el predictor detectó cambio de clase hacia el estado funcional (clase 6, condiciones normales de funcionamiento, ver gráfico remarcado con

ovalo negro). Solo 6 muestras después, el clasificador detectó la transición; es decir, que el cambio de clase C2 a C6 fue predicha acertadamente con 6 muestras de anticipación (ver óvalo verde), indicando al operador que el sistema transitará hacia un estado normal de funcionamiento. A partir del análisis anterior, se observó una nueva cualidad en el comportamiento del predictor de los estados funcionales de la planta de presión, reflejada en la extensión del horizonte de predicción, en este caso 3 muestras de ganancia en la detección de la transición entre la clase C2 a C6.

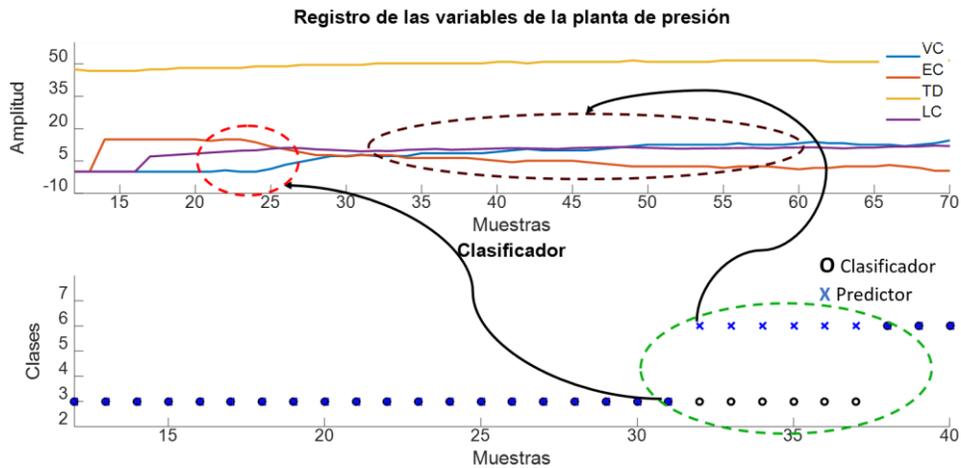


Figura 52. Evolución de los estados funcionales (clases) según clasificador y predictor. Base de datos de entrenamiento ampliación entre muestras 5 a 40.  
Fuente: Elaboración propia.

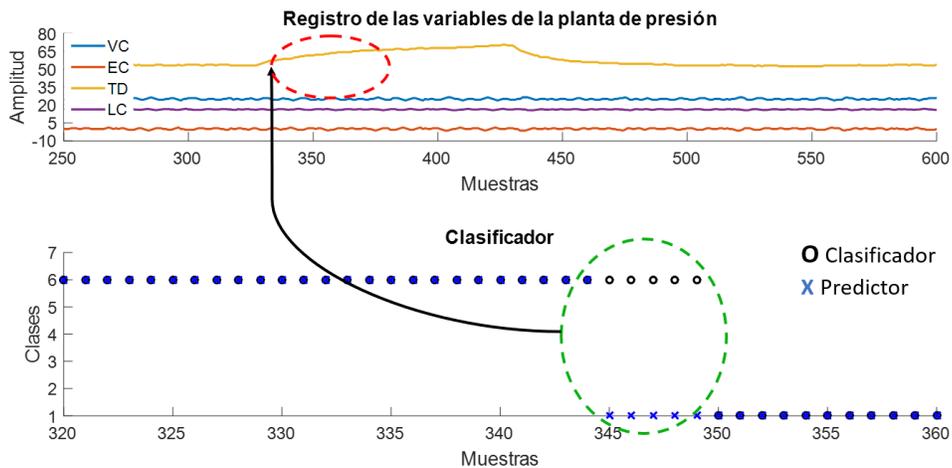


Figura 53. Evolución de los estados funcionales (clases) según clasificador y predictor. Base de datos de entrenamiento ampliación entre muestras 360 a 360.  
Fuente: Elaboración propia.

La Figura 53 corresponde a una ampliación de las muestras 320 a 360 de la base de datos usada en el entrenamiento del clasificador. Se puede observar como el predictor en la muestra 345 detectó la transición hacia el estado de falla (clase 1, ver óvalo rojo), con 5 muestras de

anticipación, solo hasta la muestra 350 el clasificador logró detectar el estado funcional de falla. La predicción del estado funcional (clase 1) es importante para activar el sistema de refrigeración del *driver* de corriente, evitando sobrecalentamiento y degradación. Se observa nuevamente, que el horizonte de predicción se extiende en este caso de 3 a 5 muestras en el predictor como ganancia adicional, en el esquema de diagnóstico inteligente propuesto para la planta de presión.

La Figura 54 muestra una ampliación entre las muestras 900 a 950 de la base de datos de prueba. Se puede observar como el predictor detecta transición hacia el estado funcional de falla 1, con 5 muestras adelante (ver óvalo rojo) 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 (ver óvalo verde). 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%).

