

Arquitectura inteligente para motores eléctricos: IIoT y machine learning para la adquisición y análisis avanzado de datos

Intelligent Architecture for Electric Motors: IIoT and Machine Learning for Advanced Data Acquisition and Analysis

S. Simanek-Gutiérrez ^{a,*}, J. A. Romero-Guerrero ^b, N. Villa-Villaseñor ^c

^a Posgrado CIATEQ, A.C. Av. del Retablo 150 Col. Constituyentes Fovissste Querétaro, 76150, Qro. México.

^b Departamento Manufactura Virtual y Lean y Cad Cae, CIATEQ A. C., San Agustín Tlaxiaca, 42163, Hgo, México.

^c Departamento de Tecnologías de la Información, Electrónica y Control, CONAHCYT-CIATEQ A. C. Zapopan, 45136, Jal., México.

Resumen

Existe una demanda creciente en la industria en distintas áreas para la recolección de variables relacionadas con las condiciones de los equipos de líneas de producción, como los motores eléctricos. Esta demanda ha aumentado debido al auge de la **industria 4.0** y la **transformación digital** que las empresas están desplegando. Entendiendo que una planta típica tiene entre 6,000 a 12,000 equipos, seleccionar los equipos críticos para asignar una inversión en la instalación y puesta en marcha de sensores que midan las condiciones de operación es un desafío tanto operativo como de inversión. Es aquí es donde las tecnologías de **IIoT (Industrial Internet of Things)**, cobran relevancia, ya que permiten mitigar costos tanto en no utilizar cableado para la recolección de datos, como en un despliegue más rápido y flexible. El siguiente reto, es como monitorear, procesar, visualizar y analizar el gran volumen de datos (**Big Data**) que se generan. Por lo que en este trabajo se propone una arquitectura que aborde estos retos, como también cual metodología puede ser usada para la integración de estos proyectos, y como cada día la industria demanda más aplicación de técnicas de **Machine Learning**.

Palabras Clave: Industria 4.0, Transformación Digital, IIoT(Industrial Internet of Things), Machine Learning, Analítica de datos, Big Data.

Abstract

There is a growing demand in various industries for the collection of variables related to the conditions of production line equipment, such as electric motors. This demand has increased due to the rise of **Industry 4.0** and the **digital transformation** that companies are deploying. Understanding that a typical plant has between 6,000 to 12,000 pieces of equipment, selecting critical equipment to assign an investment in the installation and start-up of sensors that measure operating conditions is both an operational and investment challenge. This is where **IIoT (Industrial Internet of Things)** technologies become relevant, as they allow for cost mitigation by not using wiring for data collection, as well as for a faster and more flexible deployment. The next challenge is how to monitor, process, visualize, and analyze the large volume of data (**Big Data**) that is generated. Therefore, this work proposes an architecture that addresses these challenges, as well as a methodology that can be used for the integration of these projects, and how every day the industry demands more application of **Machine Learning** techniques.

Keywords: Industry 4.0, Digital Transformation, IIoT (Industrial Internet of Things), Machine Learning, Data Analytics, Big Data.

1. Introducción

Dentro del contexto de la transformación digital que están sufriendo en general la industria de bebidas y alimentos, un concepto fundamental es Industria 4.0, que fue propuesto por Klaus Schwab, uno de los fundadores del Foro Económico

Mundial. Klaus Schwab economista de origen alemán, utilizó este término por primera vez en el FEM 2016, en su discurso del evento de Hanover “la Cuarta Revolución Industrial”. Posteriormente Klaus Schwab publicó “La Cuarta Revolución Industrial”. Durante su discurso introdujo la siguiente idea “Estamos al borde de una revolución tecnológica que

*Autor para la correspondencia: sergio.simanek.gtz@gmail.com

Correo electrónico: sergio.simanek.gtz@gmail.com (Sergio Simanek Gutiérrez), adan.romero@ciateq.mx (Jorge Adan Romero Guerrero), noe.villa@ciateq.mx (Noe Villa Villaseñor).

modificará fundamentalmente la forma en que vivimos, trabajamos y nos relacionamos. En su escala, alcance y complejidad, la transformación será distinta a cualquier cosa que el género humano haya experimentado antes” (Schwab, 2016).

