

Aplicación de un modelo estocástico para el Análisis RAM de Máquinas Rotatorias en la Industria 4.0

Tatiana Zambrano¹

tzambrano4419@uta.edu.ec

<https://orcid.org/0000-0002-7543-6883>

Facultad de Sistemas, Electrónica e Industrial
Universidad Técnica de Ambato
Ambato - Ecuador

Ernesto Ponsot

ernesto.pb@gmail.com

<https://orcid.org/0000-0001-5221-1799>

Facultad de Sistemas, Electrónica e Industrial
Universidad Técnica de Ambato
Ambato - Ecuador

RESUMEN

La aplicación de conceptos de la Industria 4.0 promovidas a través del mantenimiento predictivo de un activo industrial, marca la forma de la gestión operativa de una fábrica a largo plazo. El análisis de la data histórica de los activos brinda la oportunidad de aplicar técnicas como el modelamiento de datos, que definen el comportamiento de las máquinas a través del tiempo. Este paper presenta un análisis de confiabilidad, disponibilidad y mantenibilidad (RAM) de un grupo de ventiladores industriales que forman parte de un proceso de fabricación de clinker, desde una perspectiva que relaciona datos históricos de vibración con los estados que toman las máquinas, clasificados según el estándar ISO 14694. Para ello, se caracterizan series temporales por cada ventilador, y se obtienen métricas descriptivas, que habilitan la aplicación de un tipo de modelo autorregresivo integrado de media móvil, para predecir las condiciones que tomarán los equipos en los siguientes doce meses asociándolas al cálculo de los indicadores RAM, que definen la toma de decisiones en el marco operativo de la planta.

Palabras clave: *ARIMA; confiabilidad; disponibilidad; mantenibilidad; ventilador industrial.*

¹ Autor Principal

Application of a stochastic model for RAM analysis of Rotary Machines in Industry 4.0

ABSTRACT

The application of Industry 4.0 concepts promoted through predictive maintenance of an industrial asset shapes the long-term operational management of a factory. The analysis of historical asset data provides the opportunity to apply techniques such as data modeling, which define the behavior of machines over time. This paper presents an analysis of reliability, availability and maintainability (RAM) of a group of industrial fans that are part of a clinker manufacturing process, from a perspective that relates historical vibration data with the states taken by the machines classified according to the ISO 14694 standard. For this purpose, time series are characterized for each fan, and descriptive metrics are obtained, which enable the application of a type of integrated autoregressive model of moving average, to predict the conditions that the equipment will take in the next twelve months, associating them to the calculation of the RAM indicators, which define the decision making in the operational framework of the plant.

Keywords: *ARIMA; reliability; availability; maintainability; industrial fan.*

Artículo recibido 20 marzo 2023

Aceptado para publicación: 05 abril 2023

INTRODUCCIÓN

La innovación tecnológica que ha traído consigo la Industria 4.0 ha abierto nuevos horizontes dentro del mundo manufacturero que, entre muchas cosas, ha permitido explorar grandes volúmenes de datos industriales (Teoh Y. K et al. 2021). La visibilidad de la información ha facilitado el uso de la matemática de la confiabilidad la cual, al ser aplicada a problemas reales, recurrentes dentro de la cadena de valor de un proceso industrial, se convierte en una técnica de pronóstico que considera el análisis y tratamiento de datos en la detección temprana de posibles fallas en las máquinas, apoyando las intervenciones de mantenimiento y proporcionando un soporte guiado a las decisiones efectivas (Cachada A. et al. 2018).

Generar valor a través del mantenimiento inteligente de los activos industriales, garantiza la continuidad de su operación y conduce a obtener un producto de calidad, haciendo un uso eficiente de los recursos disponibles (Alves F. et al. 2020) Contar con modelos predictivos que puedan estimar la mantenibilidad y disponibilidad de un activo, y mejorar su gestión de mantenimiento y confiabilidad, son principios de la Industria 4.0, cuya base se cimienta en la digitalización de todos los componentes industriales y en el análisis inteligente del comportamiento de las máquinas (Spendla L. et al. 2017).