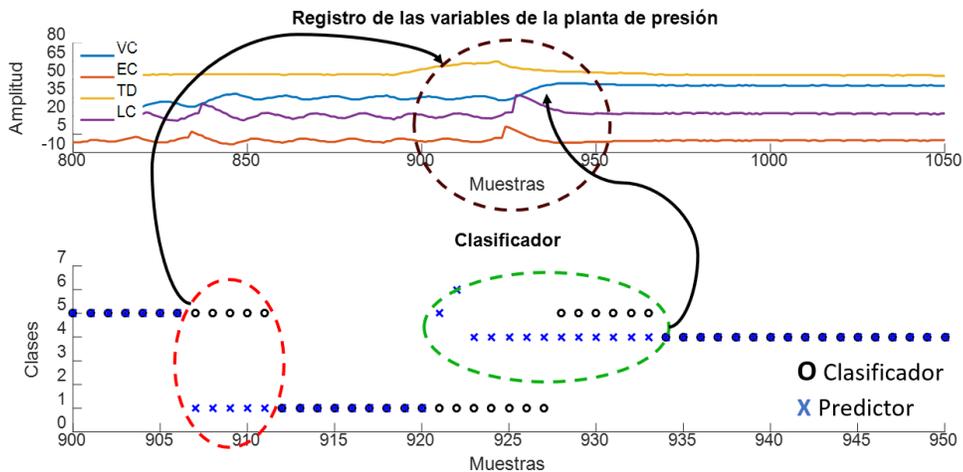


Figura 54. Evolución de los estados funcionales (clases) según clasificador y predictor. Base de datos de entrenamiento ampliación entre muestras 900 a 950.

Fuente: Elaboración propia.

En la Figura 55 se puede observar una ampliación de la respuesta entre las muestras 625 a 670 de la base de datos de prueba. En este caso el predictor clasifica acertadamente sobre el estado funcional normal de funcionamiento de la planta, hasta la muestra 627, instante en el cual detecta transición, hacia el estado funcional de alerta (clase 5, sistema controlando con perturbación, ver óvalo negro). La transición anterior es detecta con 6 muestras de anticipación por el predictor, manteniendo predicciones entre 5 y 6 muestras hasta la muestra 659. En las muestras 660-661, el predictor detecta transición hacia la clase 5 desde la clase 6. Cambio que es detectado por el clasificador 5 muestras después del predictor. Un nuevo comportamiento por parte del predictor se observa en las muestras 660-661, donde se detecta transición con dos muestras hacia la clase 5, mientras que el clasificador solo detecta la clase 5 con 1 muestra (ver óvalos rojos). En este caso, el predictor decide clasificar la predicción de las variables VC y EC en la clase 5, a partir de los cambios observados, manteniendo como mínimo una muestra conservativa para ejecutar la transición.

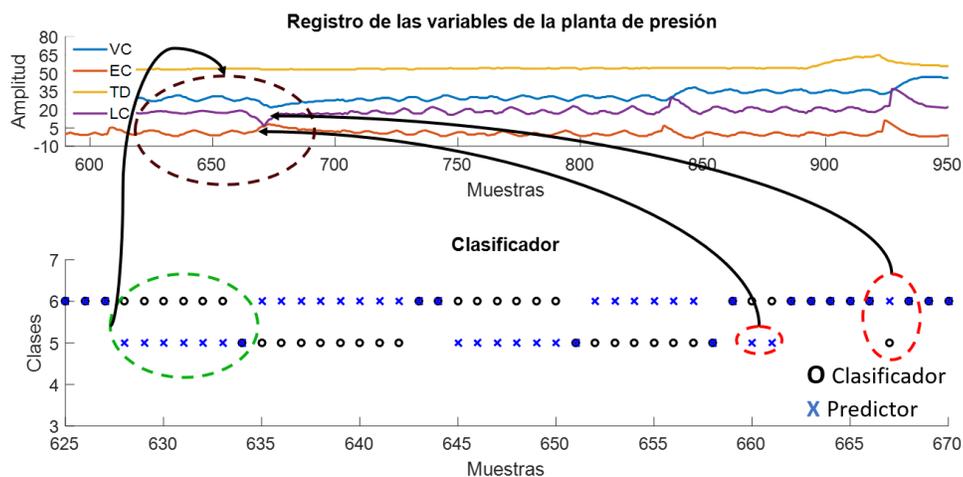


Figura 55. Evolución de los estados funcionales (clases) según clasificador y predictor. Base de datos de prueba ampliación entre muestras 360 a 360.

Fuente: Elaboración propia.

#### 5.1.4 Programación de acciones de control mediante el diagnóstico inteligente de la planta de presión.

Para implementar el esquema de supervisión inteligente sobre la planta de presión, se diseñó una aplicación denominada *Diagnosis\_VI*, la cual permite: adquisición de bases de datos de las respuestas del proceso, control, visualización gráfica y numérica, y diagnóstico automático (ver Figura 56). La aplicación se programó en la plataforma de instrumentos virtuales LabVIEW™, utilizando las estructuras para la predicción de estados funcionales MRNAs-NARX/*Fuzzy Clustering*.

En la Figura 57 se muestra el diagrama de bloques utilizado para programar las acciones de control sobre la planta de presión. El diagnóstico inteligente fue implementado para generar un

sistema de control con supervisión inteligente. Los estados funcionales del proceso y el punto de consigna fueron utilizados para programar la conmutación automática de los coeficientes de los controladores. Los demás estados como falla y alerta fueron utilizados para desactivar el controlador y generar las alarmas visuales respectivamente.

