

# Mantenimiento predictivo no supervisado: Detección de anomalías en la industria

Jorge Metri-Ojeda<sup>1</sup>, Sergio Simanek-Gutierrez<sup>2</sup>

<sup>1</sup> Universidad De Las Américas Puebla, San Andrés Cholula,  
México

<sup>2</sup> Posgrado CIATEQ A.C., Querétaro,  
México

jorge.metrioa@udlap.mx, Sergio.simanek.gtz@gmail.com

**Resumen.** La Gestión de Pronóstico y Salud (PHM), también conocida como Mantenimiento Predictivo (PdM), es actualmente una técnica de vanguardia para evitar grandes pérdidas en las industrias manufactureras. El objetivo de este trabajo es comparar diferentes algoritmos no supervisados para la detección de anomalías como una opción viable para conjuntos de datos industriales no etiquetados. Se utilizó un conjunto de datos del mundo real compuesto por 5 variables (aceleración de vibración, velocidad de vibración y temperatura) de 118 equipos de una instalación de una industria de manufactura. Después de la extracción de características, se aplicó un Análisis de Componentes Principales (PCA) para la reducción de dimensionalidad y se utilizó para entrenar un Bosque de Aislamiento, un modelo de Máquina de Soporte Vectorial de Una Clase (OC-SVM), modelo de Factor de Aislamiento Local (LOF) y Modelos de Mezcla Gaussiana. Los modelos se evaluaron en términos de precisión, con el objetivo de maximizar la detección de 12 fallas registradas como anomalías dentro del conjunto de datos. El modelo con mejor rendimiento fue el GMM con un 91 % de exactitud, seguido por OC-SVM con un 83 % de exactitud. La velocidad media en el eje Z, el valor máximo de la velocidad en el eje X y la desviación estándar de la aceleración en el eje X fueron las variables clave para diferentes tipos de fallas. Este trabajo demuestra el uso exitoso del aprendizaje no supervisado para la detección de anomalías a nivel industrial, lo que puede utilizarse como referencia para aplicaciones similares en otras industrias o en la misma industria.

**Palabras clave:** Mantenimiento predictivo, detección de anomalías, aprendizaje no supervisado.

## Unsupervised Predictive Maintenance: Anomaly Detection in Industry

**Abstract.** Prognostics and Health Management (PHM), also known as Predictive Maintenance (PdM), is currently a cutting-edge technique

to prevent major losses in manufacturing industries. The objective of this study is to compare different unsupervised algorithms for anomaly detection as a viable option for unlabeled industrial datasets. A real-world dataset was used, consisting of five variables (vibration acceleration, vibration velocity, and temperature) from 118 machines in a manufacturing facility. After feature extraction, Principal Component Analysis (PCA) was applied for dimensionality reduction and used to train an Isolation Forest, a One-Class Support Vector Machine (OC-SVM), a Local Outlier Factor (LOF) model, and Gaussian Mixture Models (GMM). The models were evaluated based on their accuracy, aiming to maximize the detection of 12 failures recorded as anomalies within the dataset. The best-performing model was GMM with 91% accuracy, followed by OC-SVM with 83% accuracy. The mean velocity on the Z-axis, the maximum velocity on the X-axis, and the standard deviation of acceleration on the X-axis were identified as key variables for distinguishing different types of faults. This work demonstrates the successful application of unsupervised learning for industrial anomaly detection, which can serve as a reference for similar applications in other sectors or within the same industry.

**Keywords:** Predictive maintenance, anomaly detection, unsupervised learning.

## 1. Introducción

La Gestión de Pronóstico y Salud (PHM) de maquinaria, también conocida como Mantenimiento Predictivo (PdM), incluye varias técnicas para anticipar la degradación crítica de equipos industriales con el objetivo de reducir riesgos y pérdidas económicas evitando periodos sin productividad. En los EE.UU., se estima que las industrias gastan alrededor de 200 mil millones de dólares en mantenimiento, y las paradas inesperadas de producción generan gastos de aproximadamente 60 mil millones de dólares [1,2].

