



ITCA
FEPADE

INFORME FINAL DE INVESTIGACIÓN

ESTUDIO DE LA APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA LA IMPLEMENTACIÓN DE MANTENIMIENTO PREDICTIVO EN UNA PLANTA DE CONTROL DE PROCESOS INDUSTRIALES

APLICACIÓN EN ITCA-FEPADE SEDE CENTRAL

DOCENTE INVESTIGADOR PRINCIPAL

ING. JUAN JOSÉ GUEVARA VÁSQUEZ

DOCENTE COINVESTIGADOR

TÉC. CARLOS GEOVANY MELÉNDEZ MOLINA

**ESCUELA DE INGENIERÍA
ELÉCTRICA Y ELECTRÓNICA.
ITCA-FEPADE SEDE CENTRAL**

ENERO 2025



MINISTERIO
DE EDUCACIÓN,
CIENCIA Y
TECNOLOGÍA



ESCUELA ESPECIALIZADA EN INGENIERÍA ITCA-FEPADE
DIRECCIÓN DE INVESTIGACIÓN Y PROYECCIÓN SOCIAL
SANTA TECLA, LA LIBERTAD, EL SALVADOR, CENTRO AMÉRICA





ITCA
FEPADE

INFORME FINAL DE INVESTIGACIÓN

ESTUDIO DE LA APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA LA IMPLEMENTACIÓN DE MANTENIMIENTO PREDICTIVO EN UNA PLANTA DE CONTROL DE PROCESOS INDUSTRIALES

APLICACIÓN EN ITCA-FEPADE SEDE CENTRAL

DOCENTE INVESTIGADOR PRINCIPAL

ING. JUAN JOSÉ GUEVARA VÁSQUEZ

DOCENTE COINVESTIGADOR

TÉC. CARLOS GEOVANY MELÉNDEZ MOLINA

**ESCUELA DE INGENIERÍA
ELÉCTRICA Y ELECTRÓNICA.
ITCA-FEPADE SEDE CENTRAL**

ENERO 2025



MINISTERIO
DE EDUCACIÓN,
CIENCIA Y
TECNOLOGÍA



ESCUELA ESPECIALIZADA EN INGENIERÍA ITCA-FEPADE
DIRECCIÓN DE INVESTIGACIÓN Y PROYECCIÓN SOCIAL
SANTA TECLA, LA LIBERTAD, EL SALVADOR, CENTRO AMÉRICA



Rector

Ing. Carlos Alberto Arriola Martínez

Vicerrector

Ing. Christian Antonio Guevara Orantes

**Director de Investigación
y Proyección Social**

Ing. Mario W. Montes Arias

**Dirección de Investigación
y Proyección Social**

Ing. David Emmanuel Ágreda Trujillo

Inga. Jeannette Tatiana Galeas Rodríguez

Téc. Cristina Michellé Vásquez Hernández

Sra. Delmy Roxana Reyes Zepeda

**Director de Escuela de
Ingeniería Eléctrica y Electrónica**

Ing. Carlos Roberto García

621.381

G939e Guevara Vásquez, Juan José, 1978 -

slv Estudio de la aplicación de Inteligencia Artificial para la implementación de mantenimiento predictivo en una planta de control de procesos industriales: Aplicación en ITCA – FEPAD Sede Central / Juan José Guevara Vásquez y Carlos Geovany Meléndez Molina. -- 1ª ed. -- Santa Tecla, La Libertad, El Salv.: ITCA Editores, 2025.

56 p. il.; 28 cm.

ISBN: 978-99983-69-47-4 (Impreso)

ISBN: 978-99983-69-48-1 (E-Book, pdf)

1. Inteligencia Artificial – Aplicaciones Industriales. 2. Aprendizaje Automático (Inteligencia Artificial) 3. Procesamiento electrónico de datos. I. Meléndez Molina, Carlos Geovany, 1985-, coaut - II. Título

Autor

Ing. Juan José Guevara Vásquez

Coautor

Téc. Carlos Geovany Meléndez Molina

Tiraje: 13 ejemplares

Año 2025

Este documento técnico es una publicación de la Escuela Especializada en Ingeniería ITCA-FEPAD; tiene el propósito de difundir la Ciencia, la Tecnología y la Innovación CTI, entre la comunidad académica, el sector empresarial y la sociedad, como un aporte al desarrollo del país. Para referirse al contenido debe citar el nombre del autor y el título del documento. El contenido de este Informe es responsabilidad de los autores.



Atribución-No Comercial
Compartir Igual
4.0 Internacional

Esta obra está bajo una licencia Creative Commons. No se permite el uso comercial de la obra original ni de las posibles obras derivadas, cuya distribución debe hacerse mediante una licencia igual que la sujeta a la obra original.

Escuela Especializada en Ingeniería ITCA-FEPAD

Km 11.5 carretera a Santa Tecla, La Libertad, El Salvador, Centro América

Sitio Web: www.itca.edu.sv

TEL: (503)2132-7423

CONTENIDO

1.	INTRODUCCIÓN.....	6
2.	PLANTEAMIENTO DEL PROBLEMA	7
2.1.	DEFINICIÓN DEL PROBLEMA.....	7
2.2.	ANTECEDENTES / ESTADO DE LA TÉCNICA.....	7
2.3.	JUSTIFICACIÓN	7
3.	OBJETIVOS.....	8
3.1.	OBJETIVO GENERAL.....	8
3.2.	OBJETIVOS ESPECÍFICOS	8
4.	HIPÓTESIS.....	8
5.	MARCO TEÓRICO	8
5.1.	CONTROL DE PROCESOS	8
5.2.	SENSORES Y TRANSDUCTORES	9
	VÁLVULAS DE CONTROL	10
5.3.	APRENDIZAJE AUTOMÁTICO Y APRENDIZAJE PROFUNDO.....	11
	RED NEURONAL	11
5.4.	MANTENIMIENTO PREDICTIVO	12
	ENTRENADOR DE CONTROL DE PROCESOS DE FLUJO Y PRESIÓN	13
6.	METODOLOGÍA DE INVESTIGACIÓN	14
6.1.	AUTOMATIZACIÓN DEL ENTRENADOR DE CONTROL DE PROCESOS DE FLUJO Y PRESIÓN	14
	CONTROL DE LAZO CERRADO (RETROALIMENTACIÓN)	17
	COMPONENTES CLASE Y SU FUNCIÓN.....	17
	ESTRATEGIAS DE CONTROL POTENCIALES.....	17
6.2.	DISEÑO DEL SISTEMA DE GENERACIÓN DE FALLAS	18
	REGISTRO DE LOS DATOS DEL PROCESO INDUSTRIAL	20
	DATALOGGER.....	20
	CREACIÓN DEL DATASET	22
	ENTRENAMIENTO Y EVALUACIÓN DE MODELOS DE CLASIFICACIÓN DE APRENDIZAJE AUTOMÁTICO	25
7.	RESULTADOS	32
7.1.	MODELOS DE APRENDIZAJE AUTOMÁTICO	32
8.	CONCLUSIONES.....	39
9.	RECOMENDACIONES.....	40
10.	GLOSARIO.....	41
11.	REFERENCIAS BIBLIOGRÁFICAS.....	43
12.	ANEXOS.....	44
12.1.	ESPECIFICACIONES TÉCNICAS DE PV1 BADGER SERIE: 1002GCN36SV0AEP36	44
12.2.	ANEXO 2. ESPECIFICACIONES TÉCNICAS DE PC1 ABB TEIP11	46
12.3.	ANEXO 3. ESPECIFICACIONES TÉCNICAS DE LOS SENSORES DE PRESIÓN	49
12.4.	ANEXO 4. ESPECIFICACIONES TÉCNICAS DE ADS1115.....	53
12.5.	ANEXO 5. ESPECIFICACIONES TÉCNICAS DE RASPBERRY PI 4	54

1. INTRODUCCIÓN

En este informe se describe el proceso de investigación efectuado por los docentes investigadores de la Escuela de Ingeniería Eléctrica y Electrónica, en el estudio de la aplicación de inteligencia artificial en autómatas programables para la implementación de mantenimiento predictivo en una planta de control de procesos industriales. La investigación buscó identificar y evaluar modelos de aprendizaje automático que una vez entrenados puedan predecir el estado operativo del proceso industrial de flujo y presión con una exactitud superior al 90%.

El mantenimiento predictivo asistido por inteligencias artificiales es cada vez más utilizado en industria 4.0 debido a que no requieren de la supervisión constante de personal de producción y mantenimiento por lo que pueden funcionar de forma autónoma detectando patrones anómalos y fallas que permiten actuar con previsión y rapidez reduciendo paros no programados que afectan la producción. El diseño y entrenamiento de un sistema neuronal que recolecte información en tiempo real de un proceso industrial permite caracterizar la información del buen funcionamiento de los actuadores del proceso, permitiendo determinar cuándo deben realizarse ajustes para prevenir fallos con lo cual se reducen los tiempos de paro de las máquinas. Por esta razón, una institución de nivel superior con carreras relacionadas a la mecatrónica, desarrollo de software y electrónica, debe incursionar en este campo a nivel investigativo para dotar a los laboratorios de material académico y equipos de práctica con los cuales se puedan realizar prácticas de redes neuronales y de mantenimiento predictivo.

El trabajo de investigación consistió en automatizar un entrenador de proceso de flujo y presión REGA para publicar los datos de funcionamiento en tiempo real. Se extrajo la información de funcionamiento de los actuadores lineales de un proceso industrial de flujo y presión en tiempo real para ponerlo a disposición de una red neuronal. Se identificaron y se experimentó con las principales técnicas de aprendizaje automático que son parte de la inteligencia artificial. Posteriormente se aplicó el aprendizaje automático a los datos operativos de la planta de control de procesos industriales del entrenador, para detectar patrones de comportamiento de uno de los actuadores lineales. Finalmente se diseñó una Red de Procesamiento Neuronal que analiza la información de un proceso industrial de flujo y presión en tiempo real para su procesamiento y análisis.

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 en buen y mal funcionamiento para crear un conjunto de datos dataset clasificados. Con el dataset creado, se entrenó y evaluó el rendimiento de predicción 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.

Los resultados de las evaluaciones de los modelos permitieron identificar aquellos que resultan ideales para la predicción de fallas con un desempeño mayor al 90 % de aciertos siendo especialmente destacados los modelos de bosque aleatorio y perceptrón multicapa. Se concluye entonces, que es posible aplicar la inteligencia artificial para la predicción de fallas en un control de procesos industriales de flujo y presión.

Se recomienda continuar con el proceso de investigación en donde, primeramente, se analice y mejore el proceso de recolección de datos del proceso para optimizar los dataset, para posteriormente ajustar los parámetros de entrenamiento del modelo de aprendizaje automático utilizado. Además, se recomienda estudiar la aplicación de modelos que permitan aplicar estimación de tiempo de vida útil RUL en la válvula de proceso con lo cual se completaría la estructura del entrenador de procesos industriales para mantenimiento predictivo.