El cambio de paradigma busca conectar todos los equipos y dispositivos disponibles a las redes OT (Operational technology) /IT (Information technology) con el fin de adquirir datos de los procesos. Estos datos pueden incluir el desempeño de las máquinas para calcular el OEE (Overall Equipment Effectiveness), parámetros de calidad de los productos e incluso variables inherentes a la operación de motores como temperatura, corriente, torque y vibración de los equipos.

Estas condiciones presentan dos grandes retos. El primero es el gran número de instrumentos y sensores que se requieren conectar para obtener los datos. Típicamente en control distribuido y sistemas de control e instrumentación, cada sensor e instrumento se cablea directamente a las tarjetas de control, utilizando protocolos como 4-20 mA, Hart, On-Off de 5 Vcd, 10 Vcd conocidos como “señales duras”. Lo anterior deriva en 2 temas, el primero incrementa el costo de la sonorización e instrumentación por el cableado necesarios, ya sea par trenzado o triadas de cable de señal, lo segundo, es un costo de instalación elevado, ya que en la industria el cableado es típicamente instalado sobre canalización, ya sea tubería Conduit o charola de distribución como lo muestra la Figura 1.

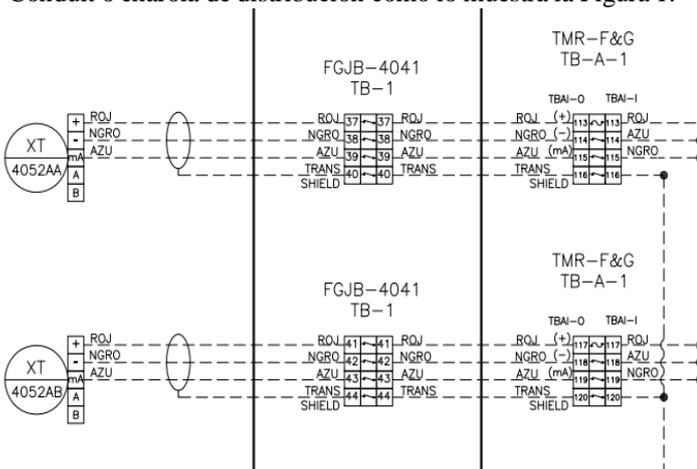


Figura 1: Diagrama tubería e instrumentación (DTI). Fuente: (Creus Solé, 2010)

Para abordar la problemática mencionada, se han desarrollado tecnologías dentro del esquema de Industria 4.0. Una de ellas son los sensores IIoT, los cuales permiten mitigar los efectos anteriormente descritos en este tipo de integraciones. Por ejemplo, en un sistema de colección de datos de 100 equipos en el cual se colectan 6 variables por cada equipo, se necesitarían un total de 600 variables que se están colectando, y eso implicaría 600 sensores y al menos 600 pares de cables para señal más 600 pares de alimentación. Los sensores IIoT ayudan a reducir esta complejidad y el número de cables requeridos para la recolección de datos.

2. Sensores IIoT

IIoT son las siglas en inglés de "Industrial Internet of Things" lo que en español significa "Internet Industrial de las Cosas". Este concepto se refiere a la interconexión de

dispositivos industriales y maquinaria a través de Internet y otras tecnologías de comunicación, con el objetivo de mejorar la eficiencia, la productividad y la seguridad en los procesos industriales.