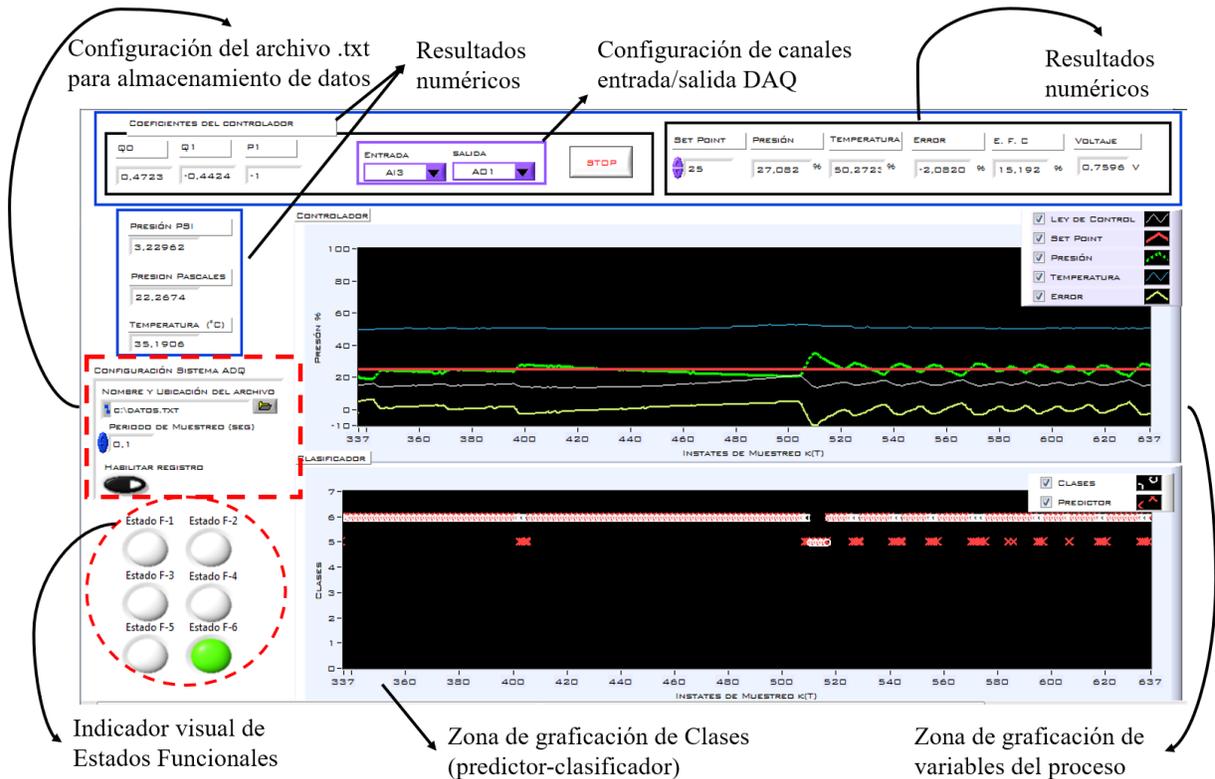


Figura 56. Aplicación *Diagnosis\_V1* para la supervisión inteligente de la planta de presión.

Fuente: Elaboración propia.

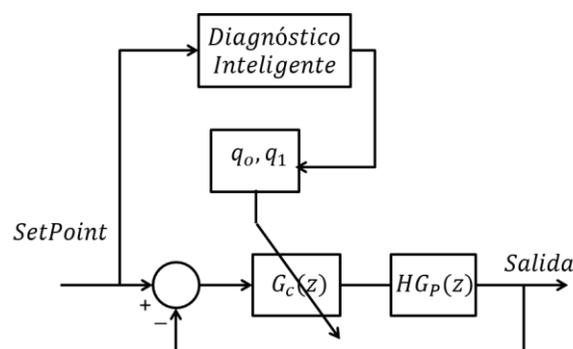


Figura 57. Diagrama de bloques implementado para la programación de acciones de control sobre la planta de presión.

Fuente: Elaboración propia.

La Figura 58 muestra los resultados de la implementación del esquema de supervisión sobre la planta de presión, se observa transición entre los estados funcionales 5 y 6. En la muestra 240 el predictor detectó perturbación en el sistema durante 5 muestras. El clasificador no detectó la perturbación (ocasionada manualmente), la cual se hizo evidente en el cambio de la variable controlada. En este caso, el predictor superó el desempeño del clasificador, estableciendo la perturbación como estado funcional 5 de falla mínima en el tanque de almacenamiento. En las demás muestras, tanto el clasificador como el predictor clasificaron acertadamente.

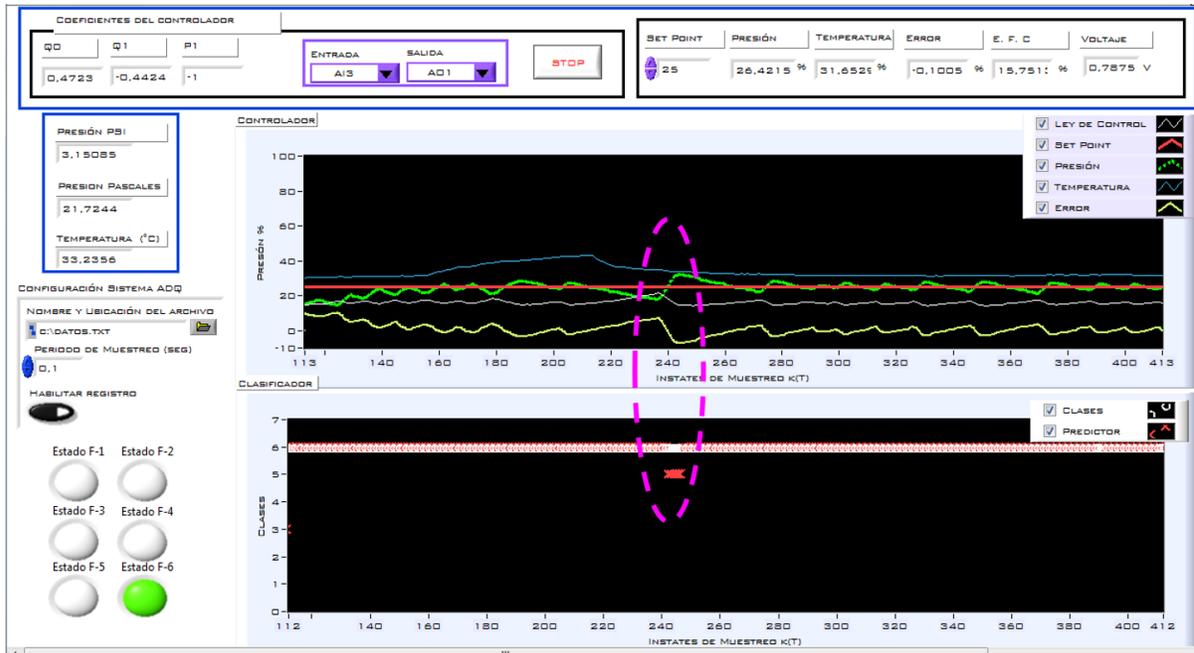


Figura 58. Respuesta gráfica de la implementación del sistema de supervisión inteligente sobre la planta de presión. Estados funcionales 6 y 7.