A lo largo de los años, la industria ha evolucionado en diferentes enfoques para la gestión del mantenimiento de equipos, por ejemplo 1) la corrección tras fallo, que ocurre solo cuando un equipo deja de funcionar; 2) el mantenimiento preventivo que generalmente es una reparación o reemplazo de partes basado en tiempo de uso; finalmente 3) el mantenimiento predictivo que usa métodos de inferencia estadística y conocimiento en ingeniería, aplicados a datos históricos, para la detección temprana de fallas [2,3].

Las estrategias PHM y PdM se aplican actualmente en diferentes industrias como maquinaria agrícola, componentes de aeronaves, seguridad de redes de comunicación, industrias de manufactura, entre otras. Los métodos más comunes son técnicas estadísticas, métodos de Inteligencia Artificial (modelos de Aprendizaje Automático y Profundo), y modelos basados en datos como los modelos de Vida Útil Remanente. Para lograr los modelos mencionados, se necesita tener datos etiquetados, es decir, el conjunto de datos debe tener ejemplos de estado saludable y de fallos. Desafortunadamente, es muy común no

tener acceso a datos etiquetados, y la estrategia debe dirigirse hacia metodologías no supervisadas [3,4].

El análisis de patrones con métodos no supervisados también se conoce como detección de anomalías. Las anomalías pueden entenderse como instancias de datos que se desvían del comportamiento normal del sistema. En el escenario de Mantenimiento Predictivo (PdM), las anomalías se consideran eventos que requieren inspección, monitoreo o incluso intervención. En el caso específico de no tener eventos de falla explícitos en el conjunto de datos, las anomalías pueden representar un enfoque robusto para el comportamiento anormal, útil para anticipar la degradación aumentada o el detrimento crítico de los componentes de la maquinaria [3,4].

Este artículo tiene como objetivo utilizar modelos de Aprendizaje Automático no supervisados para detectar anomalías dentro de una instalación de la industria alimentaria como una solución viable y asequible para PHM y PdM. Además, la hipótesis de este trabajo es que los modelos de Aprendizaje Automático no supervisados pueden ser utilizados para la detección de fallos.

## **2. Metodología**

### **2.1. Conjunto de datos y preprocesamiento**

El conjunto de datos utilizado fue creado dentro de una industria de manufactura. Se equiparon 118 equipos con sensores biaxiales que registraron el rms de la aceleración (fuerza G) y velocidad (mm/s) en los ejes X y Z, así como la temperatura en grados Celsius (°C) cada minuto entre el 21 de Noviembre de 2023 y Diciembre del 2024. Los datos se almacenaron en una base de datos Microsoft SQL Server y el procesamiento de datos se realizó con el software Matlab R2023b. Como parte del pre-procesamiento, los datos faltantes fueron imputados con interpolación cúbica polinómica por partes (spline cubic interpolation), y posteriormente filtrado utilizando un filtro pasa-baja usando el 90% del ancho de banda ocupado por las frecuencias como punto de corte.

En cuanto a la seguridad de datos, la empresa se encarga de la ciberseguridad concediendo el acceso a los datos y servidores a través de una red privada. En el caso de la integridad de los datos, los sensores instalados tienen un sistema de diagnóstico para identificar desconexiones físicas del sensor, desvinculación con los nodos y congelación de lecturas, las cuales se denominarán a partir de ahora como banderas de diagnóstico. Las banderas de diagnóstico permiten actuar rápidamente para reestablecer la entrada de datos íntegra, y evitar la pérdida de calidad; no obstante, existen puntos de medición con banderas activas (p.e.: sensores desconectados), que representaron alrededor del 1 al 10% de las observaciones del conjunto de datos (variando de sensor a sensor). Estos puntos fueron contemplados para la interpolación usando interpolación cúbica; se descartó la interpolación lineal para preservar el comportamiento de la señal.

