

APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA PREDECIR FALLAS EN UNA PLANTA DE CONTROL DE PROCESOS INDUSTRIALES

Juan José Guevara Vásquez

Ingeniero en Electrónica. Docente Investigador, Escuela de Educación Dual. Escuela Especializada en Ingeniería ITCA-FEPADE, Sede Central, Santa Tecla.

Correo electrónico: juan.guevara@itca.edu.sv

Carlos Geovanny Meléndez Molina

Técnico en Ingeniería Eléctrica. Docente Coinvestigador, Escuela de Ingeniería Eléctrica y Electrónica. Escuela Especializada en Ingeniería ITCA-FEPADE, Sede Central, Santa Tecla.

Correo electrónico: carlos.melendez@itca.edu.sv

Recibido: 22/08/2025 - Aceptado: 02/09/2025

Resumen

En este artículo se describe el proceso de investigación y los resultados obtenidos en el estudio de la aplicación de Inteligencia Artificial para predecir fallas en una planta de control de procesos industriales de flujo y presión. La investigación buscó identificar y evaluar modelos de Aprendizaje Automático que, una vez entrenados puedan predecir el estado operativo del proceso industrial con exactitud. El proyecto consistió en automatizar un Entrenador de Procesos de Flujo y Presión para publicar los datos de funcionamiento en tiempo real. El control neumático se modificó para simular por hardware fallas en el actuador corriente/presión (I/P) de la válvula de proceso que controla la presión del sistema. Los datos del proceso y de simulación de fallas fueron registrados para crear un conjunto de datos, Dataset clasificados. Con el Dataset, se entrenó y evaluó el desempeño de varios modelos de Aprendizaje Automático, ML. Finalmente, se utilizó una API de producción para cargar el modelo y evaluar el estado del proceso en tiempo real obteniendo un rendimiento superior al 90 % en las predicciones de falla.

Palabras clave

Inteligencia Artificial, Aprendizaje Automático, Red Neuronal, Perceptrón Multicapa, Bosque Aleatorio, Dataset, Control de Procesos, Node-RED.

APPLICATION OF ARTIFICIAL INTELLIGENCE TO PREDICT FAILURES IN INDUSTRIAL PROCESS CONTROL PLANTS

Abstract

This paper describes the research process and the results obtained in the study of the application of Artificial Intelligence to predict failures in a flow and pressure industrial process control plant. The research sought to identify and evaluate Machine Learning models that, once trained, can accurately predict the operating status of the industrial process. The project consisted of automating a Flow and Pressure Process Trainer to publish real-time operating data. The pneumatic control was modified to hardware simulate failures in the current/pressure (I/P) actuator of the process valve that controls the system pressure. The process and fault simulation data were recorded to create a classified Dataset. With the Dataset, the performance of various Machine Learning, ML, models were trained and evaluated. Finally, a production API was used to load the model and evaluate the state of the process in real time obtaining a performance higher than 90 % in the failure predictions.

Keywords

Artificial Intelligence, Machine Learning, Neural Network, Multilayer Perceptron, Random Forest, Dataset, Process Control, Node-RED.

Introducción

El control de procesos consiste en dos funciones claramente diferenciadas: la adquisición de datos y el control. Para producir un producto que sea de alta calidad de forma consistente, es necesario un estricto control del proceso de producción. En este sentido, el control del proceso es el control automático de una variable de salida, que al

detectar la amplitud del parámetro y comparándolo con el nivel deseado, produce una señal de error para controlar una variable de entrada [1].

Para coleccionar información del estado del proceso se utilizan sensores. El término sensor se refiere a un elemento que produce una señal relacionada con la cantidad que se está midiendo. Un transductor se define como el

elemento que al someterlo a un cambio físico experimenta un cambio relacionado, por lo que los sensores son en realidad transductores. Sin embargo, un sistema de medición puede utilizar transductores, además de sensores, en otras partes del sistema para convertir señales de una forma dada en otra distinta [2][3].