Dentro de las arquitecturas típicas que se encuentran en los dispositivos IoT, en particular IIoT se pueden identificar conforme la Figura 2:

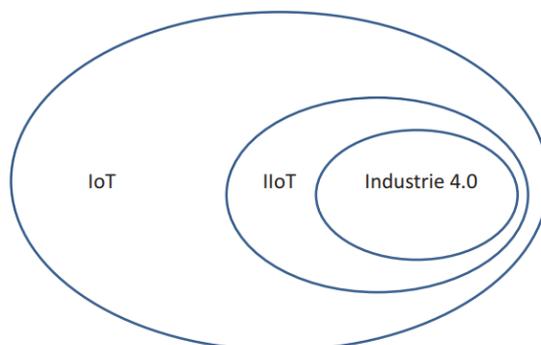


Figura 2: Relación entre IoT, IIoT, e Industria 4.0. Fuente: (Serpanos & Wolf, 2018)

Aunque hay una gran cantidad de fabricantes y protocolos para dispositivos IIoT, la mayoría están compuestos por un sensor y un radio que permiten enviar los datos. Estos datos son luego concentrados en un Gateway (que es un controlador, que permite concentrar un cierto número de radios de comunicación, bajo la cobertura de una antena), para este caso se hizo la selección de los sensores y radios de la marca Banner:

- Nodo: Q45VTP
- Gateway: DXM700
- Sensor: QM30VT1 (Temperatura y vibración)

Para la selección de esta integración, se ha tomado en cuenta la capacidad del Radio de comunicación Q45VTP el cual funciona con dos baterías de litio AA de 3.6 V, y el fabricante informa que al trabajar en la frecuencia de 900 MHz, y a una potencia de 250 mW, la vida útil puede oscilar entre 2 a 3 años con un muestreo de datos cada 5 minutos, como lo indica la Figura 3.

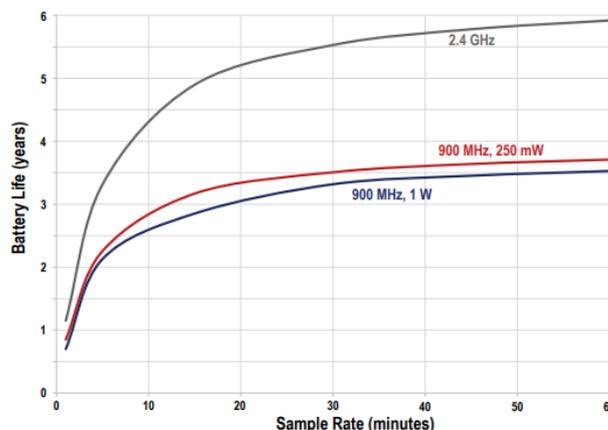


Figura 3: Vida de batería estimada para radio Q45VTP. Fuente: (Banner Engineering, 2022)

En términos de la selección del sensor QM30VT1, se eligió debido a que permite con un mismo integrado monitorear 6 variables, dentro de un catálogo de registros. Para este caso, se utilizó la configuración sugerida por el fabricante, que incluye la medición de la temperatura del motor, la vibración en dos ejes (Velocidad RMS (root mean square / valor cuadrático medio) en X, Velocidad RMS en Z, Aceleración de alta frecuencia RMS en X y Aceleración de alta frecuencia RMS en Z), así como un registro de estado del sensor y el radio que se envía al Gateway. En esta configuración, el Gateway soporta hasta 46 radios por nodo y puede configurarse mediante EthernetIP o Modbus utilizando una tarjeta de comunicación Prosoft.

3. Arquitectura de Adquisición de datos

Banner como fabricante de los dispositivos IIoT para el monitoreo de condición de operación de motores eléctricos, sugiere la arquitectura mostrada en la Figura 4, para la recolección de datos.



Figura 4: Arquitectura Banner. Fuente: (Banner Engineering, 2022)

No obstante, la arquitectura propuesta presenta ciertas limitaciones, especialmente en lo que respecta a los requerimientos de la industria de Bebidas y Alimentos, a continuación, se enuncian alguna de las limitaciones:

- Es requerida la nube propiedad de Banner
- Los Gateway requieren conexión a Internet
- Las redes industriales de OT tienen restricción de permisos en Firewalls
- No existe una etapa de preprocesamiento
- No existe una etapa de diagnóstico de la calidad de datos y el estado de los sensores.