Por lo tanto, tomando en cuenta que la aplicación de este principio permite la mejora del rendimiento del proceso de producción y considerando que existen máquinas críticas en dichos procesos, este trabajo tiene como objetivo desarrollar un análisis inteligente de confiabilidad, disponibilidad y mantenibilidad (RAM, por las siglas en inglés de *Reliability, Availability, and Maintainability*) de un tipo de máquina rotatoria, como lo es el **ventilador industrial**.

ANALÍTICA DE DATOS EN LA INDUSTRIA 4.0

Durante las últimas décadas, la analítica de datos se ha convertido en una disciplina clave en la convergencia de las Tecnologías de la Información y la Comunicación (TICs), la Estadística y la Matemática, para explorar y extraer información de grandes volúmenes de datos, que ha desafiado la forma en la que muchas empresas solían operar (Villanustre F, 2015).

El análisis de datos es una de las fuerzas impulsoras dentro de la cuarta revolución industrial y ha desplazado los enfoques clásicos, dando paso a un análisis de datos avanzados que crea productos,

procesos de producción y servicios más inteligentes. Las áreas de aplicación incluyen análisis predictivo, análisis aumentado y análisis en tiempo real (Voigt T. et al. 2021).

La combinación de grandes volúmenes de datos y el análisis predictivo, resulta ser un generador de valor con alto potencial en la industria ya que, considerando que la falla de los activos críticos ha sido calificada como el riesgo más significativo para el rendimiento de la operación productiva, el mantenimiento predictivo se convierte en una función estratégica que, con el acceso a los datos y dentro del tejido de la Industria 4.0, mejora las capacidades de operación y allana el camino para formas de mantenimiento más eficientes y optimizadas (Bousdekis A. et al. 2020).

Existen tres indicadores clave dentro del mantenimiento de un activo industrial: confiabilidad, disponibilidad y mantenibilidad, que se convierten en las principales medidas de que dispone el mantenimiento para el análisis. Pero ¿qué técnicas son comunes para realizar el análisis? Existen varias ampliamente utilizadas en el entorno industrial, como el análisis de vibraciones, la termografía infrarroja, el análisis de aceite, las pruebas de partículas magnéticas, el análisis de circuitos, entre las más importantes. No obstante, la tendencia actual es la introducción de conceptos 4.0 aliados con prácticas básicas de mantenimiento (Reis A.S.T. et al. 2021). Es así que el modelado basado en datos se ha convertido en una técnica popular en la industria moderna, impulsado mediante el análisis de datos avanzados, *machine learning*, realidad aumentada, Internet Industrial de las Cosas (IIoT), computación en la nube, entre otras (Cachada A. et al. 2018).

ANÁLISIS RAM

Dado que la confiabilidad, junto con la disponibilidad y mantenibilidad de un activo industrial, en el entorno del mantenimiento predictivo, son indicadores clave en el proceso de producción, en los últimos años se han convertido en elementos integrales de calidad, ya que contribuyen a la reducción del tiempo de inactividad no planificado de las máquinas, por lo tanto, influyen directamente en el costo operativo de la planta (Alves F. et al. 2020). El análisis RAM es un instrumento potente para evaluar la eficiencia de un sistema y elegir una estrategia de mantenimiento efectiva, que se basa en la información histórica que generan los activos bajo condiciones generalmente de naturaleza estocástica, por lo que se pueden modelar estadísticamente (Tsarouhas P., 2019).

Para desarrollar el análisis, es necesario diferenciar los activos físicos de una planta, en reparables y no reparables, dado que en los primeros, su condición operativa se puede restaurar luego de haber fallado una o varias veces, mientras que en los segundos, sólo se puede presentar una falla, luego de la cual el equipo debe ser desechado. En este sentido, conocer los tiempos de operación y de indisponibilidad de los equipos, se convierte en información fundamental al momento de calcular los parámetros RAM de un sistema (Yañez Medina M. et al. 2004).

La **confiabilidad** $C(t)$, es un indicador que mide el tiempo que la máquina ha estado funcionando, sin considerar el tiempo indisponible por paradas programadas. Sea t el tiempo de operación del activo, t_{mnp} el tiempo empleado en mantenimiento no programado y T el tiempo total del período en consideración, entonces:

$$C(t) = \frac{t-t_{mnp}}{T} \quad (1)$$

Dicho de otra forma, la confiabilidad es la probabilidad de que un activo funcione sin fallar durante un período específico, bajo las condiciones de operación diseñadas (Komal et al. 2010).