Las válvulas neumáticas de control de procesos pueden ser manipuladas para regular con precisión el flujo de un fluido. Las válvulas de control deben cumplir un exigente conjunto de requisitos para garantizar un control exacto y preciso [4]. Deben estar correctamente diseñadas, dimensionadas para el rango normal de caudales y presiones, así como fabricadas con los materiales adecuados y funcionar correctamente en todo el rango de operación [5].

Las válvulas de control no funcionan por sí solas, normalmente, un conjunto de válvula completo consta de un cuerpo de válvula, un actuador y, a menudo, un posicionador. El cuerpo de la válvula es una carcasa a presión a través de la cual pasa el fluido. El cuerpo tiene conexiones para tuberías. Un obturador de válvula móvil cambia de posición para ajustar el caudal. El obturador puede ser un disco, una bola o algún otro diseño especializado. El vástago de la válvula está conectado al obturador y al accionamiento.

El actuador proporciona la fuerza motriz para abrir o cerrar la válvula. Existen varios tipos de actuadores, como los de muelle y diafragma y los accionados por motor eléctrico. A menudo se utiliza aire comprimido como fuerza motriz para los actuadores de las válvulas. El posicionador es un dispositivo que mide la posición real de la válvula y ajusta las entradas al actuador para lograr un posicionamiento más preciso de la válvula de control [6].

El Aprendizaje Automático es una rama de la Inteligencia Artificial (IA) y la Informática que se centra en el uso de datos y algoritmos para imitar la forma en que aprenden los humanos, mejorando gradualmente su precisión. Por lo tanto, es un componente importante del campo de la ciencia de datos. Mediante el uso de métodos estadísticos, los algoritmos se entrenan para hacer clasificaciones o predicciones, y para descubrir ideas clave en proyectos de minería de datos. Los algoritmos de Aprendizaje Automático suelen implementarse utilizando frameworks que aceleran el desarrollo de soluciones, como TensorFlow, Scikit-learn y PyTorch [7].

Dado que el Aprendizaje Profundo y el Aprendizaje Automático tienden a usarse indistintamente, merece la pena señalar los matices entre ambos. El Aprendizaje Automático, el Aprendizaje Profundo y las Redes Neuronales son subcampos de la Inteligencia Artificial. Sin embargo, las Redes Neuronales son en realidad un subcampo del Aprendizaje Automático, y el Aprendizaje Profundo es un subcampo de las Redes Neuronales [8].

Las diferencias entre el Aprendizaje Profundo y el Aprendizaje Automático radican en la forma en que aprende cada algoritmo. El Aprendizaje Automático "profundo" puede utilizar conjuntos de datos etiquetados, también conocido como Aprendizaje Supervisado. El

Aprendizaje Profundo puede ingerir datos no estructurados en bruto por ejemplo, texto o imágenes y determinar automáticamente el conjunto de características que distinguen unas categorías de datos de otras. Esto elimina parte de la intervención humana necesaria y permite el uso de conjuntos de datos más grandes [9].

Las Redes Neuronales, también conocidas como Redes Neuronales Artificiales (RNA) o Redes Neuronales Simuladas (SNN), son un subconjunto del Aprendizaje Automático y constituyen el núcleo de los algoritmos de Aprendizaje Profundo. Su nombre y estructura se inspiran en el cerebro humano, imitando la forma en que las neuronas biológicas se relacionan entre sí, se componen de capas de nodos, que contienen una capa de entrada, una o más capas ocultas y una capa de salida. Cada nodo, o neurona artificial, se conecta a otro y tiene un peso y un umbral asociados. Si la salida de cualquier nodo individual está por encima del valor umbral especificado, ese nodo se activa, enviando datos a la siguiente capa de la red; en caso contrario, no se transmite ningún dato [10]. Las Redes Neuronales se basan en datos de entrenamiento para aprender y mejorar su precisión con el tiempo. Sin embargo, una vez que estos algoritmos de aprendizaje se afinan en cuanto a precisión, se convierten en potentes herramientas de la Informática y de la Inteligencia Artificial que nos permiten clasificar y agrupar datos a gran velocidad. Las tareas de reconocimiento de voz o de imágenes pueden llevar minutos frente a horas si se comparan con la identificación manual por parte de expertos humanos [11].