2. PLANTEAMIENTO DEL PROBLEMA

2.1.DEFINICIÓN DEL PROBLEMA

La Sede Central de la Escuela Especializada en Ingeniería ITCA-FEPADE, no dispone de ningún estudio de la aplicación de sistemas de aprendizaje automático ni de entrenadores para mantenimiento predictivo en donde docentes y estudiantes puedan realizar discusiones y prácticas de laboratorio.

2.2.ANTECEDENTES / ESTADO DE LA TÉCNICA

Los microcontroladores industriales son chips fiables diseñados para la precisión. Suelen encargarse de controlar robots industriales, máquinas herramienta y tareas de automatización. Una nueva tendencia en la automatización industrial es el uso de Inteligencia Artificial IA y Machine Learning ML para mejorar la eficiencia y productividad de los robots industriales. La IA y el ML se utilizan para extraer información valiosa de las redes de sensores. Este es uno de los motivos por los que la mayoría de los microcontroladores industriales están incorporando unidades de procesamiento neuronal NPU en chips o integradas. Estas unidades integran la IA y el aprendizaje profundo en los sistemas de control y las aplicaciones de automatización.

Una empresa líder en aplicación de IA y ML en automatización es Omron, que está produciendo soluciones de controladores de máquina equipados con un algoritmo de inteligencia artificial IA de aprendizaje automático Machine Learning. El AI Equipped Machine Automation Controller es el primero de una serie de tecnologías de automatización IA e Internet de Cosas IoT que la compañía ha lanzado en un intento de abordar problemas de fabricación tales como la escasez de ingenieros calificados y el aumento de los costos laborales. Omron tiene como meta convertir todos sus equipos de Factory Automation FA en AI / IoT y cree que AI ayudará a reemplazar las habilidades de los trabajadores experimentados que están llegando al final de su vida laboral.

Se dice que el controlador equipado con AI consigue una integración en tiempo real entre los controles de la línea de producción y el procesamiento de AI. Utilizando entradas de sensores que supervisan el estado de los equipos y procesos, el controlador aplica un modelo causal, aprendido por la IA incorporada, para predecir comportamientos inusuales de la maquinaria y controlarlos con seguridad antes de que puedan ocurrir problemas. Los algoritmos AI permiten al controlador aprender sobre los movimientos repetitivos de la máquina a partir de los datos de detección y controlar el estado de la maquinaria y controlarla en tiempo real.

En El Salvador es un campo muy poco explorado a nivel de investigación, no se encontraron trabajos de investigación a nivel local que estén relacionados con el área de aplicación que se aborda en esta propuesta.

2.3.JUSTIFICACIÓN

El auge de los sistemas de inteligencia artificial y aprendizaje automático no ha pasado por alto en la industria en los procesos de automatización de procesos en plantas cada vez más inteligentes. La industria 4.0 considera a la IA, ML y al mantenimiento predictivo como partes importantes de la infraestructura de fábricas automatizadas. Por esta razón, una institución de nivel superior con carreras relacionadas a la mecatrónica, desarrollo de software y electrónica debe incursionar en este campo a nivel investigativo para dotar a los laboratorios de material académico y equipos de práctica con los cuales se puedan realizar prácticas de redes neuronales y de mantenimiento predictivo.

3. OBJETIVOS

3.1.OBJETIVO GENERAL

Estudiar la factibilidad de la aplicación de Inteligencia Artificial IA y Aprendizaje Automático ML en Autómatas Programables para la implementación de mantenimiento predictivo en una planta de control de procesos industriales (Etapa 1).

3.2.OBJETIVOS ESPECÍFICOS

- Extraer la información de funcionamiento de los actuadores lineales de un proceso industrial de flujo y presión en tiempo real para ponerlo a disposición de una red neuronal.
- Identificar y Experimentar con las principales técnicas de aprendizaje automático que son parte de la inteligencia artificial.
- Aplicar aprendizaje automático a los datos operativos de una planta de control de procesos industriales para detectar patrones de comportamiento de uno de los actuadores lineales.
- Diseñar una Red de Procesamiento Neuronal que procese la información de un proceso industrial de flujo y presión en tiempo real para su procesamiento y análisis.

4. HIPÓTESIS

El diseño y entrenamiento de un sistema neuronal que recolecte información en tiempo real de un proceso industrial permite caracterizar la información del buen funcionamiento de los actuadores del proceso, permitiendo determinar cuándo deben realizarse ajustes para prevenir fallos con lo cual se reducen los tiempos de paro de las máquinas.

5. MARCO TEÓRICO

5.1. CONTROL DE PROCESOS

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. El control del proceso es el control automático de una variable de salida al detectar la amplitud del parámetro de salida del proceso y comparándolo con el nivel deseado o establecido y retroalimentando una señal de error para controlar una variable de entrada [1].




Fig. 1. Diagrama típico de un proceso controlado con realimentación.

En todo proceso hay una serie de insumos, es decir, desde productos químicos hasta mercancías sólidas. Estos son manipulados en el proceso y un nuevo producto químico o compuesto emerge en la salida. Las entradas y salidas controladas del proceso se denominan variables como se muestra en la figura 1. En una instalación de control de procesos, el controlador no está necesariamente limitado a una variable por lo que puede medir y controlar muchas variables. La mayoría de las variables controladas representan a seis u ocho dispositivos como por ejemplo los cilindros de un motor de combustión.

5.2. SENSORES Y TRANSDUCTORES

El término sensor se refiere a un elemento que produce una señal relacionada con la cantidad que se está midiendo. Por ejemplo, si se está midiendo la temperatura con un sensor resistivo, la cantidad que se mide es temperatura y el sensor transforma la entrada en cambios en la resistencia eléctrica. Por lo general se utiliza el término transductor en lugar de sensor.

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. Por otra parte, el término digital se utiliza cuando los sistemas ofrecen salidas que son digitales por naturaleza.

Los siguientes términos describen las características de funcionamiento de los transductores y de los sistemas de medición:

- **Intervalo y extensión:** define los límites entre los cuales puede variar la entrada.
- **Error:** es la diferencia entre el resultado de una medición y el valor verdadero de la cantidad que se mide:

$$\text{error} = \text{valor medido} - \text{valor real}$$

- **Exactitud:** es el grado hasta el cual un valor producido por un sistema de medición puede estar equivocado. Es, por lo tanto, la suma de todos los errores posibles más el error en la exactitud de la calibración del transductor.
- **Sensibilidad:** es la relación que indica cuanta salida se obtiene por unidad de entrada, es decir, salida/entrada. Por ejemplo, un termómetro de resistencia puede tener una sensibilidad de $0.5\Omega/^{\circ}\text{C}$.
- **Error por histéresis:** se produce cuando los transductores producen salidas distintas a partir de la misma cantidad medida ya sea por incremento o decremento continuo.
- **Error por no linealidad:** se supone que, en su intervalo de funcionamiento, la relación entre la entrada y la salida del transductor es lineal. Sin embargo, esto no es así, por lo que este error se define como desviación máxima respecto a la línea recta.
- **Repetibilidad/reproducibilidad:** describe la capacidad del transductor para producir la misma salida después de aplicar varias veces el mismo valor de entrada. El error relacionado consiste en no obtener la misma salida después de aplicar el valor de entrada, se representa como un porcentaje del intervalo total de salida:

$$\text{repetibilidad} = \frac{\text{val. max} - \text{val. min}}{\text{intervalo total}} * 100$$

- **Estabilidad:** es la capacidad que posee un transductor para producir la misma salida cuando se usa para medir una entrada constante en un período.
- **Banda/tiempo muerto:** es el intervalo de valores de entrada para los cuales no hay salida.
- **Resolución:** es el cambio mínimo del valor de entrada capaz de producir un cambio observable en la salida.
- **Impedancia de salida:** cuando un sensor produce una salida eléctrica se conecta con otro circuito electrónico, es necesario conocer su impedancia de salida ya que esta se va a conectar en serie o en paralelo. Si no se toma en cuenta la impedancia de salida al conectar el sensor, el funcionamiento del sistema puede verse afectado [2], [3], [4].

VÁLVULAS DE CONTROL

Son válvulas que pueden ser manipuladas para regular con precisión el flujo de un proceso de fluidos. Las válvulas de control deben cumplir un exigente conjunto de requisitos para garantizar un control exacto y preciso. Las válvulas de accionamiento manual también se utilizan en todas las plantas. Pueden abrirse o cerrarse con una palanca, una rueda o una cadena. Estas válvulas no se consideran válvulas de control. Sin embargo, es posible que un operario atento consiga cierto control del proceso utilizando válvulas accionadas manualmente.

La válvula de control debe estar correctamente diseñada, dimensionada para el rango normal de caudales y presiones, fabricada con los materiales adecuados y funcionar correctamente en todo el rango de operación. 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, como se muestra en la figura 2. 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.




Fig. 2. Conjunto de válvula de control.

Un 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 [5].

5.3. APRENDIZAJE AUTOMÁTICO Y APRENDIZAJE PROFUNDO

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. El aprendizaje automático 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. Posteriormente, estos conocimientos impulsan la toma de decisiones dentro de las aplicaciones y las empresas, lo que idealmente repercute en las métricas de crecimiento clave. A medida que los macrodatos sigan expandiéndose y creciendo, aumentará la demanda de científicos de datos en el mercado. Los algoritmos de aprendizaje automático suelen crearse utilizando marcos que aceleran el desarrollo de soluciones, como TensorFlow y PyTorch.

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.

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, para informar a su algoritmo, pero no requiere necesariamente un conjunto de datos etiquetados. 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 [6].

RED NEURONAL

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 señalan entre sí. Las redes neuronales artificiales (RNA) 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 a la siguiente capa de la red.

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 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 [7].




Fig. 3. Red neuronal profunda.

5.4. MANTENIMIENTO PREDICTIVO

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 una investigación realizada por Deloitte, una estrategia de mantenimiento no optimizada puede reducir la capacidad de producción de una planta industrial entre un 5 y un 20%. Estudios recientes muestran también que los tiempos de inactividad cuestan a los fabricantes industriales unos 45.000 millones de euros al año.

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. El mantenimiento predictivo puede ayudar a las empresas a ahorrar dinero reduciendo el tiempo de inactividad y evitando averías en los equipos, ayuda a las empresas a mejorar su servicio al cliente permitiéndoles planificar las averías de los equipos. Por otra parte, este tipo de mantenimiento pretende predecir futuros acontecimientos adversos para programar mejor el mantenimiento.

Al predecir los fallos antes de que se produzcan, las empresas pueden evitar el coste y los inconvenientes del tiempo de inactividad. El mantenimiento predictivo también ayuda a las empresas a optimizar sus recursos programando el mantenimiento preventivo en los momentos en que tendrá menos impacto en la producción.

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.

La inteligencia artificial es capaz de procesar grandes cantidades de datos complejos en muy poco tiempo, por lo que muchas decisiones se delegan ahora 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. 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 [8], [9].




Fig. 4. Procedimiento de desarrollo de un modelo para mantenimiento predictivo.

ENTRENADOR DE CONTROL DE PROCESOS DE FLUJO Y PRESIÓN

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. 5. Diagrama del sistema del entrenador de flujo y presión.