La **disponibilidad** $D(t)$ en cambio, es el cociente entre el tiempo que la máquina ha estado disponible y el tiempo total del periodo de análisis. La diferencia con la confiabilidad es que considera el tiempo que la máquina ha estado en mantenimiento programado. Luego, sea t_{mp} el tiempo empleado en mantenimiento programado, entonces:

$$D(t) = \frac{t-t_{mp}-t_{mnp}}{T} \quad (2)$$

En términos probabilísticos, la disponibilidad es la probabilidad de que un sistema o componente esté realizando la función requerida en un momento dado o durante un período de tiempo establecido y se mantenga en operación (Komal et al. 2010).

La **mantenibilidad** $M(t)$ es la probabilidad de que un componente o sistema defectuoso pueda cambiar a una condición operativa, especificada dentro de un intervalo de tiempo en que el mantenimiento se realiza de acuerdo con procedimientos prescritos (Komal et al. 2010). Generalmente se expresa como:

$$M(t) = 1 - e^{-\frac{t}{t_{mr}}} \quad (3)$$

donde t_{mr} es el tiempo medio de reparación. Se trata de una variable clave para el cálculo del indicador y se refiere al tiempo que el activo demora en restituirse a sus condiciones en modo operativo. Es una característica exclusiva de los equipos reparables.

ESTADO DEL ARTE

Considerando que la Industria 4.0 ha creado una oportunidad para la predicción del estado de una máquina, a través del manejo de datos, cada vez existe un mayor interés en saber cómo hacer que las fábricas sean más eficientes y productivas en función de los datos recopilados. Resolver problemas de mantenimiento de equipos basados en el control de su condición, exige la investigación de técnicas y métodos que faciliten la modelación de los sistemas y la predicción de su comportamiento.

En este contexto existen varios aportes investigativos como los de Ruiz-Sarmiento et al. (2020) quienes presentan un trabajo enfocado en la evaluación de la salud de los activos de la industria del acero inoxidable. La maquinaria en estudio fueron los tambores bobinadores dentro de los molinos Steckel, componentes críticos en el proceso de laminación en caliente para la producción de láminas de acero inoxidable. El modelo aplicado para predecir la degradación de los tambores se basa en un filtro bayesiano discreto, una herramienta del campo del *machine learning*, que estima y predice la degradación gradual de dicha maquinaria, en función de la información temporal procedente de los procesos de laminación en caliente realizados en fábrica y del aporte de expertos. El resultado obtenido se compara con otros modelos de regresión comprobando así un funcionamiento mejorado del modelo propuesto.

Chen, BT et al. (2020) también presentan un análisis de confiabilidad de equipos, pero esta vez a través de *deep learning* utilizando datos de series temporales, con los objetivos de evaluar y respaldar su mantenimiento predictivo. Para ello aplican un modelo de redes neuronales profundas (DNN) gestionado por la herramienta TensorFlow y lo evalúan en un caso de estudio de un cilindro, componente importante de un carro en la línea de ensamblaje de automóviles. Al comparar con métodos de análisis

de confiabilidad tradicionales, como el análisis de componente principales (PCA) y modelos ocultos de Markov (HMM), los resultados de la predicción muestran una mejora significativa en la precisión.

Los desafíos claves para adoptar la toma de decisiones basada en datos, están en su volumen y su velocidad de producción. Estos dos son desafíos que exigen muchos recursos, que no siempre están disponibles. Ante ello, Mishra et al. (2022) presentan un método de predicción novedoso basado en eventos, en lugar de los métodos tradicionales de predicción de series temporales. El concepto central es extraer información significativa, marcada por eventos de datos de series de tiempo y usarlos para el análisis predictivo. Los eventos extraídos retienen la información requerida para dicho análisis, mientras reducen significativamente el volumen y la velocidad de producción de los datos. Para lograrlo, trabajan con datos históricos de seis años e implementan cinco modelos de aprendizaje profundo, para luego comparar predicciones clásicas de series de tiempo versus series de eventos, obteniendo como resultado la misma o mejor predicción.