El mantenimiento es el conjunto de operaciones necesarias para preservar la funcionalidad y eficiencia de un activo y puede tener lugar en respuesta a un fallo o como acción previamente planificada. Según Deloitte, una estrategia de mantenimiento no optimizada puede reducir la capacidad de producción de una planta industrial entre un 5 y un 20% [8].

Normalmente, el Aprendizaje Automático se utiliza para definir el estado actual de un sistema y predecir su estado futuro. Utiliza datos para predecir cuándo se averiará una máquina antes de que se averíe realmente. El desarrollo, la gestión y la gobernanza de los modelos de Aprendizaje Automático son esenciales para el éxito de este tipo de mantenimiento [12].

Los modelos de Inteligencia Artificial son capaces de procesar grandes cantidades de datos complejos en muy poco tiempo, por lo que muchas decisiones se delegan en las máquinas. A lo largo de la cadena de valor se recopilan y procesan en tiempo real numerosos datos, que pueden utilizarse para analizar la situación actual y redefinir la situación deseada. En este contexto, es importante que las empresas definan qué datos son relevantes, en relación con la tecnología utilizada [13]. El siguiente paso consiste en encontrar e integrar la herramienta de medición adecuada para captar los valores, antes de definir un modelo o algoritmo adecuado para la recogida y el tratamiento de los datos. En este contexto, también es importante comprender que todas las etapas de la cadena de valor se influyen mutuamente, por lo que un enfoque aislado no es útil en la mayoría de los casos [14][15].

Desarrollo

METODOLOGÍA DE INVESTIGACIÓN

A. Automatización del entrenador de procesos

El equipo de entrenamiento para el control de procesos comprende dos lazos de control: presión y caudal del aire. Un control electrónico basado en microprocesador mantiene simultáneamente en regulación 2 lazos de control. El sistema puede controlar y mantener una presión constante de 0 a 6 bar por medio de un control de lazo cerrado; el tamaño y por lo tanto la respuesta del sistema puede ser modificado incluyendo tanques de almacenamiento. Se dispone de sensores y transmisores de corriente de 4 a 20 mA para enviar la información a un control central, el cual a su vez envía señales de corriente a los actuadores, válvulas neumáticas que regulan la presión o el caudal del sistema. (Fig. 1)




Fig. 1. Diagrama del sistema del entrenador de flujo y presión.

La implementación del sistema de control de presión se llevó a cabo mediante el montaje secuencial de diversos componentes interconectados eléctricamente. Inicialmente, se procedió a la instalación física del Programador Lógico Programable (PLC) ET 200 Siemens dentro de un panel de control, garantizando un espacio adecuado para la disipación de calor y el acceso para futuras intervenciones. Los módulos de entrada y salida digitales y analógicos, se integraron al PLC, configurando la interfaz para la recepción y emisión de señales.

Posteriormente, se realizó el montaje de los dispositivos de campo. Los Pulsadores de Interacción (OPI y PB) se fijaron en la parte frontal del panel de control, para la activación manual de funciones específicas del sistema. El Transmisor de Presión (PTI), encargado de medir la variable de proceso, se instaló en la línea de presión del sistema, asegurando una conexión mecánica adecuada para una lectura precisa. De manera similar, el Sensor de Presión (PS), utilizado para la detección de umbrales de presión, se ubicó estratégicamente en el sistema.

El siguiente paso consistió en el conexionado eléctrico de los componentes. La fuente de alimentación se cableó a la red eléctrica, proporcionando la energía necesaria al PLC, al transmisor de presión, al sensor de presión y a las bobinas de los relés. Los pulsadores y el contacto del sensor de presión se conectaron a las entradas digitales del PLC, permitiendo la recepción de señales discretas por parte de la unidad de control. La señal analógica proporcional a la presión, proveniente del transmisor de presión, se cableó a una de las entradas analógicas del PLC. Finalmente, se procedió a la energización del sistema y a la carga del programa de control en el PLC ET 200S, utilizando el software de programación de Siemens. La lógica de control implementada en el PLC definió la respuesta del sistema a las señales de los sensores y los pulsadores, controlando la activación de las electroválvulas para regular la presión del proceso y la operación según los requerimientos del sistema. Se realizaron pruebas funcionales exhaustivas para verificar el correcto funcionamiento del sistema de control de presión en sus diferentes modos de operación.