6. METODOLOGÍA DE INVESTIGACIÓN

6.1. AUTOMATIZACIÓN DEL ENTRENADOR DE CONTROL DE PROCESOS 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.



Fig. 6. Estado inicial del gabinete de control del entrenador de flujo y presión.

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, 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.




Fig. 7. Montaje del PLC en el gabinete de control del entrenador de flujo y presión.

Las salidas digitales del PLC se conectaron a las bobinas de los relés electromecánicos KI, KAI, KA2, KA3, KA4, RY1, RY2, RY3, RY4. Estos relés actuaron como interruptores controlados por el PLC, permitiendo el manejo de la alimentación de las electroválvulas YV1, YV2, YV3, YV4 y el circuito de control de las válvulas de control de flujo OMI y los contactores KMI. La lámpara indicadora HLI se cableó a través de un contacto de relé para proporcionar señalización visual del estado del sistema.

Todas las conexiones eléctricas se realizaron utilizando cableado adecuado y siguiendo el esquema eléctrico de referencia, prestando especial atención a la polaridad y a las normativas de seguridad eléctrica. Se utilizaron borneras para facilitar las conexiones y permitir un mantenimiento más sencillo. Una vez finalizado el cableado, se llevó a cabo una revisión exhaustiva para verificar la correcta conexión de cada componente y la ausencia de cortocircuitos o errores de cableado.

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.

El diagrama de control y potencia se muestra a continuación.




Fig. 8. Diagrama de control y potencia del entrenador de flujo y presión.

CONTROL DE LAZO CERRADO (RETROALIMENTACIÓN)

En un sistema de control de lazo cerrado, la salida del proceso (presión medida por el transmisor) se retroalimenta al controlador (PLC). El controlador compara esta señal con el valor deseado (programado en el PLC o establecido por el operador). Si existe una desviación, el controlador calcula una señal de control apropiada para el actuador (electroválvula en este caso) con el objetivo de llevar la presión del proceso al valor de referencia.

COMPONENTES CLASE Y SU FUNCIÓN

Transmisor de Presión (PTI). Este dispositivo es un sensor fundamental en el sistema de control. Su función principal es convertir la magnitud física de la presión del proceso en una señal eléctrica estándar y proporcional (típicamente 4-20 mA). Esta señal eléctrica es interpretada por el módulo de entrada analógica del PLC, proporcionando una medición continua y en tiempo real de la presión del sistema. La precisión y el rango de medición del transmisor son cruciales para el rendimiento general del control.

Sensor de Presión (PSV): A diferencia del transmisor, que proporciona una señal continua, el sensor de (interruptor de presión) actúa como un dispositivo de detección de umbral. Se activa o desactiva cuando la presión del proceso alcanza un valor preestablecido. En este sistema, podría utilizarse para funciones de seguridad (alarma por sobrepresión o baja presión) o como un interlock.

PLC ET 200 Siemens. El Controlador Lógico Programable (PLC) es el cerebro del sistema de control. Recibe las señales de los sensores (transmisor y sensor de presión) y los pulsadores (interacción del operador). Basándose en la lógica de control programada, el PLC procesa estas señales y genera señales de salida para controlar los actuadores (electroválvulas y Servovalvulas a través de los relés y contactores). La flexibilidad del PLC permite implementar estrategias de control complejas y adaptadas a las necesidades específicas del proceso.

ESTRATEGIAS DE CONTROL POTENCIALES

Dependiendo de los requerimientos del proceso, se podrían implementar diversas estrategias de control en el PLC, tales como:

Control ON-OFF (de dos posiciones). La electroválvula se abre o se cierra completamente en función de si la presión está por encima o por debajo de un cierto umbral (posiblemente con histéresis para evitar oscilaciones).

Control Proporcional (P). La apertura de la electroválvula es proporcional al error entre la presión medida y el valor de referencia.

Control Proporcional-Integral (PI). Combina la acción proporcional con una acción integral para eliminar el error en estado estacionario.

Control Proporcional-Integral-Derivativo (PID). Añade una acción derivativa para mejorar la respuesta dinámica del sistema, anticipándose a los cambios en el error.

La elección de la estrategia de control dependerá de la dinámica del proceso, la precisión requerida y la necesidad de estabilidad. Para el proceso industrial de flujo y presión, el controlador implementado fue un Proporcional – Integral.

6.2. 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. En el anexo 1 se muestran las características de la válvula PV1 y en anexo 2 las de PC1.

Este convertidor transforma la corriente de 4 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 a la magnitud del error en la presión del proceso PV respecto a la presión deseada SP en D1 (Fig. 5). La unidad de mantenimiento de aire comprimido UM1 (figura 9) se ajusta para que la presión que se suministra a PC1 sea de hasta 1.2 bar, lo que proporciona a un margen de ajuste suficiente para variar la presión de control de acuerdo con la señal que recibe desde el PLC.

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 “a oído”.

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 de los 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 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 por [10], [11] es posible introducir fallas en el control neumático de una válvula de proceso y a partir del análisis de sus tiempos de apertura/cierre y de esta forma 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.

Como la válvula PV1 posee un actuador Air to Open ATO es normalmente cerrado por lo que 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 caería 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 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 sensores de presión de alta calidad, la solución propuesta se muestra en la figura siguiente:




Fig. 9. Sistema de generación de fallas en el control de la válvula de proceso PV1.

En la figura 9, se muestran tres sensores de presión, 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. La información técnica de los sensores de presión utilizados se muestra en el Anexo 3. Para simular una falla interna o en los sellos en PC1, se instaló una 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 atmosfera se instaló una válvula de aguja (V2) que permite la salida de presión produciendo una caída de esta.

REGISTRO DE LOS DATOS DEL PROCESO INDUSTRIAL

En su conjunto, los datos del proceso industrial se encuentran distribuidos en dos categorías:

- **Datos del proceso**, que corresponden a las variables del control de un proceso industrial proporcional – integral típico.

Tabla 2. Datos del Proceso de Flujo y Presión

Variables	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.

Los datos del proceso son capturados por el PLC y enviados a un datalogger utilizando el protocolo PROFINET.

- **Datos de presión de control**, que representan las presiones de aire en el control de PV1.

Tabla 3. Datos de Presión de Control

Variables	Descripción
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

Los datos de presión de control son tomados de los sensores de presión S1, S2, S3 que proporcionan a su salida corrientes de entre 4 y 20 mA las cuales son procesadas por el circuito datalogger.

6.3.DATALOGGER

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 muestra en la siguiente figura.

For 2 wire 4-20 mA sensors.



Fig. 10. Montaje del circuito datalogger.

6.4. CREACIÓN DEL DATASET

a. Selección 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 son los datos del proceso (tabla 2) y, datos de presión y control (tabla 3).

b. Mecanismo de captura de datos

El PLC es el controlador del proceso industrial por lo tanto es el responsable del manejo de los datos del proceso (tabla 2). Por otra parte, el datalogger es el responsable de la captura de los datos de presión y control.

Para la captura de los datos se crearon e integraron dos flujos en Node-RED, el primer flujo es responsable de la consulta de los valores de los datos del control del proceso (tabla 2).




Fig. 11. Flujo Node-RED para captura de datos 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 (tabla 3). 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. 12. Flujo Node-RED para registro de datos de presiones de control.

c. Creación del dataset

Para la creación del dataset se utilizó la siguiente estrategia:

- I. 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.
 - a. a.1 Se incorporaron los nombres de las columnas: Presion1, Presion2, Presion3, PV, Out, SP, P, I.
 - b. a.2 Se etiquetaron los registros incorporando la columna OUTCOME (pronóstico) con valor = 0, que indica NO FALLA.
- II. Se tomaron 7846 registros ante la presencia de fallo de **“fuga en sellos de válvula de control I/P”** 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.
 - a. b.1 Se incorporaron los nombres de las columnas: Presion1, Presion2, Presion3, PV, Out, SP, P, I.
 - b. b.2 Se etiquetaron los registros incorporando la columna OUTCOME con valor = 1, que indica FALLA.
- III. Se tomaron 9841 registros ante la presencia de fallo de **“fuga a la atmósfera entre la salida de la válvula de control I/P y la válvula de control del proceso de presión”** 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.
 - a. c.1 Se incorporaron los nombres de las columnas: Presion1, Presion2, Presion3, PV, Out, SP, P, I.
 - b. c.2 Se etiquetaron los registros incorporando la columna OUTCOME con valor = 1, que indica FALLA.

- IV. Se integraron todos los registros formando un dataset con 41270 registros. Para esto, se crearon notebooks de Jupyter utilizando el lenguaje Python para el tratamiento de los datos.

El siguiente notebook muestra el proceso de preparación inicial del conjunto de datos e inserción de la columna OUTCOME:

```
import pandas as pd

# Step 1: Read the CSV file into a DataFrame
csv_file_path = '../Datasets/Dataset_Final/RAW_data_sensor_p_ok_1.csv'

df = pd.read_csv(csv_file_path)

# Verificar los primeros cinco registros
df.head()
print(df)

# Remover la columna Fecha
df.drop('Fecha', inplace=True, axis=1)
#df.head()
print(df)

# Agregar la columna OUTCOME que es la etiqueta de los datos
# y asignar el valor 1 si hay falla y 0 si no hay falla.

#df['Outcome'] = 0
df['Outcome'] = 0
#df.head()
print(df)

# Guardar el fichero modificado
df.to_csv('../Datasets/Dataset_Final/DS_DATA_OK_1.csv', index=False)
```

Posteriormente se eliminaron registros de los dataset que tenían valores en cero en donde no correspondía, esto se hizo con el código del siguiente notebook:

Eliminar filas que tienen valor cero en Out

```
import pandas as pd

# Importar el archivo CSV
df = pd.read_csv('Dataset_investigacion/Sensor_P_DATASET_OK_NON_F.csv')

# Filtrar las filas de acuerdo con una condición
filtered_df = df[df['SP'] <= 6.0]
print(filtered_df)

## Guardar el nuevo dataset
filtered_df.to_csv('Dataset_investigacion\Sensor_P_DATASET_OK.csv', index=False)
```

Una vez que los dataset estuvieron listos, se procedió a unirlos y desordenarlos. Esto se hizo con el código del siguiente notebook:

Merging by names

```
import pandas as pd

# Merge (unir) archivos csv
df = pd.concat(
    map(pd.read_csv, ['Dataset_investigacion\Sensor_DATASET_OK.csv',
                      'Dataset_investigacion\Sensor_DATASET_BAD_A.csv',
                      'Dataset_investigacion\Sensor_DATASET_BAD_B.csv']), ignore_index=True)

print(df)
```

Desordenar o mezclar registros

```
# Reordenar aleatoriamente

shuffled_df = df.sample(n=len(df))

# Reset the index of the shuffled DataFrame
shuffled_df = shuffled_df.reset_index(drop=True)

print(shuffled_df)
```

Guardar el fichero creado

```
# Guardar el fichero modificado
shuffled_df.to_csv('Dataset_investigacion\Sensor_DATASET_FINAL.csv', index=False)
```

En la siguiente figura se muestra parte de la estructura del dataset creado.