## 2.2. Extracción y selección de características

Se calcularon variables estadísticas en el dominio de tiempo, por ejemplo, media ( $\mu$ ), desviación estándar ( $\sigma$ ), valor máximo ( $max$ ), varianza ( $var$ ), curtosis ( $K$ ) y asimetría ( $\gamma$ ); adicionalmente, se calcularon variables en el dominio de la frecuencia. Para ello, se aplicó una Transformada de Fourier a cada señal y se extrajeron los momentos estadísticos del espectro de frecuencia, por ejemplo, frecuencia media ( $\mu_{freq}$ ), mediana de la frecuencia, varianza ( $var_{freq}$ ), curtosis ( $K_{freq}$ ), asimetría ( $\gamma_{freq}$ ) y distancia de pico a pico. Todas las características fueron calculadas en todas las variables originales (Aceleración y Velocidad en ejes X y Z, y Temperatura). La selección-transformación de variables se realizó utilizando un Análisis de Componentes Principales (PCA), esto nos ayudó a disminuir la dimensionalidad de los datos y la colinealidad. Para el entrenamiento de los modelos, se eligieron las variables que acumularon un 90% de la varianza explicada dentro del modelo de PCA (entre 20-25 variables dependiendo del equipo).

## 2.3. Entrenamiento de modelos

Este trabajo se enfocó en cuatro algoritmos: **Bosque de Aislamiento (IF)**, **Modelos de Mezcla Gaussiana (GMM)**, **LOF** y **OC-SVM**. Todos los modelos se ajustaron utilizando el *Statistics and Machine Learning toolbox* de Matlab R2023b. Todos los modelos se configuraron para detectar alrededor del 8% de anomalías para ser comparables con los **Modelos de Mezcla Gaussiana**.

El Bosque de Aislamiento (IF) utiliza un procedimiento de *aislamiento* similar a los árboles de decisión. El procedimiento de *aislamiento* tiene como objetivo dividir los datos por una o más variables hasta que una sola instancia se aisle del resto, a lo cual se le considera un *iTree*. El modelo IF asume que un valor atípico será más fácil de aislar que un valor normal. En este estudio, se eligieron 150 árboles *iTree* dentro del modelo IF [5,6].

El Modelo de Mezcla Gaussiana (GMM) es un método de clustering no supervisado basado en encontrar múltiples distribuciones gaussianas calculadas con el algoritmo de Expectación-Maximización. Para este estudio, los GMM se probaron en un rango 2-10 clusters (asumiendo que el mínimo podría ser cluster normal y anómalo), el modelo con mejor rendimiento se seleccionó con el menor Criterio de Información Bayesiano. Después de seleccionar el mejor modelo, el cluster más grande se seleccionó como el cluster de datos normales, y los clusters restantes se consideraron como clusters de anomalías [7].

La Máquina de Vectores de Soporte de Una Clase (OC-SVM) tiene como objetivo encontrar el hiperplano óptimo para mapear el espacio de entrada en un espacio de alta dimensionalidad que permita separar las observaciones a través de márgenes superiores e inferiores [8,9].

El Factor de Aislamiento Local (LOF) es un algoritmo de detección de anomalías basado en la densidad y distancia. En este estudio se eligió la distancia euclidia como métrica de entrenamiento del modelo [10].

## 2.4. Evaluación de modelos

Debido a la naturaleza de este trabajo (aprendizaje no supervisado), es difícil definir una estrategia de evaluación. Sin embargo, basándonos en el trabajo presentado en [5] y [6], proponemos la siguiente metodología para la evaluación. La planta de manufactura proporcionó 12 fallas entre enero de 2024 y mayo de 2024, estos datos son irrelevantes para desarrollar un modelo de Aprendizaje Supervisado y el sobremuestreo podría llevar a un sobreajuste del modelo porque la etiqueta minoritaria representa solo el 0.07 % de todo el conjunto de datos. Por lo tanto, se priorizó maximizar la detección de fallas como anomalías y evaluar los modelos en términos de exactitud (Ecuación 1) de la detección de fallas

$$Exactitud = \frac{\text{Fallas detectadas}}{\text{Fallas totales}}. \quad (1)$$

Para obtener la característica más importante para la detección de anomalías, aplicamos una *prueba T-Student* en las anomalías observadas. Después de comparar las *señales de anomalía* y las *señales normales*, seleccionamos la variable con el *p-valor* más bajo como la variable más importante para la detección de anomalías.