B. Diseño del sistema de generación de fallas

En condiciones de buen funcionamiento, el nivel de apertura de la Válvula de Proceso (PV1) se realiza ajustando la presión de aire que se aplica por medio del convertidor PC1. Este convertidor transforma la corriente de 4 mA a 20 mA que proviene del PLC en variaciones de presión de entre 0.2 bar y 1 bar. La magnitud de la corriente corresponde al error en la Presión del Proceso (PV) respecto a la Presión Deseada (SP) en D1. La unidad de mantenimiento de aire comprimido UM1 se ajusta para que la presión que se suministra a PC1 sea de hasta 1.2 bar, lo que proporciona un margen de ajuste suficiente para variar la presión de control de acuerdo con la señal que recibe desde el PLC. (Fig. 2)




Fig. 2. Sistema de generación de fallas en el control de la válvula de proceso PV1.

Las perturbaciones de presión se aplican de forma manual por medio de PSV1, el entrenador no dispone de un indicador que cuantifique el caudal de fuga de aire que disminuye la presión por lo que la magnitud de la fuga se realiza empíricamente.

Al abrir PSV1 se introduce una perturbación que obliga al controlador Proporcional-Integral (PI) del PLC a cambiar la magnitud de la corriente que recibe PC1 para corregir el error en PV ajustando la presión de control que recibe PV1 haciendo que se abra o cierre proporcionalmente. El comportamiento del sistema, estabilidad y rapidez, lo determinan los valores de las variables proporcional e integral que son introducidas por el operario y que fueron calculadas por cualquiera de los métodos de ajuste de PI que se dispone en teoría de control. Durante las pruebas realizadas, los valores PI que proporcionaron mejor estabilidad y rapidez fueron: $P = 5$ e $I = 35$. En la tabla 1 se muestran los valores de control que mostraron un mejor control del proceso.

TABLA 1. Valores de P-I con mejor desempeño en el control del proceso

PARÁMETRO	VALOR	UNIDAD
SP	0.75	bar
KP	5	
KI	40	
PV alcanzado	0.75	bar
PARÁMETRO	VALOR	UNIDAD
SP	1.0	bar
KP	5	
KI	35	
PV alcanzado	1.0	bar

De acuerdo con el trabajo realizado es posible introducir fallas en el control neumático de una válvula de proceso y a partir del análisis de sus tiempos de apertura/cierre, predecir cuándo se produzcan dos fallas: 1) falla en los sellos de la válvula que controla la válvula de proceso y, 2) fugas a la atmósfera entre la salida de la válvula de control y la de proceso. [16][17]

Como la válvula PV1 posee un actuador ATO (Air to Open) normalmente cerrado, por defecto impide el paso de aire. Al recibir presión de control desde PC1 comienza a abrirse progresivamente permitiendo el paso. Una falla en los sellos de PC1 incrementa sin control el flujo de aire hacia PV1, haciendo que se abra más rápidamente y dificultando su cierre, lo cual se traduce en que cuando la condición de control requiera de la reducción de la presión, el control tardará más tiempo en conseguirlo ya que se incrementan los tiempos de respuesta de cierre de PV1, por lo que en general el sistema será más lento cuando SP sea ajustado a un nivel inferior del previamente establecido. De igual manera, existe la posibilidad que el cierre completo de PV1 nunca se consiga.

Por otra parte, una falla de fugas a la atmósfera entre la salida de PC1 y PV1 tendrá el efecto contrario, ya que la presión de control caerá proporcionalmente al nivel de fuga presente. Como resultado PV1 tomará más tiempo en abrirse provocando que el control del sistema haga que PC1 incremente el flujo de aire hacia PV1, por lo que el sistema será más lento cuando SP se incremente a partir de un valor

establecido. Es posible, además, que la apertura total de PV1 nunca se alcance mientras la fuga esté presente.

Un control P-I bien ajustado con los valores de la tabla 1, puede alcanzar el SP en la mayoría de los casos con las fallas presentes, pero le tomará más tiempo en conseguirlo.