Relation: Sensor_DATASET_FINAL									
No.	1: Presion1	2: Presion2	3: Presion3	4: PV	5: Out	6: SP	7: P	8: I	9: Outcome
	Numeric	Numeric	Numeric	Numeric	Numeric	Numeric	Numeric	Numeric	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. 13. Estructura final del dataset.

Entrenamiento y evaluación de modelos de clasificación de aprendizaje automático

Para el entrenamiento se implementó un marco de trabajo compuesto por las siguientes herramientas:

- Biblioteca de aprendizaje automático de código abierto: Scikit-learn.

- Lenguaje de programación: Python + librerías.
- Herramienta de edición, ejecución y documentación: Jupyter Notebook.
- Herramienta para visualización de registros de dataset y evaluación preliminar de modelos: Weka.
- Entorno general de trabajo: Anaconda Navigator.

Se entrenaron y evaluaron cuatro modelos de aprendizaje automático, utilizando las siguientes métricas:

Coeficiente de correlación

Mide la relación (r) entre las predicciones de un modelo de aprendizaje automático y los valores reales. Se utiliza principalmente en problemas de regresión para evaluar qué tan bien el modelo captura la tendencia de los datos.

Interpretación:

- ❖ $r = 1 \rightarrow$ Relación positiva perfecta (cuando x sube, y también).
- ❖ $r = -1 \rightarrow$ Relación negativa perfecta (cuando x sube, y baja).
- ❖ $r = 0 \rightarrow$ No hay correlación entre x e y .

El coeficiente de correlación mide qué tan bien un modelo de IA se ajusta a los datos. Un R^2 alto o un r cercano a 1 o -1 indica un buen ajuste, mientras que valores cercanos a 0 sugieren que el modelo no predice bien.

Error absoluto medio

El Error Absoluto Medio (MAE, por sus siglas en inglés: Mean Absolute Error) es una métrica utilizada en modelos de regresión para medir el promedio de los errores absolutos entre las predicciones y los valores reales. Mide qué tan preciso es un modelo en promedio, mostrando la magnitud del error sin importar su dirección. Es una métrica sencilla y útil para evaluar el rendimiento de modelos de regresión. Se calcula sumando el error absoluto de cada predicción y dividiendo entre el número total de instancias.

Interpretación:

- ❖ MAE bajo $\rightarrow$ El modelo tiene predicciones muy precisas.
- ❖ MAE alto $\rightarrow$ El modelo tiene grandes errores en promedio.
- ❖ MAE siempre es positivo y se mide en las mismas unidades que los valores de salida.

El MAE mide qué tan preciso es un modelo en promedio, mostrando la magnitud del error sin importar su dirección. Es una métrica sencilla y útil para evaluar el rendimiento de modelos de regresión.

Raíz de error cuadrático

El RMSE (Root Mean Squared Error) es una métrica usada en modelos de regresión para medir qué tan lejos están las predicciones de los valores reales, penalizando más los errores grandes. Se calcula elevando al cuadrado las diferencias, promediándolas y sacando la raíz cuadrada.

Interpretación:

- ❖ RMSE bajo $\rightarrow$ Mejor modelo, ya que las predicciones están cerca de los valores reales.
- ❖ RMSE alto $\rightarrow$ Modelo impreciso, los errores son grandes.
- ❖ Siempre es positivo y se expresa en las mismas unidades que los valores de salida.

Diferencia con MAE: El RMSE penaliza más los errores grandes, mientras que el MAE los trata de manera uniforme.

El RMSE mide el error promedio penalizando más los errores grandes. Es útil cuando los errores extremos son importantes, pero puede ser afectado por valores atípicos.

Error relativo absoluto

El Error Relativo Absoluto (RAE, por sus siglas en inglés: Relative Absolute Error) es una métrica utilizada en modelos de regresión para evaluar la precisión de las predicciones en comparación con un modelo base simple (como la media de los datos).

El RAE compara la suma de los errores absolutos del modelo con los errores que se obtendrían si solo se predijera la media de los datos.

Interpretación:

- ❖ $RAE < 100\%$ → El modelo es mejor que predecir la media de los valores reales.
- ❖ $RAE = 100\%$ → El modelo no es mejor que predecir la media.
- ❖ $RAE > 100\%$ → El modelo es peor que la media y no tiene buen desempeño.

El RAE mide el error absoluto relativo a un modelo base, permitiendo evaluar si un modelo de IA realmente agrega valor en comparación con simplemente usar la media. Valores menores a 100% indican un buen desempeño.

Error relativo cuadrático

El Error Relativo Cuadrático (RRSE, por sus siglas en inglés: Root Relative Squared Error) es una métrica de evaluación en modelos de regresión que mide qué tan bien se desempeña un modelo en comparación con un modelo base que simplemente predice la media de los valores reales. El RRSE compara el error cuadrático medio del modelo con el error cuadrático que se obtendría si se usara la media de los datos como predicción.

Interpretación:

- ❖ $RRSE < 100\%$ → El modelo es mejor que predecir la media.
- ❖ $RRSE = 100\%$ → El modelo es igual de bueno que predecir la media.
- ❖ $RRSE > 100\%$ → El modelo es peor que predecir la media.

El RRSE mide qué tan preciso es un modelo en comparación con la media de los datos, penalizando más los errores grandes. Un RRSE bajo indica un buen modelo, mientras que valores superiores al 100% indican mal desempeño.

Scikit-learn fue el framework base para el entrenamiento y verificación del rendimiento de los modelos de aprendizaje automático, a continuación, se describe uno de los notebooks creados para el entrenamiento y evaluación:

Inicialmente, se realizan las importaciones de librerías necesarias:

1. Importaciones

```
import pandas as pd
from sklearn.model_selection import train_test_split

# Modelo MLPClassifier
from sklearn.neural_network import MLPClassifier

# Preprocesamiento
from sklearn.datasets import make_classification
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import train_test_split
from sklearn.pipeline import make_pipeline
from sklearn.preprocessing import StandardScaler

# Importar metricas para matriz de confusión
from sklearn.metrics import confusion_matrix, classification_report

# Importar joblib para acciones pipelining (almacenar) modelo
import joblib
```

Posteriormente se preparó el dataset:

2. Preparar el Dataset

```
# Importar dataset
df = pd.read_csv('../Datasets/DataSets_Prueba/REGA_DATASET_OLD.csv')

# Revisar las primeras cinco columnas
df.head()

# Obtener información del dataset
df.info()

# Separar Outcome(predicción) de las features y almacenarlas en un array
X = df.drop(columns='Outcome').values

# Cargar el feature de predicción outcome y guardarlo en un array
y = df['Outcome'].values

# Separar datos de entrenamiento y de testeo
X_train, X_test, y_train, y_test = train_test_split(X, y, random_state=42)
```

Ahora, se prepara y entrena el modelo:

3. Modelo MLPClassifier


NOTAS:

Actualización: 07-05-2025

1. Escalamiento: es indispensables para normalizar los valores del dataset.
2. En las pruebas iniciales, los mejores resultados se alcanzaron con un red de 8 a 2 y 10000 iteraciones
3. El optimizador (solver) adam mostró mejor precisión y rapidéz en el entrenamiento que lbfgs.

```
pipe = make_pipeline(StandardScaler(), MLPClassifier(solver='adam', alpha=1e-5,  
                                                    hidden_layer_sizes=(8, 2), random_state=1, max_iter=10000))
```

```
# Entrenar  
pipe.fit(X_train, y_train)
```



Finalmente se evalúa su desempeño:

```
# Evaluando la precisión  
pipe.score(X_test, y_test)
```

```
0.9597893244201358
```

```
## Hacer la predicción  
y_pred = pipe.predict(X_test)  
y_pred
```

```
array([1, 0, 1, ..., 1, 0, 0], shape=(9873,))
```

```
## Matriz de confusión  
print(confusion_matrix(y_test, y_pred))  
print(classification_report(y_test, y_pred))
```

```
[[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

En el notebook anterior, la precisión fue del 95.9 % lo cual es excelente, esto se confirma al evaluar el rendimiento realizando predicciones sobre el conjunto de datos que corresponde al segmento de testeo. La matriz de confusión muestra una precisión final del 96 % lo cual confirma la precisión anterior. El modelo entrenado y evaluado se almacena en un archivo que podrá ser alojado en un servidor de producción.

4. Almacenamiento del modelo entrenado

Crear el fichero del modelo

```
# Guardar el modelo
joblib.dump(pipe, 'MLPC_model_joblib.pkl')

['MLPC_model_joblib.pkl']
```

Recuperar el modelo

```
# Cargar el modelo
modelo_bk = joblib.load('MLPC_model_joblib.pkl')

# Evaluando el rendimiento del modelo
modelo_bk.score(X_test, y_test)

0.9597893244201358
```

6.4 Puesta en producción del modelo

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.

A continuación, se muestra el código del servidor de producción que carga el modelo entrenado:

```
from fast Api import FastAPI
import joblib
import numpy as np

# Cargar el modelo
model = joblib.load('app/MLPC_model_joblib.pkl')

"""
Como es una regresión binaria, en el arreglo en la primera
posición [0] se coloca "Sin problemas" y en la siguiente
posición [1] se coloca "Fallo". Si este orden no se sigue,
se invertirá el resultado de la predicción.
"""

class_names = np.array(['Sin problemas', 'Falla'])

app = FastAPI()

@app.get('/')

def read_root():
    return {'message': 'Investigacion API'}

@app.post('/predict')
def predict(data: dict):
    """
    Predicts the class of a given set of features.