Ali, MF et al. (2018) proponen un modelo integrado RAM que cuantifica los valores de los índices de confiabilidad, disponibilidad y mantenibilidad e identifica los equipos críticos que afectan el rendimiento de un sistema, adoptando un enfoque markoviano para modelar su comportamiento. Esto lo consiguen a través de un diagrama de transición para el modelo propuesto y formulando ecuaciones diferenciales para obtener las probabilidades de los estados. Los autores analizan la disponibilidad del sistema en estado estacionario, mientras que la confiabilidad y mantenibilidad son analizadas en estado transitorio. Los datos que se utilizan se obtienen de la *Oil and Gas Egyptian Company* y los resultados que se alcanzan permiten discutir el efecto de las tasas de falla y reparación en diferentes momentos. Concluyen que el modelo markoviano es una buena alternativa para la evaluación del desempeño de sistemas industriales.

Tsarouhas (2019), también presenta un artículo para calcular los índices RAM, con el objetivo de medir y mejorar el rendimiento de una línea de producción de *croissants* automatizada. Esto se lleva a cabo mediante el análisis de datos de fallas y reparaciones de la maquinaria, basado en técnicas estadísticas descriptivas y pruebas de correlación serial y de tendencia, las cuales validan el supuesto de independencia. Sus principales hallazgos son la obtención de un patrón de falla y la estimación de las características de confiabilidad y mantenibilidad en forma precisa y en términos cuantitativos. Con base

en este estudio, el autor demuestra cómo el análisis RAM es muy útil para decidir intervalos de mantenimiento y planificar una estrategia adecuada.

Saini et al. (2022) realizan una estimación de parámetros y un análisis de confiabilidad y mantenibilidad de una planta de producción de azúcar. La planta consta de cinco subsistemas dispuestos en serie, cada uno con una tasa de falla distinta. Se aplican diferentes propiedades estadísticas como la media, la mediana, la desviación estándar, la asimetría y la curtosis para identificar la distribución más adecuada para las fallas y tiempos de reparaciones, trabajando con datos tomados durante seis meses. La distribución y los parámetros que mejor se ajustan se determinan junto con la tendencia y el análisis de correlación en serie, para lograr el mejor rendimiento de la planta. Los modelos sugeridos pueden ser, según los autores, una herramienta adecuada para el pronóstico y la aplicación de una política de mantenimiento eficaz.

En el año 2021, Jagtap et al. presentan un análisis RAM para evaluar el desempeño de un sistema de circulación de agua (WCS) utilizado en una planta de energía a carbón. El rendimiento del WCS se evalúa utilizando un diagrama de bloques de confiabilidad (RBD), un análisis de árbol de fallas (FTA) y un enfoque probabilístico de nacimiento y muerte de Markov. El diagrama de transición del modelo propuesto representa varios estados con plena capacidad de trabajo, capacidad reducida y estado fallido. La clasificación de los equipos críticos se decide sobre la base de su nivel de criticidad. Los resultados del estudio revelan cuál es el equipo que afecta con mayor y menor porcentaje la disponibilidad del sistema y a partir de allí se recomienda una estrategia de mantenimiento modificada, basada en parámetros de disponibilidad optimizada, que mejora esta característica del sistema en la planta.

Para aplicar una nueva estrategia de detección y clasificación de fallas, ahora en sistemas mecánicos, Gonçalves et al. (2021) proponen un método basado en el análisis de matrices de covarianza de una muestra, estimada a partir de datos de vibración extraídos de los propios sistemas mecánicos. Además, utilizan la teoría estocástica, para derivar parámetros de Markov de las mismas matrices de covarianza que sirven como características en algoritmos de clasificación basados en optimización convexa, donde destacan las ventajas relacionadas con el uso de los parámetros de Markov para diagnosticar fallas por cavitación incipiente en una red de abastecimiento de agua.

Los procesos de Markov pueden tener un trato particular para realizar un análisis de confiabilidad. Así, Barbu et al. (2019) los llaman procesos de Markov a la deriva. Este tipo de procesos considera una no homogeneidad que sea suave de forma conocida, es decir, supone que la matriz de transición de Markov es una función lineal de dos (o más) matrices de transición de Markov. Para esta clase de sistemas, primero se obtienen expresiones explícitas para indicadores de confiabilidad de modelos de Markov a la deriva, como confiabilidad, disponibilidad, mantenibilidad y tasas de falla. Luego, bajo diferentes escenarios estadísticos, se estiman los parámetros del modelo, obteniendo estimadores complementarios de los indicadores de confiabilidad asociados y se investiga la consistencia de los estimadores. La calidad de los estimadores propuestos y la validación del modelo se ilustra a través de experimentos numéricos.