Como es necesario introducir fallas que no existen en un sistema en buen funcionamiento, la solución diseñada es invasiva ya que requiere de la modificación del sistema de aire comprimido entre PC1 y PV1, así como de la cuantificación de la magnitud de las fugas mediante los Sensores de Presión IFM S1 y S3 modelo PT5404 y S2 serie PA3526. S1 mide la presión del suministro de aire comprimido que se encuentra entre 1 y 2 bar. Mientras que S2 y S3 miden la presión de control que entrega PC1 a PV1 con valores entre 0 y 1 bar que se verán afectadas cuando se introducen las fugas.

Para simular una falla interna o en los sellos en PC1, se instaló la válvula de aguja V1, que permite el aumento controlado de presión desde UM1 hacia PV1 dificultando el ajuste automático de PC1. Mientras que para simular una fuga a la atmósfera se instaló la válvula de aguja V2, que permite la salida controlada de aire produciendo una caída de presión. Se diseñó un circuito Datalogger para capturar, procesar y registrar los datos del proceso industrial. El diagrama esquemático del circuito que captura las corrientes de las presiones y las convierte a niveles de voltaje se muestran en Fig. 3.




Fig. 3. Diagrama esquemático de dispositivo Datalogger.

C. Diseño del conjunto de datos de entrenamiento: Dataset.

1) Selección y captura de datos.

El objetivo de los registros del Dataset, conjunto de datos, consiste en tomar una serie de datos del proceso en un instante de tiempo determinado, con los cuales se forman filas. De acuerdo con los valores de cada fila, se determina si existe o no una falla. El establecimiento del objetivo fue importante ya que permitió elegir el modelo de Aprendizaje Automático más apropiado para el pronóstico de la falla. En ese sentido, el Dataset se diseñó para entrenar un modelo de clasificación binaria. Los datos que forman parte del Dataset se muestran en la tabla II.

TABLA II. Datos del proceso y de fallas que forman parte del Dataset

Variable	Descripción
PV	Variable de proceso, representa la presión en el sistema. Esta presión busca igualar al valor de SP.
OUT	Porcentaje de apertura de PV1.
SP	Set Point, es la presión objetivo en el sistema.
P	Control Proporcional, representa la magnitud del ajuste proporcional que se aplica al error o desviación de PV respecto a SP.
I	Control Integral, representa el ajuste en función del tiempo del error estacionario de PV respecto a SP.
P1	Presión de suministro a la salida de la unidad de mantenimiento del entrenador.
P2	Presión de control a la salida de PC1.
P3	Presión de control a la entrada de PV1.
OUTCOME	Pronóstico.

2) Mecanismo de captura de los datos.

Para la captura de los datos se crearon e integraron dos flujos en Node-RED que se muestran en Fig. 4, el primer flujo es responsable de la consulta de los valores de los datos del control del proceso. Los nodos del flujo se conectan directamente a los bloques de datos del PLC para obtener los valores en tiempo real. Para el establecimiento de la comunicación se utiliza el protocolo PROFINET.

El segundo flujo es el responsable de la consulta de los valores de presión y control. Ambos tipos de datos se integraron en un objeto JSON y se almacenaron en Archivos Separados por Coma (CSV). El intervalo de tiempo para la captura y almacenamiento de los datos fue de un segundo.




Fig. 4. Flujo Node-RED para captura de datos del proceso.

3) Creación de Dataset.

Inicialmente, se tomaron 23583 registros en buen funcionamiento modificando los valores de las variables SP, P, I. Durante este proceso se registraron los valores de las variables, en donde el PV alcanzó el valor de SP de forma estable. Se incorporaron los nombres de las columnas: Presion1, Presion2, Presion3, PV, Out, SP, P, I. Se etiquetaron los registros incorporando la columna OUTCOME, pronóstico, con valor = 0, que indica NO FALLA.

Posteriormente, se tomaron 7846 registros ante la presencia de fallo de "fuga en sellos de válvula PC1", modificando los valores de las variables SP, P, I únicamente con los valores en donde en el paso anterior la PV alcanzó de forma estable la SP. Se incorporaron los nombres de las columnas: Presion1, Presion2, Presion3, PV, Out, SP, P, I. Se etiquetaron los registros incorporando la columna OUTCOME con valor = 1, que indica FALLA.