## 3. Resultados y discusión

El porcentaje de datos anómalos en el conjunto de datos fue de 8 % utilizando todos los modelos descritos anteriormente (Tabla 1). Los modelos con mejor rendimiento fueron el GMM y el OC-SVM, detectando alrededor del 0.916 (91.6 %) y el 0.833 (83 %) de las fallas como anomalías. Por otro lado, IF y LOF demostraron la menor exactitud, detectando aproximadamente el 0.583 (58.3 %) de las fallas como anomalías (Tabla 1). Debido al buen rendimiento del GMM, el resto del manuscrito se centró en estudiar este modelo en 3 fallas importantes como la rotura de la correa del motor, fallas en los rodamientos y una falla por sobrecorriente en el motor.

Debido a los acuerdos de privacidad y confidencialidad, no es posible divulgar beneficios e impactos económicos puntuales de los modelos dentro de la planta de manufactura. Sin embargo, los modelos han permitido ahorrar horas de trabajo, desperdicio de producto y tiempos muertos al planificar revisiones y mantenimiento de acuerdo con el volumen de anomalías detectadas. En este sentido, se planifica el mantenimiento en equipos que han demostrado un alto volumen de anomalías en periodos de tiempo definidos (p.e.: 1 semana). Este enfoque en conjunto con los paros planeados para limpieza e inspección, permite mitigar las falsas alarmas disparadas por los modelos, por ejemplo, equipos con 1 o 2 anomalías aisladas.

La razón de la diferencia entre el rendimiento de los modelos puede deberse al tipo de anomalías y la metodología de detección de anomalías de los modelos. De acuerdo con [11], las anomalías pueden dividirse en diferentes categorías, entre ellas se encuentran las puntuales, contextuales y colectivas. Las anomalías

**Tabla 1.** Rendimiento de modelos de detección de anomalías.

Modelo	Exactitud	Proporción de anomalías (%)
IF	0.583	8.00
OC-SVM	0.833	8.00
<b>GMM</b>	0.916	8.72
LOF	0.583	8.00

puntuales son aquellos puntos que difieren del resto de casos u observaciones, mientras que las colectivas se refieren a un grupo de puntos, que en conjunto, difieren del resto de datos. Es probable que en este conjunto de datos se presenten anomalías colectivas que fueron más fáciles de capturar por modelos que ajustan una función de probabilidad de distribución o una función matemática como en el caso del GMM y los hiperplanos de la máquina de soporte vectorial de una clase en comparación de los modelos de aislamiento por distancia (IF y LOF) [12].

En el caso del efecto del procesamiento de datos en los resultados del GMM, se realizaron pruebas preliminares con diferentes valores de varianza explicada por el modelo de Análisis de Componentes Principales; se observó que aumentar la varianza explicada hacia un 99% o disminuirla por debajo de 90% reducía la exactitud de los modelos en rangos de 0.25 a 0.5, siendo este un parámetro importante debido a que transforma los datos para entrenar al modelo final.

Por otro lado, como parte de los hiperparámetros del modelo, se comparó el efecto de utilizar la matriz de covarianza completa o diagonal, siendo la última la que demostró los mejores resultados. El uso de la matriz de covarianza completa creaba 1 o 2 clusters (de tamaños similares) que fallaba al detectar las fallas como anomalías o generaba un exceso de anomalías detectadas. De acuerdo con los trabajos [13,14], la matriz de covarianza completa puede ocasionar un sobreajuste del modelo al considerar las correlaciones entre las variables independientes y crear límites flexibles entre clusters.