Fuente: Elaboración propia.

En la figura 59 se observa como el clasificador y predictor acertaron en la clasificación hasta la muestra 479. En la muestra 480, se generó un cambio en el punto de consigna del sistema del 40% al 50%, ocasionando detección de transición por parte del predictor hacia la clase 4 (estado asociado a la operación normal en la zona de operación que incluye el 50%), con 2 muestras adelante, mientras que el clasificador para la misma condición detectó transición hacia la clase 5, con 2 muestras, y luego transición hacia el estado funcional detectado por el predictor. En este caso el predictor logró predecir con dos muestras adelante el cambio en la zona de operación del controlador conmutando las ganancias para la zona (40%-50%). Después de la muestra 485, el predictor logró predecir 2 muestras adelante, transiciones entre las clases 4-5 y 5-4, alertando al operador de que el sistema se encuentra controlando con perturbación.

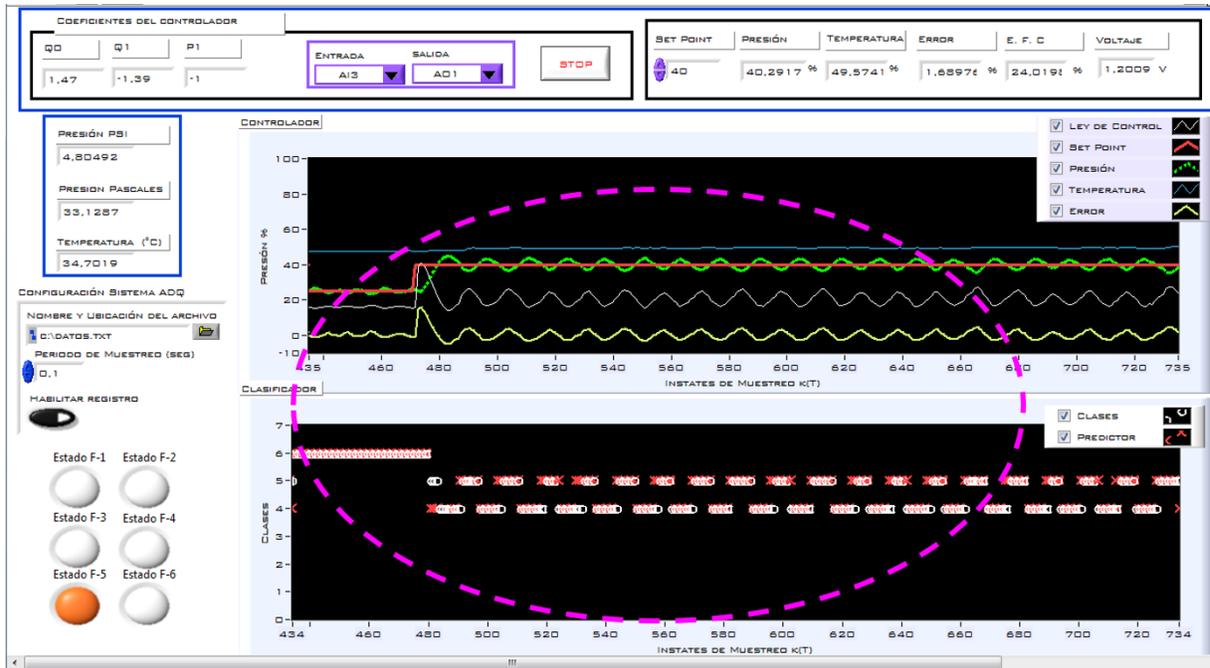


Figura 59. Respuesta gráfica de la implementación del sistema de supervisión inteligente sobre la planta de presión. Estados funcionales 2, 4, 5 y 6.

Fuente: Elaboración propia.

En la Figura 60, se observan transiciones entre los estados funcionales 2,3,4,5 y 6. Tanto el predictor como el clasificador, lograron clasificar acertadamente sobre el estado funcional 4, hasta la muestra 2010, momento en el cual el predictor logró predecir 3 muestras adelante respecto al clasificador la perturbación en el sistema, con tendencia de saturación a cero de la acción de control. En la muestra 2025, el predictor logró detectar transición hacia el estado funcional 4 con 1 muestra de anticipación, luego predijo con 2 muestras transición hacia la clase 5. El clasificador siguió la dinámica del predictor, hasta la muestra 2038, en la cual fue evidente la falla inminente detectada por el predictor con dos muestras sobre el estado 3, luego con 3 muestras sobre el estado funcional 5, 1 muestra sobre el estado funcional 2, y finalmente detección de transición hacia la falla inminente con 8 muestras de anticipación respecto al clasificador, indicando una clasificación acertada.