También han sido desarrolladas revisiones de literatura en torno al tema, como las que realizan Quezada et al. (2018). Los autores indican que los dos modelos de procesos estocásticos más comunes en la literatura y aplicaciones son los procesos Gamma y de Wiener, sin embargo, en su trabajo también muestran sus limitaciones, por lo que presentan el proceso inverso Gaussiano como una opción muy atractiva para los datos de degradación de un activo. Por otra parte, Achouch et al. (2022) presentan una revisión exhaustiva de la literatura sobre métodos y herramientas aplicadas para modelos de mantenimiento predictivo inteligente en la Industria 4.0, mediante la identificación y categorización del ciclo de vida de los proyectos de mantenimiento y los desafíos encontrados. Los autores presentan modelos asociados a este tipo de mantenimiento, tales como: mantenimiento basado en condición (CBM), pronósticos y gestión de la salud (PHM) y vida útil remanente (RUL). Además, presentan un flujo de trabajo industrial novedoso de mantenimiento predictivo, que incluye la fase de apoyo a la decisión en la que se muestra una recomendación para una plataforma de mantenimiento.

Jimenez et al. (2020) exponen una revisión desde diferentes enfoques y técnicas de mantenimiento, resaltando que a un mantenimiento predictivo inteligente se lo controla tan solo con tres fases: adquisición de datos, procesamiento y toma de decisiones. Esta última, dividida en dos etapas: diagnóstico y pronóstico. Los algoritmos más utilizados según los autores para el diagnóstico de fallas son la regresión lineal, el bosque aleatorio, los modelos de Markov, los modelos de redes neuronales artificiales y los vectores de soporte regresor (SVR), mientras que para la prognosis existen de dos tipos:

predecir la vida útil remanente (RUL) y la probabilidad que tiene un activo de seguir funcionando, que se la puede conocer a través de modelos ARMA, ARIMA y SVR. En este estudio se desarrolla una aplicación de toma de decisiones para proporcionar un análisis visual de la RUL de una herramienta de mecanizado y se revisan conceptualmente los modelos planteados.

En el mismo ámbito, Topic et al. (2016) desarrollan un modelo mejorado para el cálculo de índices de confiabilidad para diferentes conceptos de configuración de plantas de energía eólica, utilizados en las últimas dos décadas. Se trata del modelo de promedio móvil autorregresivo (ARMA) combinado con la simulación secuencial de Monte Carlo, para predecir con mayor precisión durante la falla, la energía esperada no servida (EENS). Utilizan una base de datos estadística de *LWK - Land Wirtschafts Kammer* para determinar la confiabilidad de los componentes de las diferentes plantas de energía eólica en las configuraciones que fueron objeto de estudio y finalmente discuten la influencia de las fallas de los componentes especialmente mecánicos y eléctricos en EENS.

Los modelos de predicción también alcanzan a los procesos de decisiones de gestión de calidad, como es el caso de las soldaduras de tuberías industriales de una empresa en Edmonton - Canadá, según lo menciona Ji, Wenying (2018). En este trabajo el objetivo fue mejorar los procesos de soporte de decisiones de gestión de calidad, desde un nivel de gestión operativa, mediante la introducción de un análisis impulsado cuantitativamente, que permite que los modelos de simulación se ajusten mediante datos y mediciones en tiempo real. Se basa en estadísticas bayesianas para recalibrar y realinear modelos con datos en tiempo real, que son generados por sistemas de control de calidad reales. También se desarrollan métricas analíticas descriptivas y predictivas, para conocer el desempeño de la calidad del operador y pronósticos del desempeño de la calidad del proyecto, respaldando y mejorando los procesos de toma de decisiones.