    Args:
```

```

data (dict): A dictionary containing the features to predict.
e.g. {"features": [1, 2, 3, 4]}

Returns:
dict: A dictionary containing the predicted class.
"""
features = np.array(data['features']).reshape(1, -1)
prediction = model.predict(features)
class_name = class_names[prediction][0]
return {'predicted_class': class_name}

```

El fichero de configuración de Docker es el siguiente:

```

FROM python:3.11

WORKDIR /code

COPY ./requirements.txt /code/requirements.txt

RUN pip install --no-cache-dir -r /code/requirements.txt

COPY ./app /code/app

EXPOSE 8000

CMD ["uvicorn", "app.server:app", "--host", "0.0.0.0", "--port", "8000"]

```

El esquema de consulta y respuesta de predicciones se muestra en la siguiente figura:




Fig. 14. Estructura final del dataset.

Como el modelo se ejecuta en una computadora distinta a la aplicación que controla el proceso que es una Raspberry PI 4 (Especificaciones técnicas en Anexo 5), fue necesario crear un flujo Node-RED para coleccionar los datos y enviarlos al servidor de producción en tiempo real. El flujo es el siguiente:




Fig. 15. Flujo Node-RED para envío de datos al modelo en tiempo real.

El nodo clave del flujo es el comando CURL, este debe contener los valores del proceso y de presión de control y enviarlo al servidor de producción para que el modelo evalúe y devuelva una predicción, la estructura de un comando CURL típico se muestra a continuación:

```
curl -X 'POST' 'http://172.16.60.129:8000/predict' -H 'accept: application/json' -H 'Content-Type: application/json' -d '{"features": [1.522,1.422,1.073,4.42,11.82,4.5,25,75]}'
```

7. RESULTADOS

7.1. MODELOS DE APRENDIZAJE AUTOMÁTICO

a. Regresión Lineal

Los resultados del modelo:

Tabla 4. Resultados de evaluación del modelo de regresión lineal.

Medición	Resultado
Coefficiente de correlación	0.3588
Error absoluto medio	0.4288
Raíz de error cuadrático	0.4619
Error relativo absoluto	87.5465%
Error relativo cuadrático	93.339%

El modelo tiene un **rendimiento deficiente**.

- Baja correlación (0.3588) indica que las variables de entrada explican poco la variabilidad en los datos.
- Errores relativamente altos (MAE y RMSE) sugieren que las predicciones no son precisas.
- RAE y RRSE elevados (cerca de 100%) indican que el modelo no es mucho mejor que simplemente predecir la media.

Posibles soluciones:

- Agregar más variables relevantes al modelo (capturar otros datos e integrarlos al dataset).
- **Probar modelos más complejos como regresión polinómica o redes neuronales.**
- Optimizar hiperparámetros y ajustar el modelo.
- Realizar transformaciones en los datos.

Matriz de confusión:

[[3009 1386] [1839 1664]]		precision	recall	f1-score	support
0	0.62	0.68	0.65	4395	
1	0.55	0.48	0.51	3503	
accuracy				0.59	7898
macro avg		0.58	0.58	0.58	7898
weighted avg		0.59	0.59	0.59	7898

Fig. 16. Matriz de confusión del modelo de regresión lineal.

Conclusión: el modelo 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.

b. Árbol aleatorio

Los resultados del modelo:

Tabla 5. Resultados de evaluación del modelo de árbol aleatorio.

Medición	Resultado
Coefficiente de correlación	0.9973
Error absoluto medio	0.0049
Raíz de error cuadrático	0.0367
Error relativo absoluto	0.9916%
Error relativo cuadrático	7.411%

El modelo tiene un **rendimiento excelente**:

- Alta correlación (0.9942) indica que las variables de entrada explican casi toda la variabilidad en los datos.
- Errores muy bajos (MAE = 0.0029 y RMSE = 0.0535) sugieren que las predicciones son altamente precisas.
- RAE y RRSE extremadamente bajos confirman que el modelo es mucho mejor que simplemente predecir la media.

Conclusión: tiene una capacidad predictiva sobresaliente y es altamente preciso. Si no hay overfitting (sobreajuste), es un modelo excelente para la tarea.

c. Bosque aleatorio

Este modelo es una mejora del anterior ya que resuelve el problema del sobreajuste, sus resultados son los siguientes:

Tabla 6. Resultados de evaluación del modelo de bosque aleatorio.

Medición	Resultado
Coeficiente de correlación	0.9942
Error absoluto medio	0.0029
Raíz de error cuadrático	0.0535
Error relativo absoluto	0.5837%
Error relativo cuadrático	10.805%

El modelo tiene un **rendimiento excelente**:

- Alta correlación (0.9942) indica que las variables de entrada explican casi toda la variabilidad en los datos.
- Errores muy bajos (MAE = 0.0029 y RMSE = 0.0535) sugieren que las predicciones son altamente precisas.
- RAE y RRSE extremadamente bajos confirman que el modelo es mucho mejor que simplemente predecir la media.

Conclusión: tiene una capacidad predictiva sobresaliente y es altamente preciso. Si no hay overfitting (sobreajuste), es un modelo excelente para la tarea.

La matriz de confusión obtenida es la siguiente:

[[4364 7]					
[9 3518]]					
		precision	recall	f1-score	support
	0	1.00	1.00	1.00	4371
	1	1.00	1.00	1.00	3527
	accuracy			1.00	7898
	macro avg	1.00	1.00	1.00	7898
	weighted avg	1.00	1.00	1.00	7898

Fig. 17. Matriz de confusión del modelo bosque aleatorio.

Este modelo es el mejor, en la matriz de confusión se observa que predijo correctamente 4364 registros de buen funcionamiento con solamente 7 falsos positivos. Además, predijo correctamente 3518 registros con fallas con solamente 9 falsos negativos.

d. Perceptrón Multicapa de Clasificación

Los modelos árbol y bosque aleatorios no implementan redes neuronales profundas porque están basados en reglas y conjuntos. Sin embargo, de acuerdo con los resultados su desempeño es excelente por lo que perfectamente pueden utilizarse para pronosticar el estado de falla en el proceso.

A pesar de lo anterior, se decidió entrenar y evaluar el modelo Perceptrón Multicapa en su variante de clasificación que si 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%) en las predicciones con la siguiente matriz de confusión:

[[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. 18. Matriz de confusión del modelo perceptrón multicapa de clasificación.

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.

7.2 Entrenador de Control de Procesos de Flujo y Nivel

El entrenador de control de procesos ha sido dotado de las siguientes mejoras:

- a. Control automatizado con el módulo ET200 que cuenta con un PLC S7 1500, con módulos de entrada analógicas de 4 – 20 mA, salidas analógicas de 4 – 20 mA, entradas y salidas digitales de 0 – 24 V.
- b. Gestión remota del proceso por medio de programa Node-RED en donde se han incorporado flujos para la gestión del proceso:




Fig. 19. Gestión del proceso de forma remota con Node-RED.

Y flujos para el monitoreo de las presiones en el control neumático de PV1:




Fig. 20. Indicadores del estado de las presiones de control con Node-RED.

- c. Sistema de generación de fallas manual para simular fallas de fuga a la atmósfera y en los sellos de PV1. En cada falla, se monitorean las presiones con sensores de presión de grado industrial de alta calidad marca IFM (Anexo 3).

7.3 Red Neuronal

Si bien los resultados mostrados demuestran que en términos porcentuales el modelo de bosque aleatorio posee un rendimiento en torno al 99 % siendo superior al 96 % del MLP, la diferencia es baja y ambos son excelentes para la predicción de fallas.

El modelo de bosque aleatorio puede presentar los siguientes problemas en producción:

- Entrena muchos árboles de decisión, lo que puede consumir mucha memoria y CPU, especialmente con grandes volúmenes de datos o muchos árboles. Esto representa un problema serio si consideramos que se va a ejecutar en una computadora orientada a la automatización de un proceso industrial que posee pocos recursos de CPU y memoria.
- Aunque es menos propenso al overfitting (sobre ajuste) que un solo árbol, puede sobre ajustar si hay demasiados árboles o si no se controla bien la profundidad y el número mínimo de muestras. Este problema se puede reducir si se ajustan sus hiperparámetros. Pero esto es generalmente una tarea compleja.

Por otra parte, el modelo perceptrón multicapa puede presentar los siguientes problemas:

- Requiere de un ajuste fino de los hiperparámetros lo cual suele ser complejo.
- Requiere un mayor tiempo de entrenamiento por lo que consume mas recursos de CPU y memoria, esto es una limitante si se dispone de una computadora con pocos recursos.
- Es indispensable normalizar los datos para que funcione correctamente.
- Si se dispone de pocos datos para el entrenamiento, este modelo se sobre ajustará.

La red neuronal fue creada con el siguiente código:

```
pipe = make_pipeline(StandardScaler(), MLPClassifier(solver='adam',
alpha=1e-5,hidden_layer_sizes=(8, 2), random_state=1, max_iter=10000))
```

Por lo posee las siguientes características:

Parámetro	Valor	Descripción
solver	adam	Optimizador eficiente basado en descenso de gradiente estocástico adaptativo
alpha	1e-5	Parámetro de regularización L2 (evita overfitting).
max_iter	10000	Máximo número de iteraciones para convergencia.
random_state	1	Control de aleatoriedad para reproducibilidad.
hidden_layer_sizes	(8, 2)	Estructura de las capas ocultas.

Como el enfoque del proyecto estuvo orientado a la aplicación de una red neuronal, se implementó el modelo MLP entrenado con un rendimiento promedio del 96 %. La siguiente figura muestra gráficamente la estructura de la red neuronal.




Fig. 21. Red neuronal MLP puesta en producción.

Se observa una red profunda con ocho entradas y una salida. Internamente, la red posee dos capas ocultas, la primera es de ocho neuronas y la segunda compuesta por dos neuronas. En el modelo hay únicamente una neurona de salida, lo que corresponde con una clasificación binaria (falla / no falla).

7.4 Utilidad del entrenador

Con las mejoras realizadas al entrenador de flujo y la incorporación de un modelo de predicción de fallas integrado, estudiantes y docentes pueden aprender a:

- I. Elaborar un dataset con parámetros que pueden utilizarse para la predicción de falla.
- II. Entrenar modelos de aprendizaje automático de clasificación binaria.
- III. Experimentar con modelos de ML para predecir fallas y determinar cual es el mas apropiado para su aplicación.
- IV. Poner en producción modelos de ML entrenados y evaluar su rendimiento en tiempo real.

8. CONCLUSIONES

a) Factibilidad de la aplicación de Inteligencia Artificial.

Considerando los resultados obtenidos (tablas: 5, 6; figuras: 17, 18) así como la puesta en producción del modelo MLP entrenado, se concluye que es factible implementar modelos de aprendizaje automático. El modelo de regresión lineal 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, Random Forest.

Consideraciones 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.
- Random Forest 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 Random Forest son la mejor opción.

En resumen:

- Se debe utilizar Random Forest 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, como la evidencia demuestra, es posible utilizar modelos de aprendizaje automático para pronosticar fallas en un proceso industrial como el utilizado en esta investigación.

b) Necesidad de utilización de IA en la industria.

En industria 4.0 la integración de los modelos de aprendizaje automático es vital ya que se utiliza principalmente para lograr que los sistemas sean mas autónomos requiriendo cada vez menos intervención humana. Estos modelos se nutren de la gran cantidad de datos que se producen en las fábricas automatizadas y se entrenan para ser cada vez mas precisos y mejorar la toma de decisiones. Por otra parte, los datos generados también se utilizan para identificar comportamientos y patrones normales a partir de los cuales se puede determinar cuando alguna de las etapas del proceso de fabricación empieza a salirse de estos patrones y a partir de esto informar cuando la desviación es tan grande como para predecir una falla o estimar cuanto tiempo de vida útil (RUL) tienen los dispositivos.

c) Fortalecimiento de laboratorios de ITCA-FEPADE.

ITCA-FEPADE ya cuenta con diversos entrenadores de control de procesos, celdas de fabricación y fabricas automatizadas didácticas. Estos entrenadores pueden dotarse de los componentes y procesos descritos en esta investigación para que pueda aplicarse la predicción de fallas guiada por modelos de aprendizaje entrenados. Esto expande el potencial de entrenamiento de los entrenadores existentes.

d) Beneficios para estudiantes de ITCA-FEPADE.

Los estudiantes se beneficiarán ya que incursionarán en inteligencia artificial, entenderán como funcionan los modelos de aprendizaje automático y podrán explicar, así como aplicar todas las etapas involucradas en el proceso de implementación de IA en la predicción fallas como una etapa preliminar al mantenimiento predictivo que es parte fundamental de la industria 4.0.

9. RECOMENDACIONES

Los objetivos inicialmente propuestos en este proyecto de investigación fueron alcanzados exitosamente, la hipótesis fue confirmada por lo que las siguientes recomendaciones están orientadas en la continuidad del proyecto en una segunda etapa que buscaría expandir las prestaciones del entrenador dotándolo de los componentes necesarios para aplicar mantenimiento predictivo guiado por modelos de aprendizaje automático.

a) Analizar y mejorar el proceso de diseño del dataset para predicción de fallas.

Incorporar funciones que permitan determinar el tiempo que toma al PV alcanzar el SP con ausencia y presencia de fallas e incorporar estos datos a los registros del dataset.

b) Evaluar el rendimiento de otros modelos de aprendizaje automático.

Evaluar modelos de boosting como XGBoost, LightGBM, CatBoost que suelen ser mas precisos que bosque aleatorio.

c) Investigar e implementar modelos de aprendizaje automático para predecir fallos antes que estos ocurran.

Utilizar modelos de autoencoder y combinarlos con modelos RNN, LSTM y otros que son ideales cuando se tienen datos de múltiples sensores.

d) Investigar e implementar modelos de aprendizaje automático para indicar los dispositivos o áreas de la maquinaria en donde se produce una falla.

10. GLOSARIO

A

Anaconda Navegador: es una interfaz gráfica de usuario (GUI) que se incluye con la distribución Anaconda. Permite administrar paquetes, entornos y canales de Conda sin necesidad de usar la línea de comandos. Es útil para aquellos que prefieren una interfaz visual para gestionar sus entornos de desarrollo y ejecutar aplicaciones. · 26

C

Control de procesos: es la práctica de supervisar y regular las operaciones en una planta de producción para garantizar la eficiencia, la calidad y la seguridad. · 7

csv es un formato de archivo de texto que almacena datos en forma de tabla, donde cada fila representa un registro y cada columna está separada por una coma. · 22

D

Datalogger: es un dispositivo electrónico que registra datos de forma automática a lo largo del tiempo, generalmente de variables ambientales o de proceso. Estos dispositivos pueden medir y almacenar información como temperatura, humedad, presión, luz, sonido, voltaje, corriente y más. · 20

Dataset: un dataset (o conjunto de datos) es una colección organizada de información, estructurada para facilitar su análisis y uso en el entrenamiento de modelos de aprendizaje automático. · 22

J

JSON: es un formato de datos ligero y fácil de leer que se utiliza para almacenar y transmitir datos en aplicaciones web y software. · 22

N

Node-RED: herramienta de programación visual que facilita la creación de aplicaciones basadas en eventos, especialmente en entornos de Internet de las Cosas (IoT). · 22

P

Perceptrón Multicapa. El Perceptrón Multicapa (o Multilayer Perceptron, MLP) es un tipo de red neuronal artificial compuesta por varias capas de nodos (neuronas) organizadas · 30

S

Sensor: dispositivo que detecta un estímulo físico, como la temperatura, la luz o la presión, y lo convierte en una señal que se puede medir o interpretar. · 8

sobreajuste: es un comportamiento de machine learning no deseado que se produce cuando el modelo de machine learning brinda predicciones precisas para los datos de entrenamiento, pero no para los datos nuevos. · 39

V

Válvula: dispositivo mecánico que controla el flujo de fluidos (líquidos o gases) dentro de un sistema industrial. · 9

W

Weka: es una plataforma de software de código abierto que se utiliza para minería de datos y aprendizaje automático. · 26

11. REFERENCIAS BIBLIOGRÁFICAS

- [1] W. Dunn, *Fundamentals of Industrial Instrumentation and Process Control*, 2a ed. Estados Unidos: McGraw-Hill, 2018.
- [2] A. B. Herrero Pablo San Segundo y Rebeca, *2.1 Sensores industriales | Introducción a la Automatización Industrial*. Consultado: el 7 de julio de 2023. [En línea]. Disponible en: https://bookdown.org/alberto_brunete/intro_automatica/sensores-industriales.html
- [3] Pepperl+Fuchs, “Sensores capacitivos”, Pepperl+Fuchs. Consultado: el 26 de enero de 2022. [En línea]. Disponible en: https://www.pepperl-fuchs.com/global/es/classid_144.htm
- [4] rspro, “Sensores de automatización industrial. Guía de selección”. RS pro. [En línea]. Disponible en: <https://www.studocu.com/es-ar/document/instituto-universitario-escuela-argentina-de-negocios/comercio-electronico/a700000007389460-aplicaciones-de-sensores/32095826>
- [5] G. Buckbee, “5. Final Control Elements”, en *Process Control Basics*, 1a ed., Estados Unidos: ISA, 2022.
- [6] “What is Machine Learning? | IBM”. Consultado: el 15 de enero de 2024. [En línea]. Disponible en: <https://www.ibm.com/topics/machine-learning>
- [7] “What are Neural Networks? | IBM”. Consultado: el 15 de enero de 2024. [En línea]. Disponible en: <https://www.ibm.com/topics/neural-networks>
- [8] G. Liguori, “Predictive maintenance in industry 4.0: applications and advantages”, CodeX. Consultado: el 15 de enero de 2024. [En línea]. Disponible en: <https://medium.com/codex/predictive-maintenance-in-industry-4-0-applications-and-advantages-72bd7383823e>
- [9] “AWS Industrial IoT Predictive Maintenance ML Model Reference Architecture”, [En línea]. Disponible en: <https://d1.awsstatic.com/architecture-diagrams/ArchitectureDiagrams/aws-industrial-PdM-ML-storage-RA.pdf>
- [10] M. Daigle, C. S. Kulkarni, y G. Gorospe, “Application of model-based prognostics to a pneumatic valves testbed”, en *2014 IEEE Aerospace Conference*, mar. 2014, pp. 1–8. doi: 10.1109/AERO.2014.6836319.
- [11] C. S. Kulkarni, M. J. Daigle, G. Gorospe, y K. Goebel, “Experimental Validation of Model-Based Prognostics for Pneumatic Valves”, *Int. J. Progn. Health Manag.*, vol. 8, p. 018, 2017.

12. ANEXOS

12.1. ESPECIFICACIONES TÉCNICAS DE PV1 BADGER SERIE: 1002GCN36SV0AEP36



Research Control Valves

Model Numbers

1. The first 4 digits are base model number and designate valve size

Digits Valve Size

1001	1/4 in.
1002	1/2 in.
1003	3/4 in.
1004	1 in.
1005	1-1/2 in.
1007	2 in.
1000	Parts
1006	Repairs
1011	1/4 in. Trim