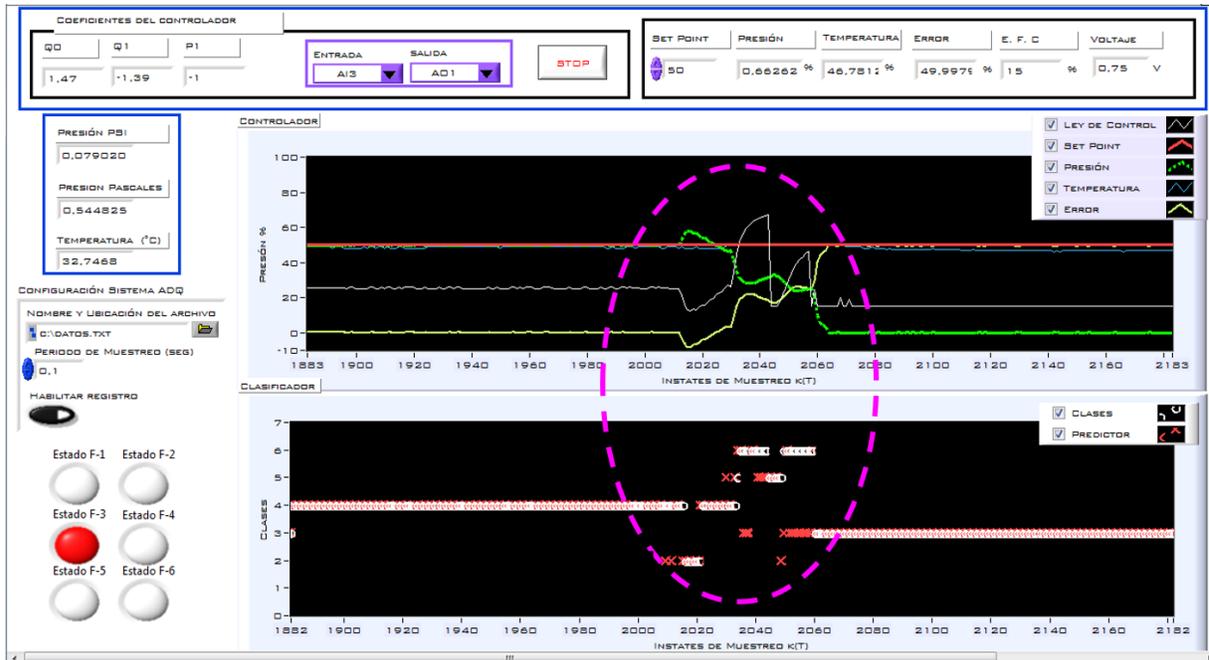


Figura 60. Respuesta gráfica de la implementación del sistema de supervisión inteligente sobre la planta de presión. Estados funcionales 2, 3, 4, 5 y 6.

Fuente: Elaboración propia.

## **5.2 Conclusiones**

En este proyecto 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. Para el sistema de producción de aire medicinal se establecieron y validaron las acciones de mantenimiento, basadas en el análisis de la respuesta del predictor de estados funcionales, y la experticia del grupo de ingeniería del departamento de mantenimiento asociado al proceso. Para implementar el esquema de supervisión sobre la planta de presión, se diseñó una aplicación con posibilidad de observar la evolución gráfica del diagnóstico, almacenar bases de datos y observar mediante indicadores visuales los estados funcionales. Se establecieron las acciones de control para el proceso basadas en la predicción de los estados funcionales y el punto de consigna. Se mostraron los resultados de simulación e implementación, demostrando la efectividad del esquema de supervisión.

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.

A partir de la implementación del esquema de supervisión inteligente sobre la planta de presión, se observó capacidad del predictor para detectar cambios en el punto de consigna como una transición entre las zonas de operación de los controladores. Adicionalmente, el predictor logró detectar la perturbación aplicada en la zona de trabajo equivalente al 25%, la cual no fue detectada por el clasificador. Lo anterior permitió demostrar la capacidad de generalización del predictor ante dinámicas no presentadas en la etapa de entrenamiento del clasificador.

Durante la programación de las acciones de mantenimiento y control, siempre se tuvieron en cuenta los conceptos del personal experto, en este caso ingenieros y operarios que trabajan diariamente con los procesos y que están capacitados en el funcionamiento y mantenimiento de este. La IA permitió incorporar en el diagnóstico el conocimiento de los operarios e ingenieros, generando un sistema de supervisión basado en la experiencia.

Como perspectiva de trabajo futuro, se propone una metodología basada en la predicción a partir del análisis del comportamiento de los grados de pertenencia del clasificador difuso, así como la comparación con otras estrategias de clasificación basada en RNAs o algoritmos genéticos. Se propone de igual forma la posibilidad de optimizar el diagnóstico a partir de metaheurísticas poblacionales de inteligencia colectiva, manteniendo la línea de investigación relacionada con la IA.

## **6. Anexos**

En los siguientes anexos se encuentran los diagramas de flujo de las acciones de mantenimiento planteadas para cada estado funcional predicho mediante MRNAs-NAR/*fuzzy clustering*; del sistema de producción de aire medicinal. Durante la programación de las acciones de mantenimiento, se tuvo en cuenta el concepto técnico y la experticia del grupo de ingeniería del departamento de mantenimiento involucrado con el proceso de producción de aire medicinal.