En el marco de las políticas CBM tradicionales en las que se realiza un seguimiento secuencial o periódico del activo, Naderkhani et al. (2017) proponen una nueva estrategia de muestreo basada en dos intervalos. El primero cuando el activo se encuentra en un estado saludable y el siguiente, con mayor frecuencia, cuando se deteriora y entra en estado no saludable. El modelo propuesto está formulado bajo los lineamientos del proceso de decisión semi-Markoviano (SMDP) el cual permite desarrollar un

algoritmo computacional para obtener, tanto los umbrales de control, como los intervalos de muestreo, minimizando el costo computacional promedio esperado a largo plazo por unidad de tiempo.

CASO DE ESTUDIO

Considerando las investigaciones presentadas en la sección anterior, este trabajo analiza la confiabilidad, disponibilidad y mantenibilidad de un activo industrial, que está presente en casi todo tipo de procesos productivos: **el ventilador industrial**. Se trata de una máquina rotatoria que lleva a cabo diferentes funciones, que van desde sopladores de aire y gases, hasta extractores de polvo. Este trabajo considera para el análisis un grupo de ocho ventiladores, que forman parte de un proceso de producción de *clinker* (componente clave en la elaboración del cemento), en su etapa de enfriamiento. En dicha etapa se encuentra el sistema de aireación, que concentra la mayor cantidad de ventiladores del proceso (ver **Figura 1**).

Figura 1.

Enfriador de clinker – Planta cementera



Los ventiladores que conforman el sistema de aireación del enfriador de *clinker*, actúan como sopladores que transmiten energía para generar la presión necesaria, con la que se mantiene un flujo continuo de aire para enfriarlo, pero además, generan aire caliente secundario que ayuda a la combustión de un horno rotatorio. La **Tabla 1** indica los valores de flujo volumétrico y presión estática con los cuales debe operar cada uno de los ocho ventiladores que conforman el sistema de aireación del enfriador.

Tabla 1.

Valores de flujo volumétrico y presión estática de los ventiladores

Ventilador	Flujo volumétrico (m³/h)	Presión estática (Pa)
FN1	34000	10000
FN2	17000	10000
FN3	57000	10000
FN4	48000	9500
FN5	45000	8500
FN6	43000	8000
FN7	40000	7500
FN8	38000	7000

La predicción de fallas en los ventiladores representa la premisa del mantenimiento predictivo en el enfriador de *clinker* (Manco G. et al. 2017). Aplicar técnicas de predicción capaces de detectar fallas a partir de datos históricos y describirlos en términos de condición de FNs, que lo distinguen de su comportamiento normal, es lo que a continuación se desarrolla aplicando la metodología que sugiere Jiménez et al. (2020) para realizar un análisis predictivo inteligente de un activo industrial.

Adquisición de datos

Es la etapa más importante, ya que de la veracidad de éstos depende la calidad de los resultados que permiten realizar la predicción (Jagtap H.P. et al. 2020). Los datos utilizados corresponden al diagnóstico de los ventiladores, registrado mensualmente durante cuatro años a partir del 2018. En total se cuenta con un conjunto de 1248 datos para el análisis.

Se trata de medidas de velocidad de vibración (mm/s) tomadas en las direcciones horizontal, vertical y axial en puntos específicos de la máquina, cuya clasificación de estados se basa en el estándar ISO 14694. Dicho estándar establece los límites permisibles de vibraciones que permiten determinar la condición de las máquinas, tomando en cuenta el valor pico máximo de entre las tres direcciones medidas. Se establecen cuatro condiciones o estados para los ventiladores, guardando concordancia con el rango (mm/s) sugerido por la norma. Éstos son: *Estable, Aceptable, Tolerable y Crítico* (ver **Tabla 2**).

Tabla 2.