Finalmente, se tomaron 9841 registros ante la presencia de fallo de "fuga a la atmósfera entre la salida de PC1 y PV1, modificando los valores de las variables SP, P, I únicamente con los valores en donde en el paso anterior la PV alcanzó de forma estable la SP. Se incorporaron los nombres de las columnas: Presion1, Presion2, Presion3, PV, Out, SP, P, I. Se etiquetaron los registros incorporando la columna OUTCOME con valor = 1, que indica FALLA. Se integraron todos los registros formando un Dataset con 41270 registros. Durante el proceso, se crearon notebooks de Jupyter utilizando el lenguaje Python para el tratamiento de los datos. Posteriormente se eliminaron registros de los Dataset que tenían valores en cero en donde no correspondía y una vez que los Dataset estuvieron listos, se procedió a unirlos y desordenarlos. En Fig. 5, se muestra una parte del Dataset creado.

Relation: Sensor_DATASET_FINAL									
No.	1: Presion1 Numeric	2: Presion2 Numeric	3: Presion3 Numeric	4: PV Numeric	5: Out Numeric	6: SP Numeric	7: P Numeric	8: I Numeric	9: Outcome Numeric
1	1.495	1.386	1.064	5.5	9.23	5.5	35.0	50.0	1.0
2	1.507	1.266	1.034	4.4	0.0	3.0	100.0	1.0	0.0
3	1.497	1.266	1.035	2.87	0.0	2.0	1.0	0.0	0.0
4	1.52	1.415	1.071	5.49	11.66	5.5	35.0	50.0	0.0
5	1.509	1.397	1.067	3.46	11.03	3.5	25.0	60.0	1.0
6	1.523	1.366	1.059	4.48	7.47	4.5	25.0	75.0	1.0
7	1.517	1.405	1.068	4.68	10.85	4.7	25.0	75.0	0.0
8	1.52	1.414	1.071	4.18	11.5	4.2	25.0	60.0	0.0
9	1.51	1.266	1.034	3.18	0.0	3.0	100.0	0.0	0.0
10	1.518	1.265	1.034	5.93	0.0	5.5	35.0	50.0	1.0
11	1.52	1.402	1.068	3.72	10.09	3.8	25.0	60.0	1.0
12	1.499	1.266	1.035	2.27	0.0	2.0	1.0	0.0	0.0
13	1.532	1.384	1.064	3.81	9.17	3.8	25.0	60.0	0.0
14	1.52	1.377	1.063	3.83	8.06	3.8	25.0	60.0	1.0

Fig. 5. Muestra de la estructura final del Dataset.

D. Entrenamiento de modelos de Aprendizaje Automático y puesta en producción

Se entrenaron y evaluaron cuatro modelos de Aprendizaje Automático, utilizando las siguientes métricas: Coeficiente De Correlación, Error Absoluto Medio, Raíz de Error Cuadrático, Error Relativo Absoluto, Error Relativo Cuadrático.

Los modelos entrenados y evaluados fueron:

- Regresión Logística.
- Árbol Aleatorio.
- Bosque Aleatorio.
- Perceptrón Multicapa de Clasificación.

El modelo seleccionado para poner en producción fue Perceptrón Multicapa. Para la puesta en producción se montó un servidor de aplicaciones Web Uvicorn con Linux sobre una imagen de Docker. Con esto se logró que el modelo funcionase como un servicio donde la consulta son los registros del proceso en un determinado momento, estos registros son pasados al modelo para su evaluación obteniendo como resultado un pronóstico de falla.

Resultados

En la tabla III se muestran los desempeños obtenidos por los modelos en las predicciones.