### 6.1 Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 1).

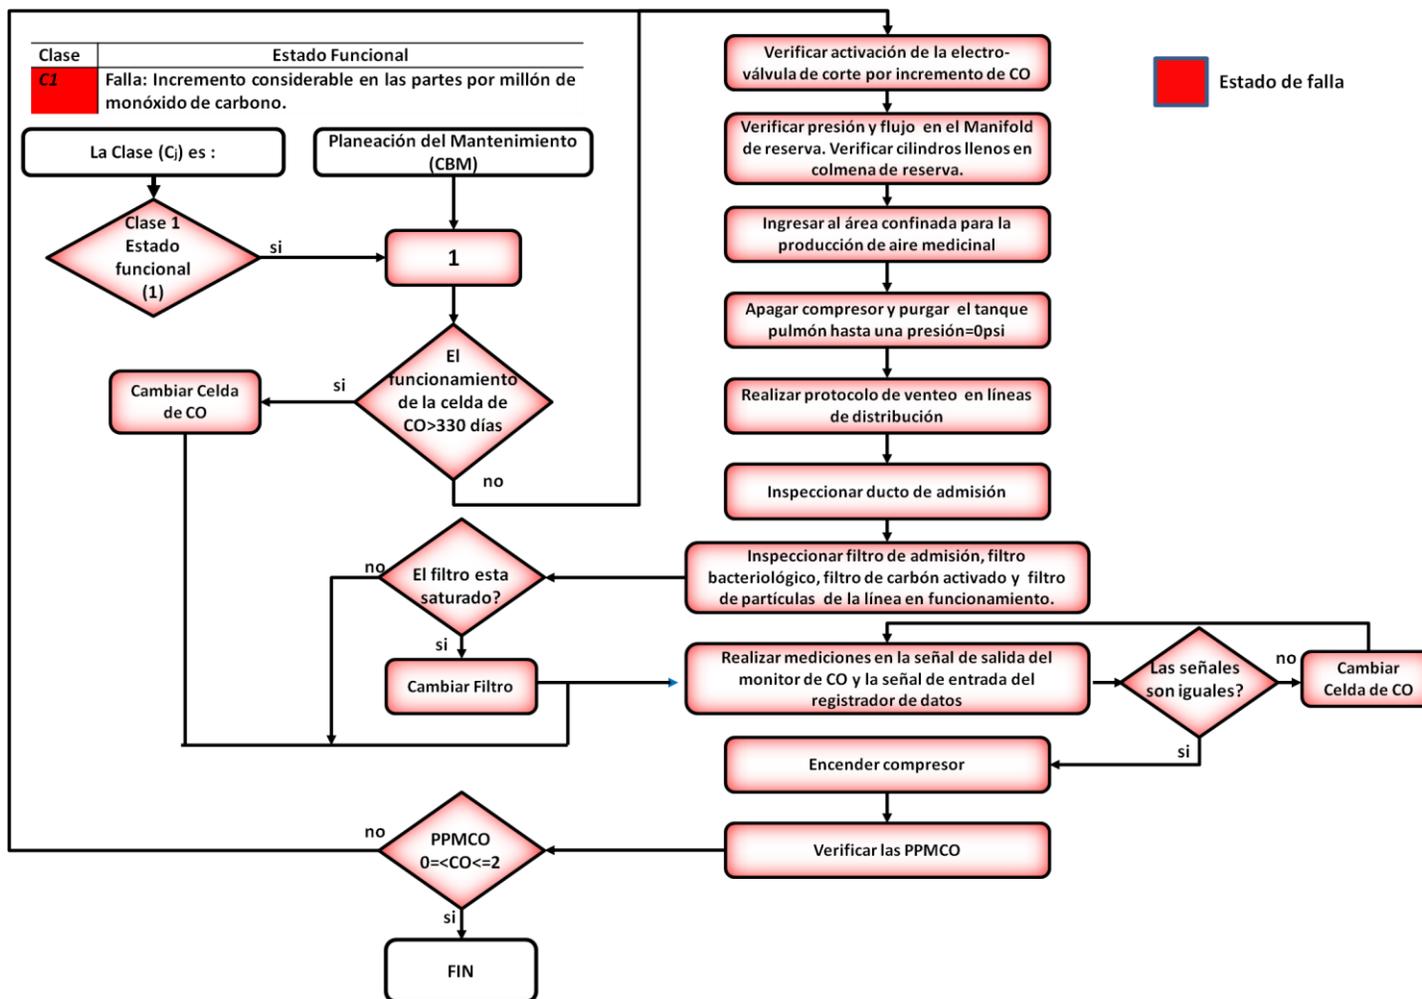


Figura 61. Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 1). Fuente: Elaboración propia.