El principal requisito para la implementación de un sistema de adquisición de datos a gran escala es que los datos deben estar On-premise, o en otras palabras alojados y almacenados en servidores propiedad de la empresa. Esto es un modelo muy diferente al uso de nubes de terceros como puede ser AWS o Azure. Con base a los puntos anteriores, se propuso el modelo ad-hoc mostrado en la Figura 5.

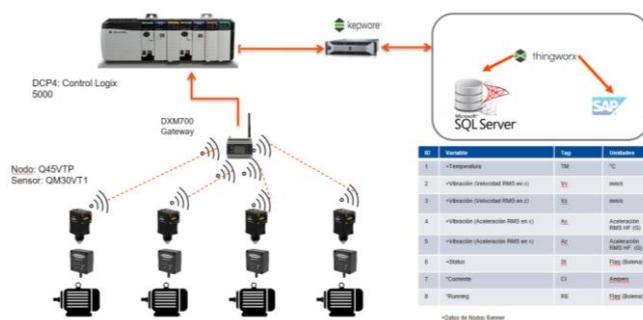


Figura 5: Arquitectura propuesta para adquisición de datos con IIoT. Fuente: Elaboración propia.

En la propuesta de arquitectura presentada, se agrega una capa con un PLC, que permite interconectar los Gateway con la red OT. Además, se realiza un acondicionamiento de las señales, así como una detección de fallas y verificación de la calidad de datos, lo cual es sumamente importante en este tipo de sistemas de adquisición de datos a gran escala, en equipos como motor y bomba tipo Cornell que muestra la Figura 6.

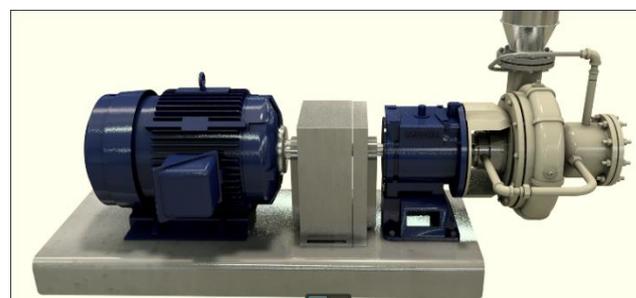


Figura 6: Equipo motor y bomba tipo Cornell, donde es colocada la sonorización para monitoreo de temperatura, velocidad y aceleración. Fuente: Elaboración propia.

4. Acondicionamiento de señales

El sistema de adquisición de datos a gran escala propuesto e implementado en este artículo, incluye una etapa de acondicionamiento de señales en la que se llevan a cabo los siguientes procesos, como lo muestra la Figura 7:

- Lectura de registros en unidades de ingeniería
- Conversión de unidades, operación de escalamiento
- Asignación de valores a variables de lectura
- Monitoreo de variación de dato, se toman 6 muestras en intervalos de 5 minutos, verificando que exista un camino en la lectura de temperatura. Esto permite saber si el sensor y el radio siguen comunicando o el dato se quedó congelado
- Monitoreo de status de comunicación del Radio
- Monitoreo del bit de desconexión de sensor a radio de comunicación
- Monitoreo del bit de operación de radio, esto permite monitorear la vida útil de las baterías y cuando es necesario cambiar la alimentación de los radios

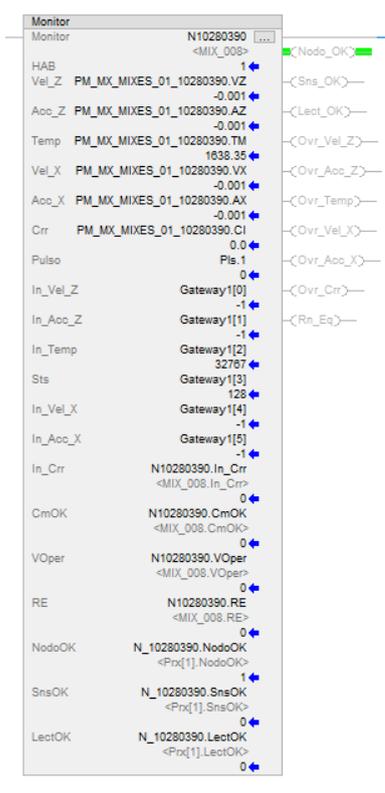


Figura 7: Bloque de acondicionamiento y monitoreo de falla. Fuente: Elaboración propia.