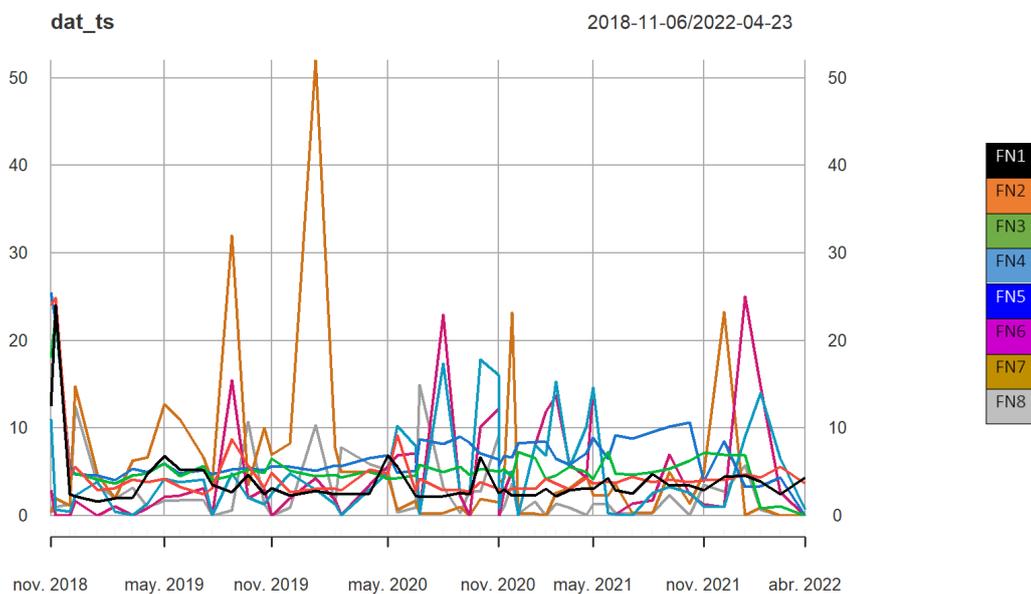
ISO 14694. Estados y rangos de valores

Identificador	Condición de FNs.	Rango (mm/s)
E	Estable	0.001-1.990
A	Aceptable	2.000-5.990
T	Tolerable	6.000-14.990
C	Crítico	15.000-90.000

Procesamiento de datos

Entendiendo al procesamiento como la acumulación y tratamiento de los datos que describen la condición de los FNs para generar información de valor (Mishra S. et al. 2022) en esta sección se describe la historia que hay detrás del comportamiento de cada uno de los ocho ventiladores. Para ello, se construyen sendas series temporales, cuyos datos corresponden a los valores pico máximos de todas las medidas de velocidad de vibración (mm/s) ya que son las que definen, según la norma, la condición de las máquinas (**ver Figura 2**). Sin duda, el estado que toma cada uno de los ventiladores industriales a lo largo del tiempo es de naturaleza estocástica, dado que está sujeto a la imprevisibilidad de eventos, originados por modos de operación, de falla, condiciones de fábrica, frecuencia de mantenimiento, entre otras.

Figura 2. *Series de tiempo de vibraciones máximas - FNs*



Como se puede observar en la **Figura 2** el comportamiento de los FNs es variable y carece de tendencia. Como en todo proceso de análisis de datos, es necesario obtener algunas estadísticas iniciales, que permitan avizorar un panorama más claro, sobre el cual se puedan examinar las series de tiempo y aplicar los modelos adecuados para realizar la predicción.

La **Tabla 3** muestra algunas de las métricas descriptivas. En ellas se observa principalmente, que entre series de vibración máxima para los ventiladores, ni el promedio ni la varianza son constantes y todos presentan una dispersión apreciable, considerablemente mayor en los FN5, FN6 y FN7.

Tabla 3.

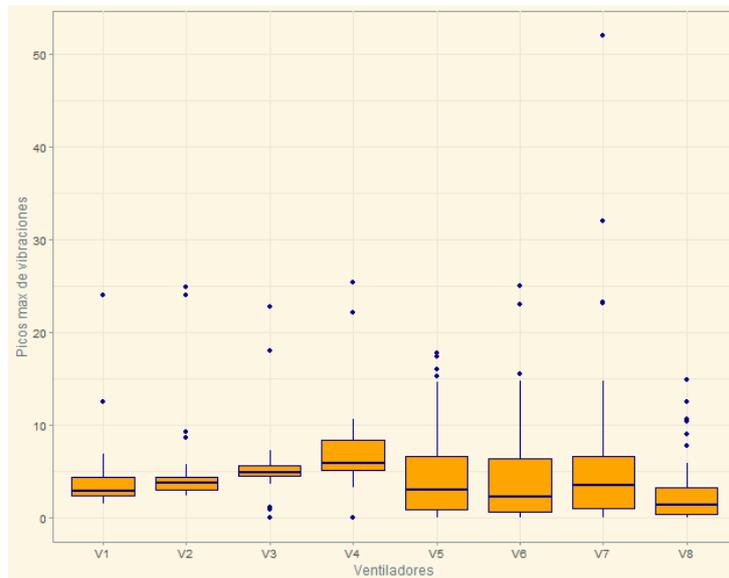
Estadísticas descriptivas de los valores de pico máximos de medidas de velocidad de vibración por ventilador