El primer ejemplo de anomalías detectadas por el modelo GMM se dio 3 días previos a la rotura de correa del motor de un equipo. La prueba *T-Student* demostró que la variable más importante era el valor medio de la Velocidad en el eje Z ( $p = 1,17^{-20}$ ). al inspeccionar la variable, se observó que la velocidad eje Z tenía un valor más alto en el valor medio de las observaciones anómalas (3.5 mm/s) en comparación con las observaciones normales (1.25 mm/s). De igual manera, los valores máximos de velocidad en eje Z para las anomalías fue considerablemente mayor (4-6.5 mm/s) en comparación con las observaciones normales (1.8 - 2.9 mm/s).

Otra de las anomalías detectadas por el modelo de GMM resultó en una falla en los rodamientos del equipo. De acuerdo con la prueba *T-Student*, la variable más importante fue el valor máximo en la velocidad del eje X ( $p = 1,86^{-17}$ ). Al observar los valores máximos de velocidad del eje X, se encontró que las señales con anomalías podían llegar a velocidades de hasta 14 mm/s (con una media

de 7.75 mm/s), mientras que las observaciones normales demostraban valores de aproximadamente 5.5 mm/s con una media de 3.9 mm/s.

Finalmente, el modelo GMM detectó una anomalía que se desarrolló a los 3 días en una falla por sobrecorriente. El análisis de las variables demostró que la desviación estándar en la aceleración del eje X era la característica más importante ( $p = 3,21^{-12}$ ) para determinar que dicha observación fue una anomalía. Al analizar los valores de la variable se observó que las señales normales se caracterizaban por una baja variabilidad (desviación estándar) entre un 0.05 - 0.15 G; por otro lado, las señales anómalas tuvieron una desviación estándar de hasta 0.25 G.

Los resultados presentados en este trabajo son comparables a otros estudios sobre la detección de anomalías utilizando conjuntos de datos industriales. Por ejemplo, Carrasco et al. [4] utilizaron un conjunto de datos proporcionado por ArcelorMittal. Los autores implementaron los algoritmos *Histogram Based Outlier Score*, *Lightweight Online Detector of Anomalies* y *Extreme Gradient Boosting Outlier Detection*. El mejor modelo fue el algoritmo *Extreme Gradient Boosting Outlier Detection*, calculando variables en una ventana de tiempo de 48 h. Su rendimiento varió entre un 0.45 a 0.85 usando el Área Bajo la Curva (AUC) como métrica dependiendo de las variables calculadas.

En otro estudio, se utilizó un OC-SVM para la detección de anomalías en una turbina de gas industrial de una empresa coreana; el conjunto de datos estaba compuesto principalmente por datos de temperatura, presión de los compresores y tasas de flujo de combustible. El modelo resultante detectó anomalías con una precisión de alrededor de 0.54-0.64 y una puntuación F-1 de 0.62-0.63 [15].

Finalmente, en un estudio con datos de turbinas de gas, realizado por Lee et al., [16], se evaluaron los modelos OC-SVM, Isolation Forest, k-means y un Auto-Encoder Convolutivo para la detección de anomalías. Los resultados demostraron un rendimiento excepcional del Auto-Encoder (0.874) en comparación con los otros modelos (0.034 - 0.522) en términos de puntuación F-1, seguido por el Isolation Forest. Sin embargo, algoritmos muy complejos como el Auto-Encoder podrían ser difíciles de implementar en aplicaciones en línea.

## 4. Conclusión

Este artículo demostró que los modelos de aprendizaje automático no supervisados pueden utilizarse para la detección de anomalías en un entorno industrial. Además, los modelos detectan entre el 83 % y el 91 % de las fallas como anomalías en un conjunto de datos sin etiquetas. Este enfoque nos permitió identificar eventos relevantes en cada sensor de la planta de manufactura, lo cual podrá prevenir daños críticos en la línea de producción. Se espera que este método sea replicable en escenarios similares donde no se cuente con datos etiquetados. Para futuras investigaciones, se planea construir índices de salud no supervisados, aunque esperamos contar con etiquetas para explorar modelos supervisados de diagnóstico de fallas y vida útil remanente.