La implementación de sistemas con un gran número de sensores (100-300), y una gran cantidad de datos de condición de operación (de 600 a 1800 datos), requiere una estrategia de monitoreo de la calidad de la señal, así como de la salud de los sensores y de la infraestructura del sistema.

5. Visualización

En todo sistema de recolección de datos, es necesario contar con una etapa que permita la conexión en tiempo real (Live Data) y una conexión a base de datos (Historizador), existen diferentes soluciones para esto, como Historian, KepserverEx Historian, etc. En el caso particular de este estudio, se utilizó una base de datos en SQL Server de Microsoft. Se consideró que, para un sistema con 300 puntos de medición, y por cada punto existen 6 variables asociadas, lo que da como resultado 1800 datos diferentes, más 600 datos de VDF (Variador de frecuencia), para un total de 2400. Con una frecuencia de muestreo de 1 minuto, se están colectando 144,000 datos por hora, y 3,456,000 registros al día, cerca 6 GB de datos mensual, esto implica manejo de Big Data (Hassanien & Darwish, 2021).

Para visualizar los datos, se requiere una interfase gráfica. Típicamente se usa alguna aplicación para creación de HMI (Human Machine Interface) como puede ser Factory Talk View de Rockwell o Intouch de Aveva. Sin embargo, para este caso se utilizó un modelo de WEB con cliente-servidor como lo muestra la Figura 8, utilizando MATLAB (Chapman, 2013).

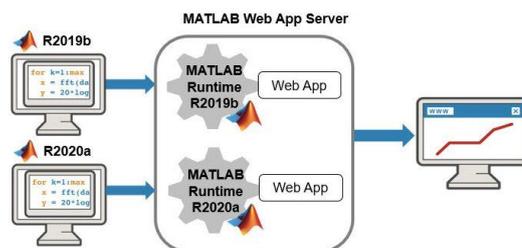


Figura 8: Arquitectura MATLAB Web App Server (Matworks, 2023)

Existen diversas herramientas y plataformas que permiten la creación de interfaces gráficas para la visualización de datos en tiempo real y en el histórico de señales. MATLAB es una de ellas, y ofrece la posibilidad de desarrollar interfaces personalizadas que se adapten a las necesidades específicas de cada proyecto, como realizar graficas de las señales mostrado en la Figura 9.

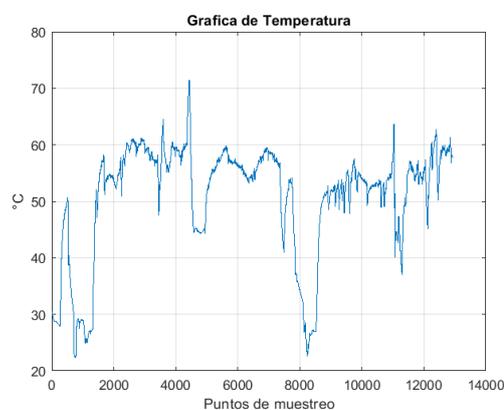


Figura 9: Grafica de temperatura de 10 días. Fuente: Elaboración propia.