1012	1/2 in. Trim
1013	3/4 in. Trim
1014	1 in. Trim
1015	1-1/2 in. Trim
1016	"P" Trim
1017	Topworks

2. The next 2 digits designate body type

Digits Body Type

GC	Globe Cast
GB	Globe Barstock
AB	Angle Barstock
AH	Angle High Pressure Union
GH	Globe High Pressure Union
TC	Three-Way Cast
TB	Three-Way Barstock
GS	Globe Sanitary
AS	Angle Sanitary
GE	Globe, Extended (CBX, Hastelloy C bellow)
GU	Globe Cast High Pressure Union

3. The next digit designates body end fitting

Digit Body End Fitting

N	NPT
F	Flanged (size, rating or face finish not specified)
S	Socket Weld (size not specified)
B	Butt Weld (extension nipples) (size not specified)
T	Tube Fittings (for example, Swagelok, AE)
W	Wafer (clamp between flanges)
Y	Clamp Type (sanitary)
U	Union Type (sanitary)

4. The next 2 digits designate the body-bonnet material

Digits Body-Bonnet Material

16	DIN 1.4462/Duplex 2205
17	DIN 1.4571/1.4581
36	316 S/S
3L	316L S/S
34	304 S/S
37	347 S/S
BR	Brass or Bronze
CS	Carbon Steel
MN	Monel
C2	Carpenter 20 (Alloy 20)
HB	Hastelloy B (Alloy B)
HC	Hastelloy C (Alloy C)
H2	Hastelloy C-22
HG	Hastelloy G
IN	Inconel
TI	Titanium
TA	Tantalum
NI	Nickel
KY	Kynar
PC	PVC
ZR	Zirconium

5. The next 2 digits designate bonnet style and packing

Digits Bonnet Style

SV	Standard	Packing	Cv Ring
SK	Standard	Kalrez Cv Rings	
SG	Standard	Grafoil	
SR	Standard	Reversed Cv Ring	
CV	Cooling Fin	Cv Ring	
CG	Cooling Fin	Grafoil	
CK	Cooling Fin	Kalrez Cv Rings	
CM	Cooling Fin, Medium Guided (Packing not specified, assumes PTFE)		
BV	Bellows	Cv Ring	
BG	Bellows	Grafoil	
EG	Extension Neck	Grafoil	
EV	Extension Neck	Cv Ring	
HV	Heavy Duty Guide	Cv Ring	
HG	Heavy Duty Guide	Grafoil	
KV	H.D. Guided Cooling Fin	Cv Ring	
KG	H.D. Guided Cooling Fin	Grafoil	
MV	Medium Guided Trim w/	Cv Ring	
DV	Double Cv Rings (PTFE)	Cv Ring	
DK	Double Cv Rings (Kalrez)	Cv Ring	
MU	Manual, Union	Disk	

Sanitary Bonnets

YO	Clamp Type with O-Ring
UO	Union Type with O-Ring
YD	Clamp Type with Double O-Rings
UD	Union Type with Double O-Rings
YP	Clamp Type with Purge Port and Double O-Rings
UP	Union Type with Purge Port and Double O-Rings
YR	Sanitary Clamp Type with Rolling Diaphragm
YR	Sanitary Clamp Type with Rolling Diaphragm

6. The next 2 digits designate actuator type

Digits Actuator Type

OS	ATO Standard
CS	ATC Standard
OP	ATO-P with Positioner
CP	ATC-P with Positioner
OB	ATO with Buyout Positioner
CB	ATC with Buyout Positioner
OR	ATO Reversible
CR	ATC Reversible
O3	ATO S/S Topworks
C3	ATC S/S Topworks
OO	Less Topworks
MN	Manual
OE	EVA-1 Signal-to-Open
CE	EVA-1 Signal-to-Close
O9	EVA-100/200 Signal-to-Open
C9	EVA-100/200 Signal-to-Close
E4	SEVA-100
E5	SEVA-200
OH	ATO With Handwheel
CH	ATC With Handwheel
OT	ATO Size 35 (1.125 in. mounting) w/o positioner
CT	ATC Size 35 (1.125 in. mounting) w/o positioner
OW	ATO Size 35 (1.125 in. mounting) with positioner
CW	ATC Size 35 (1.125 in. mounting) with positioner
OZ	ATO Size 35 (1.0 in. mounting) with positioner [For BA-2500, BA-2030, etc.]
CZ	ATC Size 35 (1.0 in. mounting) with positioner [For BA-2500, BA-2030, etc.]

7. Next 3 digits designate trim size & characteristic—
examples only

NOTE: The following are just examples of how the innervalue model number is constructed. A complete list of all the innervalue would be too large to list.

Digits Trim Size and Characteristics

ALN	"A" Linear
BEP	"B" =%
CLN	"C" Linear
DEP	"D" =%
60L	6.0 Linear
50P	5.0 =%
P01	"P-1"
ELN	"E" Linear
FEP	"F" =%
GLN	"G" Linear
HEO	"H" =%
45L	4.5 Linear
35P	3.5 =%
P15	"P-15"
AQO	"A" Quick Open, metal-to metal
AQS	"A" Quick Open, soft seat
ALS	"A" Linear, soft seat
000	Less Trim
APS	"A" =%, soft seat

8. The next 2 digits designate trim material (normally same as body material)

NOTE: "X" in any space denotes "Special"

Digits Trim Material

16	DIN 1.4462/Duplex 2205
17	DIN 1.4571
36	316 S/S
3L	316L S/S
ST	Stellite (with 316 base material)
S6	Stellite, 416 S/S
HB	Hastelloy B (Alloy B)
HC	Hastelloy C (Alloy C)
H2	Hastelloy C-22
HG	Hastelloy G
3T	316 S/S, Teflon
3K	316 S/S, Kel-F
TC	Tungsten Carbide
S3	Stellite, 316 S/S
S2	Stellite, Carp. 20
SB	Stellite, Hastelloy B (Alloy B)
SC	Stellite, Hastelloy C (Alloy C)
TA	Tantalum
TI	Titanium
KY	Kynar
PC	PVC
NI	Nickel
MN	Monel
37	347 S/S
S4	Stellite & 304
C2	Carpenter 20 (Alloy 20)
TS	Titanium Nitride-Coated Stellite
SP	Stellite & Phosphor Bronze (P Trim)
ZR	Zirconium


Example: 1002-GC-N-36-SV-OS-ALN-36

1002	1/2 in. Valve
GC	Globe Cast
N	NPT
36	316 S/S
SV	Standard Bonnet, Cv Ring Packing
OS	ATO Standard
ALN	"A" Linear
36	316 S/S



RCV-AS-02527-EN-03 (November 2023)

Application Data Sheet



Spring Adjuster: Sets the open/closing position of the valve

- (E) Resorte de ajuste: Ajusta las posiciones de abierto/cerrado en válvula
- (F) Réglage du ressort de rappel détermine le point d'ouverture/ fermeture du clapet
- (D) Feder Einstellmutter: Korrigiert Offen- und Geschlossenstellung
- (NL) Veerinstelling: Instellen van de open/ sluitpositie van de klep
- (S) Justerskruv: för öppet/stängt läge samt fjäderkraft vid stängt ventilläge

Type 754
Type 47-O 73-O


Air Connection

- (E) Conexión de señal da aire.
- (F) Racordement
- (D) Luftanschluß
- (NL) Luchtinlaat
- (S) Luftanslutning

Signal Pressure 3- 15 psi (0.2 - 1 bar)

- (E) Señal de presión
- (F) Pression pilote
- (D) Signaldruck
- (NL) Stuurdruk
- (S) Signaltryck

Size	1/4"	1/8" NPT
Size	1/2"-1"	1/4" NPT



ACTUATOR
TYPE 754
TYPE OS

BODY/BONNET
TYPE 807
TYPE RC200

1. Spring adjuster
2. Spring case
3. Spring seat
4. Spring
5. Drive screw
6. Nameplate
7. Stem nut
8. Washer
9. Diaphragm plate
10. Hex Head screw
11. Diaphragm
12. Actuator stem
13. O-Ring
14. O-Ring follower
15. Pressure case
16. O-Ring gland
17. Stem nut
18. Travel pointer
19. Screw
20. Flat washer
21. Travel scale
22. Connector
23. Packing gland
24. Yoke locknut
25. Packing follower
26. Packing set
27. Packing adaptor
28. Std bonnet
29. Stem
30. Gasket
31. Plug
32. Seat
33. Globe body

(E)

1. Ajuste de resorte
2. Caja de resorte
3. Asiento de resorte
4. Resorte
5. Tornillo guía
6. Chapa de identidad
7. Tuerca del vástago
8. Arandela
9. Plaqueta de la membrana
10. Tornillo, cabeza hex.
11. Membrana
12. Vástago de actuador
13. Junta tórica
14. Empujador
15. Cámara de presión
16. Prensaestopas
17. Tuerca del vástago
18. Placa indicadora
19. Tornillo
20. Arandela
21. Indicador de carrera
22. Conector
23. Prensaestopas
24. Tuerca de horquilla
25. Anillo de empaquetadura
26. Empaquetadura
27. Adaptador
28. Bonete
29. Vástago
30. Junta de cuerpo
31. Tapón
32. Asiento
33. Cuerpo de válvula

12.2. ANEXO 2. ESPECIFICACIONES TÉCNICAS DE PC1 ABB TEIP11

Concept

The TEIP11 signal converter converts standard electrical signals, e.g. 4 to 20 mA to 0.2 to 1 bar (3 to 15 psi). It is therefore a connecting link between electrical/electronic and pneumatic systems. The signal conversion process is similar to the patented force balance method.

Special features of the TEIP11 signal converter are its relatively small dimensions and outstanding operational stability when subject to shock and vibration. The converter can be subjected to loads up to 10 g with less than 1% effect on function.

The housing units are available in a variety of models to meet your installation requirements. For potentially explosive conditions, units that offer intrinsically safe operation or pressure-resistant encapsulation are available with international approval certificates for use worldwide. Various ranges can be supplied on the input side and the output side for signal conversion (see **Specification** on page 4).

The device requires only compressed air 1.4 to 10 bar (20 to 145 psi) for the power supply.

In order to ensure smaller dimensions and lower costs, an air power stage is not included in the pneumatic unit.

This reduces the air capacity, meaning that the I/P signal converter can only be used to control small-volume air systems.

Designs




Figure 1: TEIP 11 designs

Control room housing unit for rail mounting

The control room housing for rail mounting is the simplest and lowest priced version of the I/P signal converter.

A mounting base that is compatible with all commercially available EN rails is used for installation.

The housing unit with plastic cap has an IP 20 protection rating.

Field mount housing

The field mount housing is suited for installation on-site or in open areas. The housing can be made from plastic with IP rating IP 54, from aluminum with IP rating IP 65 and from stainless steel with IP rating IP 65. The housing is suited for wall mounting and for 2 in pipe mounting.

Specification

Input (electric)

Signal range

0 to 20 mA or 4 to 20 mA
0 to 10 mA or 10 to 20 mA
4 to 12 mA or 12 to 20 mA
(additional ranges available upon request)

Input resistance

$R_i = 260 \Omega$ at 20°C (68°F), $T_k + 0.4\%/\text{K}$

Overpressure limit

30 mA (for Ex devices see).

Capacitance / inductance

Negligible

Output (pneumatic)

Signal range

0.2 to 1 bar (3 to 15 psi)

Air capacity

at supply air pressure	[kg/h]	[Nm ³ /h]	[scfm]
1.4 bar (20 psi)	0.05	0.041	0.024
2.0 bar (30 psi)	0.07	0.057	0.033
4.0 bar (60 psi)	0.10	0.082	0.048
6.0 bar (90 psi)	0.16	0.130	0.076
10.0 bar(150 psi)	0.25	0.205	0.120

Power supply (pneumatic)

Instrument air

Free of oil, water, and dust acc. to DIN/ISO 8573-1
Pollution and oil content according to Class 3
Pressure dew point 10 K below operating temperature

Supply pressure

1.4 to 10 bar (20 to 145 psi)

Output signal

0.2 to 1 bar (3 to 15 psi)

Air consumption

Equivalent to air capacity

Transmission data and contributing factors

Characteristic curve

Linear, direct, or reverse action

Characteristic curve deviation

$\leq 1\%$

Hysteresis

$\leq 0.3\%$

Dead band

$\leq 0.1\%$

Temperature

$\leq 1\%$ / 10 K within -20 to 85°C (-4 to 185°F)
 $\leq 2\%$ / 10 K within -55 to -20°C (-67 to -4°F)

Power supply

$\leq 0.8\%$ at 1.4 to 2 bar (20 to 30 psi)
 $\leq 0.8\%$ at 2 to 3 bar (30 to 45 psi)
 $\leq 0.5\%$ to 3 to 10 bar (45 to 150 psi, each 1 bar [15 psi])

Mechanical vibration

$\leq 1\%$ to 10 g and 20 to 80 Hz

Seismic vibration

Meets the requirements of DIN IEC 68-3-3 Class III for strong and strongest earthquakes.

Mounting orientation

Zero points $\leq 0.5\%$ at 90° change of position

Step response

10 to 90 % and 90 to 10 % 0.6 s
5 to 15 % and 15 to 5 % 0.25 s
45 to 55 % and 55 to 45 % 0.2 s
85 to 95 % and 95 to 85 % 0.15 s