**Agradecimientos.** Los autores agradecen a la empresa de manufactura por la disponibilidad de los resultados y a la empresa encargada de la instalación del hardware para la adquisición de datos (nombres omitidos por privacidad), así como al equipo de desarrollo de software involucrado en la implementación y despliegue de los modelos presentados en este artículo.

## Referencias

1. Kolokas, N., Vafeiadis, T., Ioannidis, D., Tzouvaras, D.: A generic fault prognostics algorithm for manufacturing industries using unsupervised machine learning classifiers. *Simulation Modelling Practice and Theory* 103, 102–109 (2020)
2. Amruthnath, N., Gupta, T.: A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance. In: 2018 5th International Conference on Industrial Engineering and Applications (ICIEA), pp. 355–361. IEEE, Singapore (2018)
3. Carvalho, T., Soares, F., Vita, R., Francisto, R. d. P., Basto, J., Alcalá, S.: A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024 (2020)
4. Carrasco, J., Lopez, D., Aguilera-Martos, I., et al.: Anomaly detection in predictive maintenance: A new evaluation framework for temporal unsupervised anomaly detection algorithms. *Neuro computing* 462, 440–452 (2021)
5. Brito, L., Susto, G., Brito, J., Duarte, M.: An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery. *Mechanical Systems and Signal Processing*, 163, 10810 (2022)
6. Susto, G., Beghi, A., McLoone, S.: Anomaly detection through on-line isolation Forest: An application to plasma etching. In: 28th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC), pp. 89–94, IEEE, USA (2017)
7. Wen, L., Yang, G., Hu, L., Yang, C., Feng, K.: A new unsupervised health index estimation method for bearings early fault detection based on Gaussian mixture model. *Engineering Applications of Artificial Intelligence*, 128, 107562 (2024)
8. Barbado, A., Corcho, Ó., Benjamins, R.: Rule extraction in unsupervised anomaly detection for model explainability: Application to OneClass SVM. *Expert Systems with Applications*, 189, 116100 (2022)
9. Shin, H., Eom, D., Kim, S.: One-class support vector machines — an application in machine fault detection and classification. *Computers & Industrial Engineering*, 48(2), 395–408 (2005)
10. Alghushairy, O., Alsini, R., Soule, T., Ma, X.: A Review of Local Outlier Factor Algorithms for Outlier Detection in Big Data Streams. *Big Data and Cognitive Computing*, 5(1), (2021)
11. Forthuis, R.: A Typology of Data Anomalies. In: *Information Processing and Management of Uncertainty in Knowledge-Based Systems. Theory and Foundations*, pp. 26–38, Springer (2018)
12. Cao, Y., Xiang, H., Zhang, H., Zhu, Y., Ming Ting, K.: Anomaly Detection Based on Isolation Mechanism: A Survey. *ArXiv* (2024)
13. Thajeel, J.K., Adel, R., Muhammed Ali, H., Shakir, R.R.: Effect of the covariance matrix type on the CPT based soil stratification utilizing the Gaussian mixture model. *Journal of the Mechanical Behavior of Materials*, 31 (2022)
14. Magdon-Ismail, M., Purnell, J.T.: Approximating the Covariance Matrix of GMMs with Low-Rank Perturbations. In: Fyfe, C., Tino, P., Charles, D., Garcia-Osorio,

- C., Yin, H. (eds) Intelligent Data Engineering and Automated Learning – IDEAL 2010. IDEAL 2010. Lecture Notes in Computer Science, Springer, Berlin (2010)
15. Kang, H., Choi, Y., Yu, J., Jun, S., Lee, J., Kim, Y.: Hyperparameter Tuning of OC-SVM for Industrial Gas Turbine Anomaly Detection. *Energies*, 15(22), (2022)
  16. Lee, G., Jung, M., Song, M., Choo, J.: Unsupervised anomaly detection of the gas turbine operation via convolutional auto-encoder. In: Proceedings of the Annual Conference of the Prognostics and Health Management Society, pp. 1–6, IEEE, USA (2020)