TABLA III. Desempeño de los modelos entrenados para predecir fallas

Modelo	Porcentaje general de aciertos (%)
Regresión Logística	35.8
Árbol Aleatorio	99.4
Bosque Aleatorio	99.7
Perceptrón Multicapa de Clasificación	96

El Modelo de Regresión Logística necesita mejoras, ya que su capacidad predictiva es baja y apenas supera un predictor trivial (la media). Los resultados fueron los esperados porque este modelo no es el más adecuado para la cantidad y la multi variedad de valores del Dataset. Los modelos de Árbol y Bosque Aleatorio, tienen una capacidad predictiva sobresaliente, son altamente precisos. Si no hay overfitting o sobreajuste, son modelos excelentes para la tarea. El Modelo Perceptrón Multicapa MLP en su variante de clasificación, implementa Redes Neuronales profundas. Se creó una instancia del modelo con las siguientes características:

- Escalamiento preliminar de los datos.
- 8 neuronas de entrada y 2 de salida.
- 100 capas de neuronas ocultas.
- 10000 iteraciones con algoritmo de optimización ADAM.
- Ratio de aprendizaje de 1-5.

El modelo produjo un rendimiento del 0.96 (96%). La matriz de confusión se muestra en Fig. 6.

[[5317 160]				
[237 4159]]				
	precision	recall	f1-score	support
0	0.96	0.97	0.96	5477
1	0.96	0.95	0.95	4396
accuracy			0.96	9873
macro avg	0.96	0.96	0.96	9873
weighted avg	0.96	0.96	0.96	9873

Fig. 6. Matriz de Confusión del Modelo Perceptrón Multicapa.

La Matriz de Confusión muestra que produjo 160 falsos positivos y 237 falsos negativos lo que indica que está muy bien equilibrado y su desempeño es excelente. Por lo que puede utilizarse para pronosticar fallos en el proceso industrial.

En la Fig. 7 se muestra gráficamente la estructura de la red neuronal.




Fig. 7. Red Neuronal MLP puesta en producción.

Conclusiones

Considerando los resultados obtenidos, así como la puesta en producción del Modelo Perceptrón Multicapa MLP entrenado, se concluye que es factible implementar modelos de Aprendizaje Automático. El Modelo de Regresión Logística es muy simple, por lo que sus resultados no son aceptables para ser implementado.

Los modelos que se pueden utilizar en producción son: Perceptrón Multicapa y Bosque Aleatorio o Random Forest.

Consideraciones importantes sobre estos modelos:

- Perceptrón Multicapa consume bastante poder de proceso y tiempo durante el entrenamiento.
- El ajuste de Perceptrón Multicapa puede llegar a ser complejo, el investigador debe comprender muy bien cómo funciona y los algoritmos de optimización que lo conforman.
- Bosque Aleatorio es una mejora significativa, ya que combina múltiples árboles para reducir el error y mejorar la precisión.
- Si se busca un mejor rendimiento y menos sobreajuste, Perceptrón Multicapa y Bosque Aleatorio son la mejor opción.
- Se debe utilizar Bosque Aleatorio si se quiere mayor precisión y estabilidad en las predicciones.
- Se debe utilizar Perceptrón Multicapa de Clasificación, si se posee suficiente tiempo y poder de proceso, ya que puede

optimizarse para que se ajuste a datos multi variados como los que se producen en un proceso industrial.

En general, el proyecto demostró que es posible utilizar Modelos de Aprendizaje Automático para pronosticar fallas en un proceso industrial como el utilizado en esta investigación.

El mantenimiento predictivo es un elemento clave en el proceso de fabricación moderno. Puede utilizarse en industrias como la automovilística, la aeroespacial, la energética y la manufacturera, entre otros.

El mantenimiento predictivo puede ayudar a las empresas a ahorrar dinero reduciendo el tiempo de inactividad y evitando averías en los equipos. Las empresas pueden mejorar su servicio al cliente.

El mantenimiento predictivo prevé futuros acontecimientos adversos para programar el mantenimiento antes de que se produzcan las fallas.