6. Analítica de Datos

Además de visualizar los datos mediante graficas en series de tiempo, también es necesario implementar una capa para analizar datos de manera de estadística. Muchas de las plataformas actuales solo permiten crear visualización de datos en tiempo real o en el mejor de los casos, algunas capacidades de obtener alarmas y registros. También es necesario hacer análisis de datos, y ahí es donde MATLAB tiene su fortaleza, algunas de las toolbox recomendables para estos proyectos son:

- Database Toolbox
- Deep Learning Toolbox
- Industrial Communication Toolbox
- Parallel Computing Toolbox
- MATLAB Compiler
- Predictive Maintenance Toolbox
- Signal Processing Toolbox
- Statistics and Machine Learning Toolbox
- System Identification Toolbox
- MATLAB Web App Server

Dentro de algunos de los análisis básicos que es posible realizar, está el análisis estadístico descriptivo para tener una perspectiva del comportamiento de los datos que trae cada señal como se muestra en la Figura 10. También existen

análisis de cluster, ANOVA, PCA (Análisis de Componentes Principales)

predicción, como en series de tiempo. Sin embargo, requieren un alto esfuerzo en desarrollo y capacidad de cómputo.

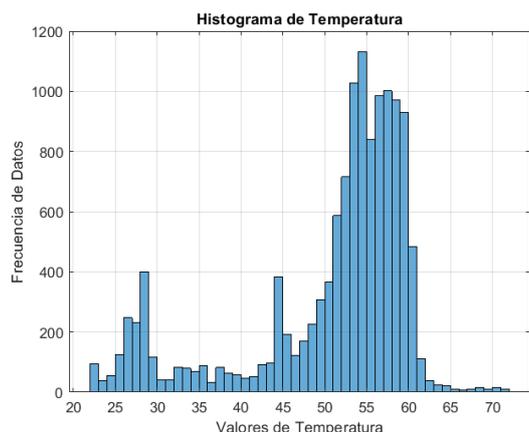


Figura 10: Histograma y distribución de datos de temperatura de 10 días. Fuente: Elaboración propia

7. Técnicas de machine Learning

En el auge de las tecnologías de industria 4.0 siempre se hace mención específica de AI (Inteligencia Artificial) y de ML (Machine Learning), aunque típicamente en el ámbito comercial muchas soluciones o plataformas usan los términos de forma indistinta o como sinónimos, existe una distinción entre estos conceptos (Fernandes de Mello & Ponti, 2018)

El concepto de Inteligencia Artificial (AI) es un campo de estudio de la Informática, Matemáticas y Estadística, que busca desarrollar sistemas y algoritmos capaces de realizar tareas que requieren un cierto grado de inteligencia humana, algunas de las aplicaciones son: el aprendizaje automático, el procesamiento del lenguaje natural, visión artificial y robótica. Mientras Machine Learning (ML), es una rama de la AI enfocada en desarrollar e implementar algoritmos y modelos que permiten a los sistemas computacionales aprender a partir de los datos recolectados, sin requerir una programación explícita para realizar la tarea. En ML se utilizan técnicas estadísticas y matemáticas, especialmente en el ámbito del cálculo vectorial y álgebra lineal, para analizar grandes conjuntos de datos y detectar patrones que permitan hacer predicciones y tomar decisiones, en la Figura 11 se muestra una clasificación de los distintos algoritmos.

En el contexto de la literatura sobre el tema, las técnicas y modelos en ML se clasifican en 3 grandes grupos (Jo, 2021):

- Aprendizaje supervisado
- Aprendizaje no supervisado
- Aprendizaje reforzado.

Uno de los algoritmos que en los últimos años ha tenido un alto impacto son las redes neuronales, tanto profundas como convolucionales, ya que, con el incremento de capacidad de cómputo, masificación de GPU, y una gran cantidad de datos colectados y etiquetados, es posible probar y entrenar estos algoritmos para hacer reconocimiento de patrones, que es muy útil en reconocimiento de imágenes y en modelos de