## 6.2 Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 2).

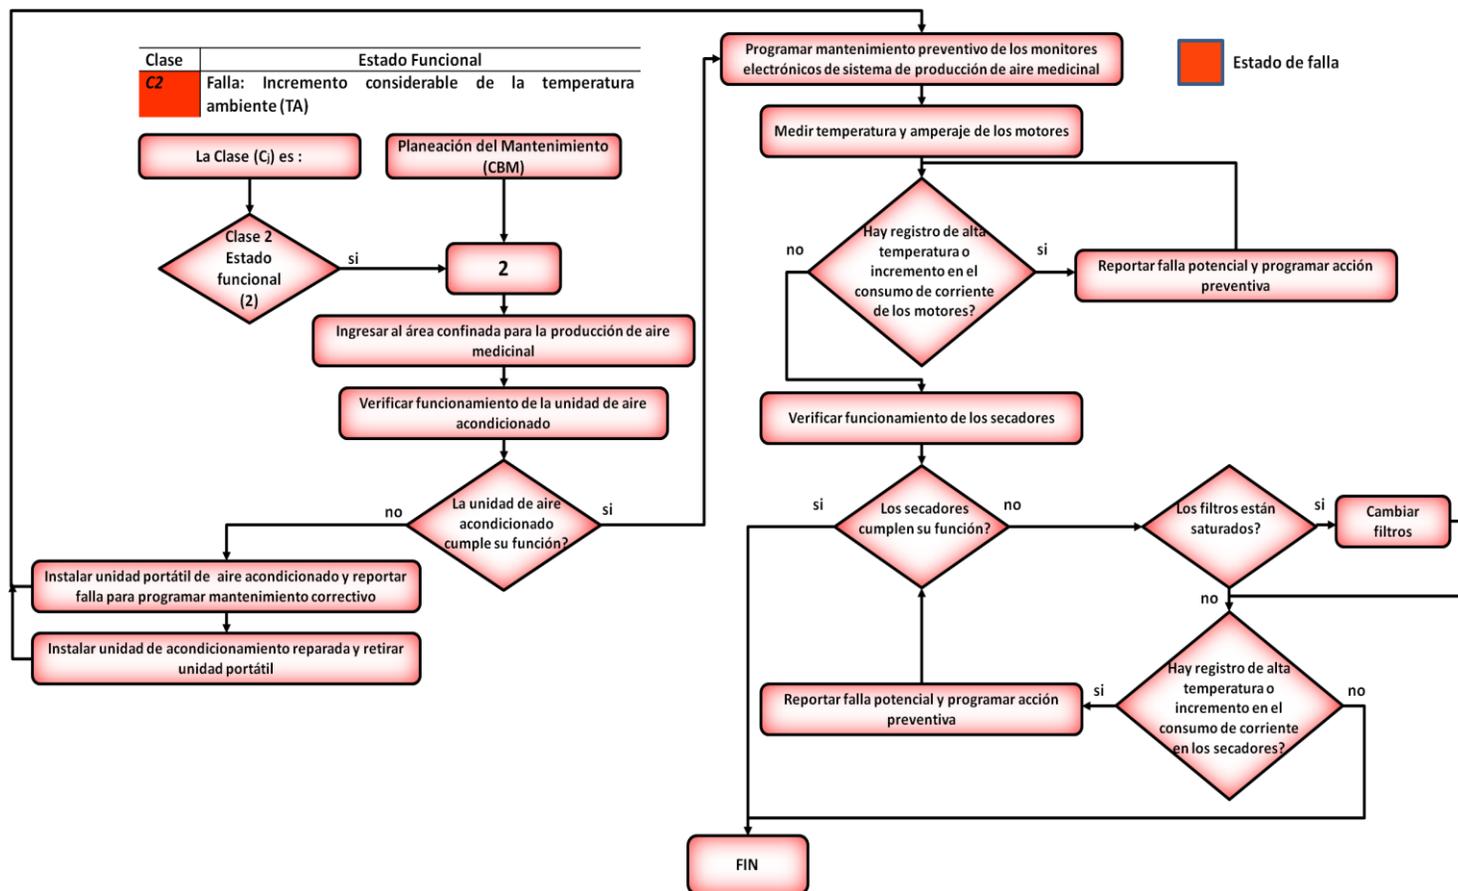


Figura 62. Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 2).  
Fuente: Elaboración propia.