Referencias

- [1] W. Dunn, *Fundamentals of Industrial Instrumentation and Process Control*, 2a.ed. Estados Unidos: McGraw-Hill, 2018.
- [2] A. Brunete, P. San Segundo y R. Herrero, "Sensores y actuadores" en *Introducción a la Automatización Industrial*, Madrid, España: Universidad Politécnica de Madrid, 2025. Cap. 2. pp. 36-65. [En línea]. Disponible en: <https://bookdown.org/alberto-brunete/intro-automatizada/intro-automatizada.pdf>
- [3] Sensores de automatización industrial. Guía de selección, RS. PRO, Londres, Inglaterra, pp.2-30. [En línea]. Disponible en: <https://surl.la/nbarft>
- [4] H. Ali, S. Noor, S. M., Bashi, and M.H. Marhaban, "A Review of Pneumatic Actuators (Modeling and Control)". ResearchGate. Aust. J. [On line]. Available: https://www.researchgate.net/publication/223260423_A-Review_of_Pneumatic_Actuators_Modeling_and_Control
- [5] M. S. Xavier et al., "Soft Pneumatic Actuators: A Review of Design, Fabrication, Modeling, Sensing, Control and Applications". IEEE Access. vol. 10, pp.1-44, Accessed Jun. 22 [On line]. Available: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9785890>
- [6] G. Buckbee, "Final control elements", *Process control basics*, 1a ed. Estados Unidos: International Society of Automation (ISA), 2022, Cap. 5, pp. 73-91. [On line]. Available: <https://shre.ink/oD8e>
- [7] E. Manrique Rojas, "Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo", Risti, vol. 04, no. E28, pp-586-599, Fe. 2020. Accedido: 20 ago. 2025, [En línea]. Disponible en: https://media.proquest.com/media/hms/PFT/1/OSI9G?_s=pV2Pzcal8RftJa0Qyn708Gzh0Mc%3D
- [8] Deloitte. "Introduction to predictive maintenance (PdM)". Accessed: 10 jul. 2025. [On line]. Available: <https://www.deloitte.com/us/en/services/consulting/services/predictive-maintenance-and-the-smart-factory.html>
- [9] D. Bergman. "¿What is Machine Learning?" IBM. Accessed: 15 de enero de 2024. [On line]. Available: <https://www.ibm.com/think/topics/machine-learning>
- [10] P. De Wilde, "Neural Network Models: Theory and Projects", 2° ed. New York, U.S.A. Springer SBM, 2013. [On line]. Available: <https://shre.ink/o8C1>
- [11] F. Lee, "¿What are Neural Networks?" IBM. Accessed: 15 de enero de 2024. [On line]. Available: <https://www.ibm.com/think/topics/neural-networks>
- [12] J. Dalzochio, R. Kunst, E. Pignaton, A. Binotto, J. Barbosa, "Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges", *Comput. Ind.*, vol. 123, Art. 103301, dic. 2020. Accessed: 15 de enero de 2024, doi: 10.1016/j.compind.2020.103298. [On line]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S0166361520305327>
- [13] A. Kanawaday y A. Sane, "Machine learning for predictive maintenance of industrial machines using IoT sensor data", en *2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS)*, Pekin, China, 2017, pp. 87-90. [On line]. Available: <https://ieeexplore.ieee.org/document/8342870/authors#authors>
- [14] AWS Industrial IoT Predictive Maintenance ML Model Reference Architecture, AWS Industrial. (2020). Architecture Diagrams [PDF]. Available: <https://d1.awsstatic.com/architecture-diagrams/ArchitectureDiagrams/aws-industrial-PdM-ML-storage-RA.pdf>
- [15] G. Liguori, "Predictive maintenance in industry 4.0: applications and advantages". CodeX. Accessed: 15 ene. 2024. [On line]. Available en: <https://medium.com/codex/predictive-maintenance-in-industry-4-0-applications-and-advantages-72bd7383823e>
- [16] C. S. Kulkarni, M. J. Daigle, G. Gorospe, and K. Goebel, "Experimental Validation of Model-Based Prognostics for Pneumatic Valves", *International journal of prognostics and health management*, vol. 8, p. 018, 2017. Accessed: Falta fecha de acceso [On line]. Available: <https://pubmed.ncbi.nlm.nih.gov/32747869/>
- [17] M. Daigle, C. S. Kulkarni and G. Gorospe, "Application of model-based prognostics to a pneumatic valves testbed", *2014 IEEE Aerospace Conference*, Big Sky, MT, USA, 01-08 Mar., 2014, pp. 1-8, doi: 10.1109/AERO.2014.6836319