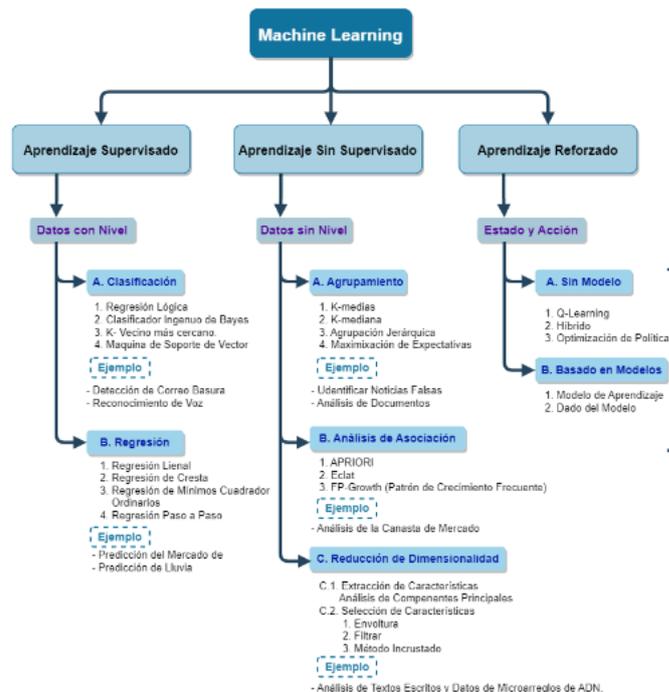


Figura 11: Claficación de algoritmos en ML. Fuente: Elaboración basada con información de (Joshi, 2020)

En este desarrollo se utilizó la técnica de clasificación de K-means, que permite hacer un cruce de datos entre dos variables que se relacionen. Para las velocidades y aceleraciones, existe una correlación entre los ejes x y z, al comparar los datos del mismo tipo se obtienen la gráfica (Ver Figura 12).

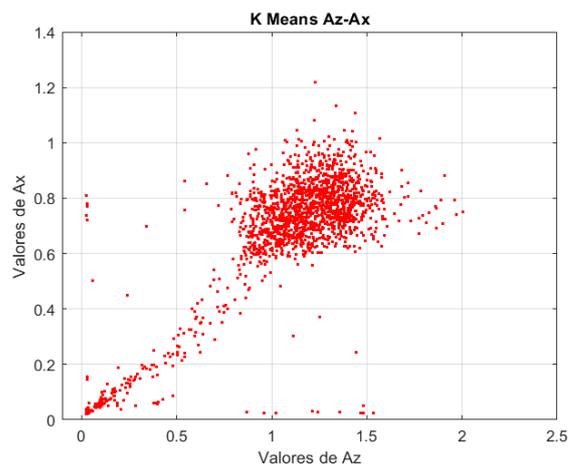


Figura 12: Correlación entre aceleraciones 10 días de datos. Fuente: Elaboración propia.

Para analizar las aceleraciones RMS de alta frecuencia, se utilizaron 12,938 datos en el eje x y 12,938 datos en el eje z. Al cruzar esta información, se obtiene un plano que muestra la distribución y concentración de los datos. El resultado esperado es la presencia de dos grandes zonas de concentración: la primera en la región cerca a cero, y que correspondería a un estado de reposo del motor, mientras que la segunda zona debería estar concentrada en un valor típico 0.6 y 1.0, que sería el estado de operación del motor, aquí se

puede distinguir que si un equipo opera de forma normal, la concentración de datos y de puntos debería ser homogénea, sin embargo, si se observan datos fuera de esas zonas o muy dispersos, indicaría una alta probabilidad que el equipo este trabajando en condiciones anormales como será desbalanceo, desalineación de flecha o problemas de lubricación o en rodamientos (Ver Figura 13).

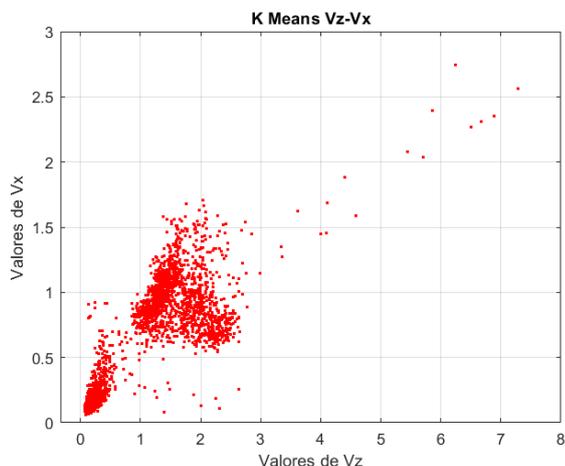


Figura 13: Correlación entre velocidades 10 días de datos. Fuente: Elaboración propia.