### 6.3 Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 4).

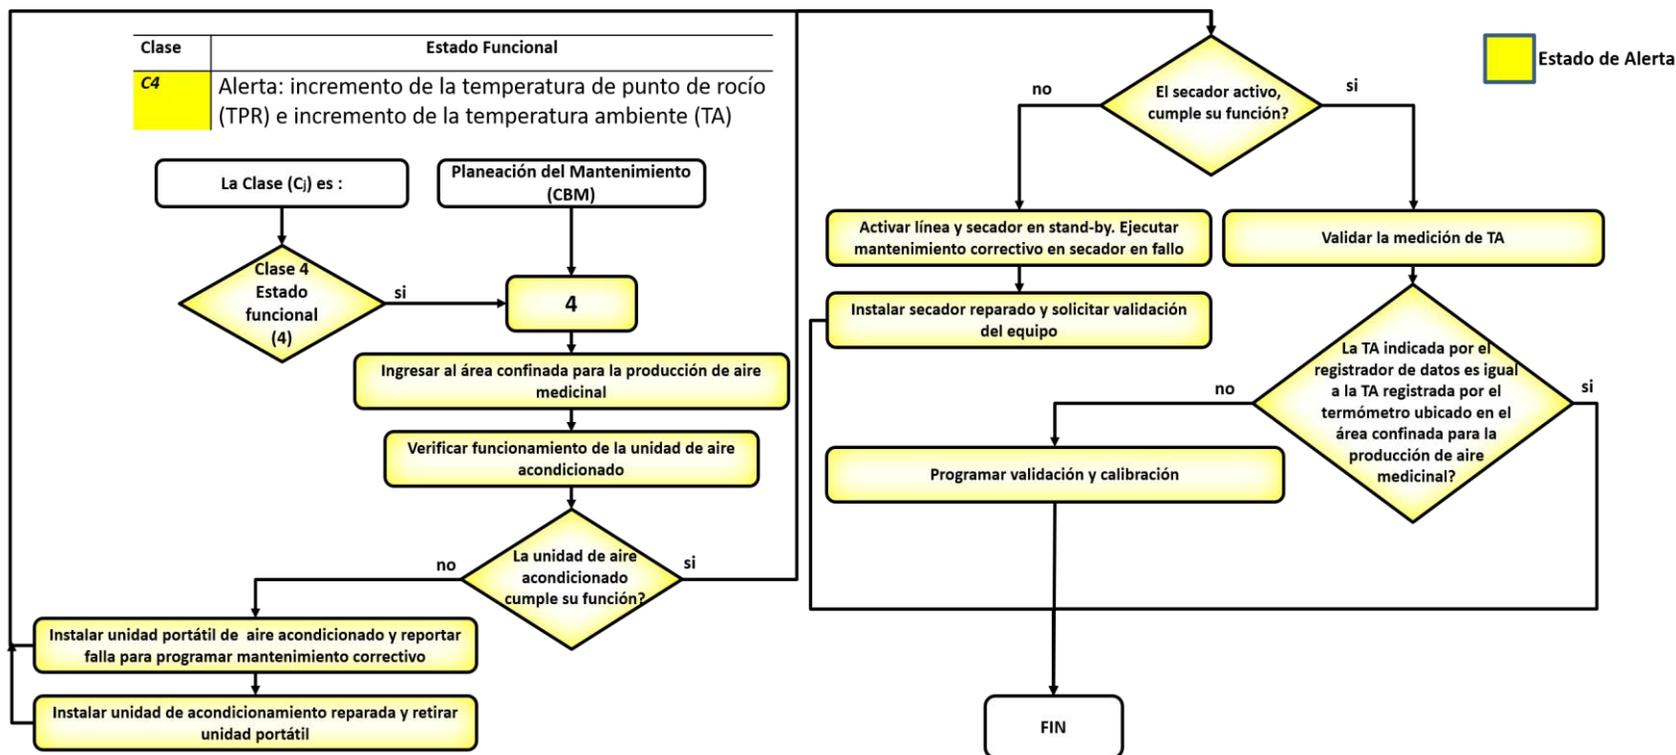


Figura 63. Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 4).

Fuente: Elaboración propia.

### 6.4 Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 5).

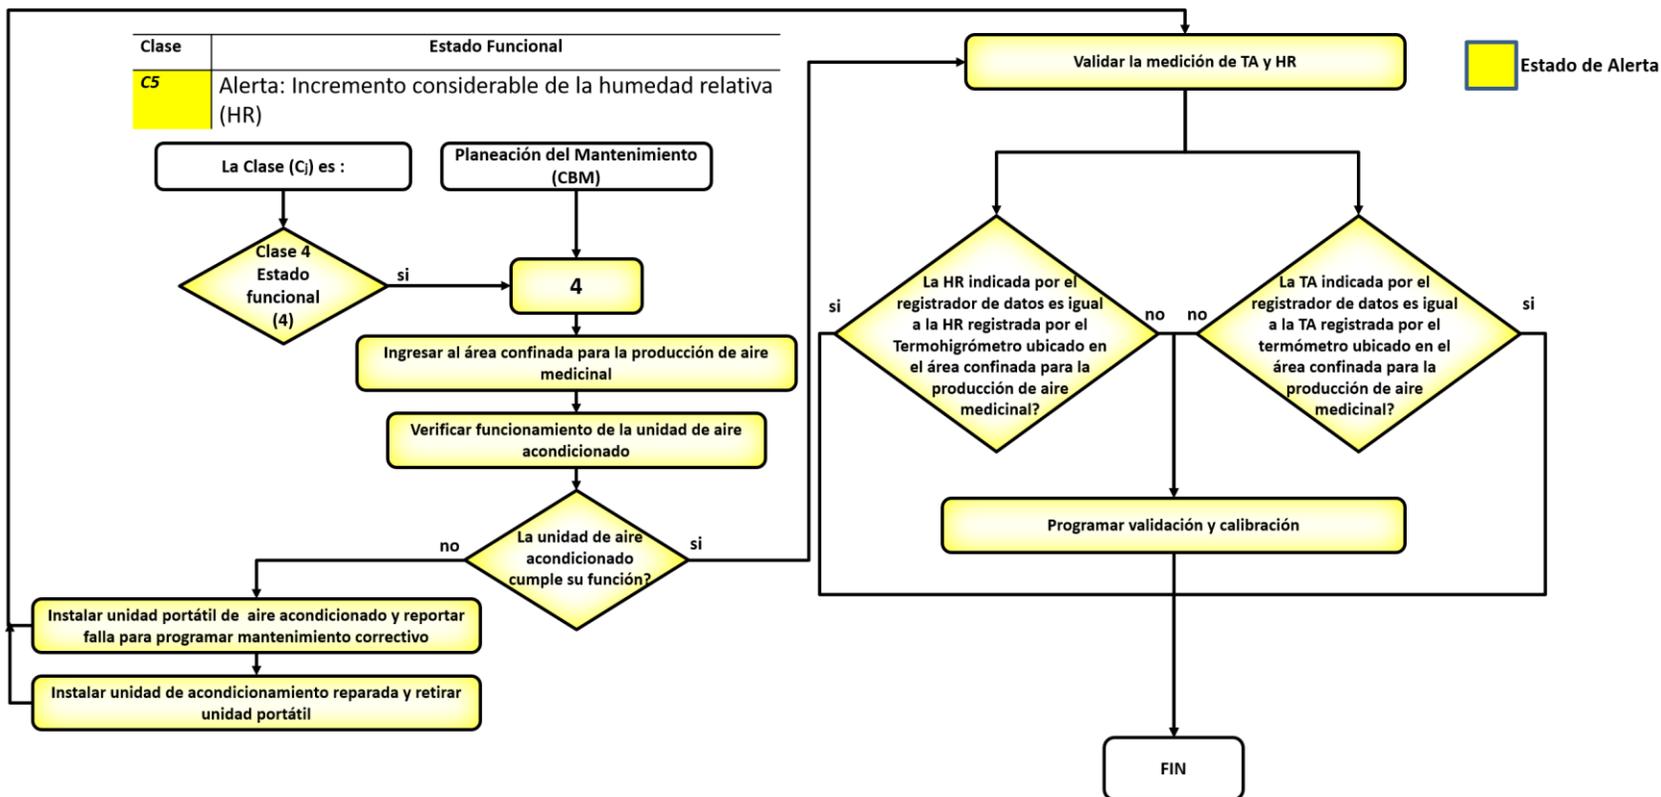


Figura 64. Diagrama de flujo propuesto para establecer las acciones de mantenimiento basadas en el estado funcional (clase 5).

Fuente: Elaboración propia.