EMC

Meets the requirements of EMC Directive 2014/30/EU
(increased interference immunity as per EN 50082-2 PR)

CE Marking

Complies with the EC directive for CE conformity

Operating conditions at installation site

Ambient temperature

Depending on the ordered model:

–40 to 85 °C (–40 to 185 °F)

–55 to 85 °C (–67 to 185 °F)

For Ex d:

–40 to 85 °C (–40 to 185 °F)

Mounting position

Any

Environmental capabilities

Climate class

GPF or FPF acc. to DIN 40040

Temperature:

–55 to 85 °C (–67 to 185 °F),

–45 to 85 °C (–49 to 185 °F)

Relative humidity for operation, storage, or transport:

75 % average, 95 % short-term,

no condensation

Expected service life of the device

With proper use and consideration of relevant environmental conditions, the service life of the TEIP11 can reach approx. 10 years.

Regular maintenance work and / or proper repairs by ABB

Service, along with the use of ABB spare parts, can extend the service life of the TEIP11.

Design for rail mounting

Material / IP rating

IP 20 aluminum housing unit, with plastic cover

Mounting

Rail mounting:

EN 50022 - 35 × 7.5

EN 50035 - G 32

EN 50045 - 15 × 5

Electrical connection

2-pole screw terminal for 2.5 mm² (14 AWG)

Pneumatic connection

1/8 NPT threaded hole for supply air and output

Weight

0.25 kg (0.55 lb)

Dimensions

Refer to **Design for control room housing unit for rail mounting** on page 10.


12.3. ANEXO 3. ESPECIFICACIONES TÉCNICAS DE LOS SENSORES DE PRESIÓN

PA3526



Transmisor de presión con célula de medición cerámica

PA-2,5-RBG14-A-ZVG/US/ IV



Características del producto					
Número de entradas y salidas		Número de salidas analógicas: 1			
Rango de medición		0...2,5 bar	0...2500 mbar	0...36 psi	0...250 kPa
Conexión de proceso		conexión de rosca G 1/4 rosca exterior rosca interno:M5			
Campo de aplicación					
Característica especial		Contactos dorados			
Aplicación		para aplicaciones industriales			
Fluidos		fluidos líquidos y gaseosos			
Temperatura del fluido [°C]		-25...90; (previa solicitud: -40...90 °C)			
Presión de rotura mín.		50 bar	725 psi	5 MPa	
Resistencia a la presión		20 bar	290 psi	2 MPa	
Tipo de presión		presión relativa			
Datos eléctricos					
Tensión de alimentación [V]		9,6...32 DC			
Resistencia de aislamiento mín. [MΩ]		100; (500 V DC)			
Clase de protección		III			
Protección contra inversiones de polaridad		sí			
Entradas/salidas					
Número de entradas y salidas		Número de salidas analógicas: 1			
Salidas					
Número total de salidas		1			

PA3526



Transmisor de presión con célula de medición cerámica

PA-2,5-RBG14-A-ZVG/USI /V


Señal de salida	señal analógica			
Número de salidas analógicas	1			
Salida analógica de corriente [mA]	4...20			
Carga máx. [Ω]	720; (Ub = 24 V; (Ub - 9,6 V) / 20 mA)			
Resistente a sobrecargas	sí			
Rango de configuración / medición				
Rango de medición	0...2,5 bar	0...2500 mbar	0...36 psi	0...250 kPa
Precisión / variaciones				
Repetibilidad [% del margen]	< 0,1; (en caso de variaciones de temperatura < 10 K)			
Exactitud señal analógica [% del margen]	< ± 0,25 (BFSL) / < ± 0,5 (LS); (BFSL = Best Fit Straight Line (configuración del valor mínimo); LS = configuración del valor límite)			
Estabilidad a largo plazo [% del margen]	< ± 0,05; (cada 6 meses)			
Coeficiente de temperatura punto cero [% del margen por cada 10 K]	< ± 0,1; (0...80 °C)			
Coeficiente de temperatura margen [% del margen por cada 10 K]	< ± 0,2; (0...80 °C)			
Tiempos de respuesta				
Tiempo de respuesta a un escalón para la salida analógica [ms]	3			
Condiciones ambientales				
Temperatura ambiente [°C]	-25...80			
Temperatura de almacenamiento [°C]	-40...100			
Grado de protección	IP 65			
Homologaciones / pruebas				
CEM	EN 61000-4-2 ESD	4 kV CD / 8 kV AD		
	EN 61000-4-3 radiado HF	30 V/m		
	EN 61000-4-4 Burst	2 kV		
	EN 61000-4-6 HF conducido	10 V		
	emisión de perturbaciones	según Directiva 2004/104/CE sobre vehículos a motor		
	CISPR 25			
	inmunidad a perturbaciones	según Directiva 2004/104/CE sobre vehículos a motor		
Resistencia a choques	ISO 11452-2 radiado HF	100 V/m		
	ISO 7637-2 pulse	grado de severidad 4		
	DIN EN 60068-2-27	50 g (11 ms)		
Resistencia a vibraciones	DIN EN 61373	Categoría 3		
	DIN EN 60068-2-6	20 g (10...2000 Hz)		
	DIN EN 61373	Categoría 2		
MTTF [años]	506			

PT5404



Transmisor de presión

PT-010-SEG14-A-ZVG/US/ IW



1 Junta de estanqueidad



Características del producto

Número de entradas y salidas	Número de salidas analógicas: 1			
Rango de medición	0...10 bar	0...145 psi	0...1000 kPa	0...1 MPa
Conexión de proceso	conexión de rosca G 1/4 rosca exterior (DIN EN ISO 1179-2)			

Campo de aplicación

Aplicación	para aplicaciones industriales		
Fluidos	fluidos líquidos y gaseosos		
Temperatura del fluido [°C]	-40...90		
Presión de rotura mín.	300 bar	4350 psi	30 MPa
Resistencia a la presión	25 bar	360 psi	2,5 MPa
Nota sobre la resistencia a la presión	estático		
Resistencia al vacío	-1000 mbar	-0,1 MPa	
Tipo de presión	presión relativa		

Datos eléctricos

Tensión de alimentación [V]	8,5...36 DC
Resistencia de aislamiento mín. [MΩ]	100; (500 V DC)
Clase de protección	III
Protección contra inversiones de polaridad	sí
Retardo a la disponibilidad [s]	< 0,1

Entradas/salidas

Número de entradas y salidas	Número de salidas analógicas: 1
------------------------------	---------------------------------

Salidas

Número total de salidas	1
Señal de salida	señal analógica

PT5404




Transmisor de presión

PT-010-SEG14-A-ZVG/US/ IW

Número de salidas analógicas	1			
Salida analógica de corriente [mA]	4...20			
Carga máx. [Ω]	(U _b – 8,5 V) / 21,5 mA; @8,5V= 0 Ω; @12V max. 160 Ω; @24V max. 720 Ω			
Protección contra cortocircuitos	sí			
Resistente a sobrecargas	sí			
Rango de configuración / medición				
Rango de medición	0...10 bar	0...145 psi	0...1000 kPa	0...1 MPa
Precisión / variaciones				
Repetibilidad [% del margen]	< ± 0,05; (en caso de variaciones de temperatura < 10 K)			
Exactitud señal analógica [% del margen]	< ± 0,5; (incl. deriva debida al par de apriete, error del punto cero y del margen, no linealidad, histéresis)			
Desvío de la linealidad [% del margen]	< ± 0,1 (BFSL) / < ± 0,2 (LS)			
Desvío de la histéresis [% del margen]	< ± 0,2			
Estabilidad a largo plazo [% del margen]	< ± 0,1; (cada 6 meses)			
Coefficiente de temperatura punto cero y margen [% del margen por cada 10 K]	< 0,1 (-25...90 °C) / < 0,2 (-40...-25 °C)			
Tiempos de respuesta				
Tiempo de respuesta a un escalón para la salida analógica [ms]	1			
Condiciones ambientales				
Temperatura ambiente [°C]	-40...90			
Temperatura de almacenamiento [°C]	-40...100			
Grado de protección	IP 67; IP 69K			
Homologaciones / pruebas				
CEM	DIN EN 61000-6-2			
	DIN EN 61000-6-3			
Resistencia a choques	DIN EN 60068-2-27	50 g (11 ms)		
Resistencia a vibraciones	DIN EN 60068-2-6	20 g (10...2000 Hz)		
MTTF [años]	686			
Directiva sobre equipos a presión	Buenas prácticas de la técnica al uso; aplicable para fluidos del grupo 2; fluidos del grupo 1 previa solicitud			
Datos mecánicos				
Peso [g]	59			
Carcasa	cilíndrico			
Dimensiones [mm]	Ø 19 / L = 66			
Materiales	inox (1.4542 / 630); inox (1.4404 / 316L); PEI			
Materiales en contacto con el fluido	inox (1.4542 / 630)			

12.4. ANEXO 4. ESPECIFICACIONES TÉCNICAS DE ADS1115



DEVICE	RESOLUTION (Bits)	MAXIMUM SAMPLE RATE (SPS)	INPUT CHANNELS Differential (Single-Ended)	PGA	INTERFACE	SPECIAL FEATURES
ADS1115	16	860	2 (4)	Yes	I²C	Comparator




Figure 4-1. RUG Package, 10-Pin (Top View)




Figure 4-2. DYN and DGS Packages, 10-Pin (Top View)

Table 4-1. Pin Functions: RUG, DYN, and DGS Packages

NAME	PIN			TYPE	DESCRIPTION ⁽¹⁾
	ADS1113	ADS1114	ADS1115		
ADDR	1	1	1	Digital input	I²C target address select
AIN0	4	4	4	Analog input	Analog input 0
AIN1	5	5	5	Analog input	Analog input 1
AIN2	—	—	6	Analog input	Analog input 2 (ADS1115 only)
AIN3	—	—	7	Analog input	Analog input 3 (ADS1115 only)
ALERT/RDY	—	2	2	Digital output	Comparator output or conversion ready (ADS1114 and ADS1115 only). Open-drain output. Connect to VDD using a pullup resistor.
GND	3	3	3	Analog	Ground
NC	2, 6, 7	6, 7	—	—	No connect. Leave the pin floating or connect to GND.
SCL	10	10	10	Digital input	Serial clock input. Connect to VDD using a pullup resistor.
SDA	9	9	9	Digital I/O	Serial data input and output. Connect to VDD using a pullup resistor.
VDD	8	8	8	Analog	Power supply. Connect a 0.1μF, power-supply decoupling capacitor to GND.

12.5. ANEXO 5. ESPECIFICACIONES TÉCNICAS DE RASPBERRY PI 4



Specification

Processor: Broadcom BCM2711, quad-core Cortex-A72 (ARM v8) 64-bit SoC @ 1.8GHz

Memory: 1GB, 2GB, 4GB or 8GB LPDDR4 (depending on model) with on-die ECC

Connectivity:

- 2.4 GHz and 5.0 GHz IEEE 802.11b/g/n/ac wireless LAN, Bluetooth 5.0, BLE
- Gigabit Ethernet
- 2 × USB 3.0 ports
- 2 × USB 2.0 ports.

GPIO: Standard 40-pin GPIO header (fully backwards-compatible with previous boards)

Video & sound:

- 2 × micro HDMI ports (up to 4Kp60 supported)
- 2-lane MIPI DSI display port
- 2-lane MIPI CSI camera port
- 4-pole stereo audio and composite video port

Multimedia: H.265 (4Kp60 decode); H.264 (1080p60 decode, 1080p30 encode); OpenGL ES, 3.0 graphics

SD card support: Micro SD card slot for loading operating system and data storage

Input power:

- 5V DC via USB-C connector (minimum 3A¹)
- 5V DC via GPIO header (minimum 3A¹)
- Power over Ethernet (PoE)–enabled (requires separate PoE HAT)

Environment: Operating temperature 0–50°C



ITCA FEPADE

SEDE CENTRAL Y CENTROS REGIONALES EL SALVADOR



La Escuela Especializada en Ingeniería ITCA-FEPADE, fundada en 1969, es una institución estatal con administración privada, conformada actualmente por 5 campus: Sede Central Santa Tecla y cuatro centros regionales ubicados en Santa Ana, San Miguel, Zacatecoluca y La Unión.

1. SEDE CENTRAL SANTA TECLA

Km. 11.5 carretera a Santa Tecla, La libertad.
Tel.: (503) 2132-7400

2. CENTRO REGIONAL SANTA ANA

Final 10a. Av. Sur, Finca Procvia.
Tel.: (503) 2440-4348

3. CENTRO REGIONAL ZACATECOLUCA

Km. 64.5, desvío Hacienda El Nilo sobre autopista a Zacatecoluca.
Tel.: (503) 2334-0763 y 2334-0768

4. CENTRO REGIONAL SAN MIGUEL

Km. 140 carretera a Santa Rosa de Lima.
Tel.: (503) 2669-2298

5. CENTRO REGIONAL LA UNIÓN

Calle Sta. María, Col. Belén, atrás del Instituto Nacional de La Unión
Tel.: (503) 2668-4700

www.itca.edu.sv