Durante el análisis de las velocidades en RMS se observa que los datos si presentan dos grandes zonas, sin embargo, no se están concentrando de forma homogénea, lo que indica seguramente un problema de balance en uno de los ejes. Otro punto relevante es observar las anomalías, que pueden ser encontrados como los puntos que están más allá de 3 sigma (desviación estándar), lo que indica una condición fuera de lo normal del equipo.

8. Conclusiones

Los proyectos de transformación digital en la industria tienen requisitos específicos en cuanto diseño y a los recursos disponibles, tanto operativos, técnicos y financieros. Las tecnologías como IIoT permiten mitigar costos, y acelerar la implementación de proyectos de adquisición de datos a gran escala. Por otro lado, siempre es necesario considerar requerimientos y restricciones de red OT y Ciberseguridad. Con la implementación de este tipo de sistemas, se genera un gran volumen de datos, que no pueden ser tratados y procesados como típicamente se usa en la industria, y se necesitan herramientas más robustas, que permitan visualizar

la información, y hacer análisis de los datos. Finalmente, el auge de tecnologías y técnicas como AI (ML y DL), requieren también plataformas mucho más robustas, que tengan la capacidad de procesamiento y desarrollo de funciones, que lleven a los usuarios a una interpretación adecuada de los datos.

Con la adopción de las nuevas tecnologías de Industria 4.0, se ha producido un cambio de paradigma, donde se ha dejado de lado el uso de herramientas tradicionales como Excel, para adoptar plataformas más avanzadas como MATLAB (Xue, 2020) y Python (Eckroth, 2018). Estas plataformas permiten la implementación de algoritmos de aprendizaje automático (ML), ofreciendo una capacidad de procesamiento mucho más potente y una interpretación mejorada de los datos. Que conlleva a un cambio en las arquitecturas de desarrollo y puesta en producción, para que, con estos resultados, la industria puede tomar decisiones estratégicas que potencien la competitividad y la eficiencia en los recursos.

Referencias

- Banner Engineering. (2022). Sure Cross® Wireless Q45VTP and VTPD Node (P/N 208637 Rev. D).
- Chapman, S. J. (2013). MATLAB® Programming with Applications for Engineers. Cengage Learning.
- Creus Solé, A. (2010). Instrumentación Industrial. Alfaomega Grupo Editor, S.A. de C.V., México.
- Eckroth, J. (2018). Python Artificial Intelligence Projects for Beginners. Packt Publishing.
- Fernandes de Mello, R., & Ponti, M. A. (2018). Machine Learning. A Practical Approach on the Statistical Learning Theory. Springer International Publishing AG.
- Shehab,N.,Badawy, M., y Arafat, A. (2021). Big Data Analytics and Preprocessing. Hassanien, A. E., & Darwish, A. (Eds). Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenge. Springer Nature
- Jo, T. (2021). Machine Learning Foundations: Supervised, Unsupervised, and Advanced Learning. Springer Nature Switzerland AG.
- Joshi, A. V. (2020). Machine Learning and Artificial Intelligence. Springer Nature Switzerland AG 2020.
- Matworks. (2023).. Obtenido de <https://la.mathworks.com/products/MATLAB-web-app-server.html>
- Schwab, K. (2016). La cuarta revolución industrial. Leddy.
- Serpanos, D., & Wolf, M. (2018). Internet-of-Things (IoT) Systems: Architectures, Algorithms, Methodologies. Springer.
- Xue, D. (2020). MATLAB® Programming. Mathematical Problem Solutions. Degruyter.