Ventilador	Media	Mediana	Desv. Est.	Varianza
FN1	3.90	2.92	3.37	11.39
FN2	4.75	3.82	4.19	17.53
FN3	5.51	4.92	3.35	11.24
FN4	7.00	5.92	3.95	15.60
FN5	4.77	3.01	4.98	24.77
FN6	4.59	2.31	5.87	34.40
FN7	5.79	3.33	9.13	83.44
FN8	2.63	1.34	3.44	11.81

En el mismo contexto, pero realizando comparaciones gráficas, mediante diagramas de caja, de los datos de cada uno de los ventiladores, se observa que sólo tres (FN5, FN6 y FN7), guardan similitud en sus rangos numéricos de pico máximo de vibración. Los restantes (FN1, FN2, FN3, FN4 y FN8), muestran diferencias tanto entre sí, como con los primeros, en cuanto a su dispersión (mucho menor en estos últimos) como en sus medianas de vibración. Además, los datos están más separados en la parte superior de la mediana, excepto en el FN2, donde sucede lo contrario, indicando distribuciones asimétricas. Destacan también los valores atípicos que están presentes en todos los ventiladores. Al proyectar hacia el eje de las ordenadas las cajas, todas ellas se interceptan, indicando que no se puede tener certeza de que los comportamientos sean en realidad, muy diferentes (**ver Figura 3**).

Figura 3.

Diagrama de caja de los FNs



Luego de la evaluación de la condición de los ventiladores, a través de las métricas descriptivas, se caracterizan sus series temporales para explorar sus propiedades. En primer término, se ha aplicado la prueba de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) que contrasta la estacionariedad de las series, característica principal de éstas (**ver Tabla 4**). En esta prueba, la hipótesis nula afirma que la serie es estacionaria (Hyndman R.J. et al. 2021).

Tabla 4.

Estacionariedad de las series utilizando KPSS. Nivel de significación $\alpha=0.05$

Ventilador	Kpss_stat	kpss_pvalue	Estacionaria
FN1	0.336	0.100	SI
FN2	0.369	0.091	SI
FN3	0.314	0.100	SI
FN4	0.126	0.100	SI
FN5	0.280	0.100	SI
FN6	0.452	0.055	SI
FN7	0.314	0.100	SI
FN8	0.378	0.087	SI

Los *kpss pvalue* sugieren que no es necesario diferenciar las series y se las acepte como estacionarias, considerando un nivel de significación $\alpha=0.05$.

Ya que se trata de series temporales univariantes de naturaleza estocástica, es importante conocer qué tan relacionados están los valores pasados y actuales de las series, es decir, si la variable condición de los FNs puede ser explicada por los datos de ella misma en períodos anteriores y si se pueden expresar sus valores pasados como una combinación lineal, para poder obtener predicciones.

Se aplica entonces, la Función de Autocorrelación (ACF) y la Función de Autocorrelación Parcial (PACF), que para un proceso estocástico $Y_{(t)}$ miden respectivamente, la correlación existente entre las variables $Y_{(t)}$ y $Y_{(t-k)}$, y la correlación entre las variables $Y_{(t)}$ y $Y_{(t-k)}$, pero eliminando el efecto de las variables intermedias $Y_{(t-1)}, Y_{(t-2)}, \dots, Y_{(t-k-1)}$. Así, estas características son ilustradas en las figuras desde la **Figura 4** a la **Figura 11** y serán posteriormente tomadas en cuenta en los métodos de pronóstico que se utilizarán. De forma preliminar observamos:

- En todas las figuras se nota de sus ACFs el decaimiento inmediato de las autocorrelaciones, señal clara de que las series son estacionarias y no necesitarán diferenciación.
- En las **Figuras 5, 6, 7** notamos que el segundo término de la PACF tiene una magnitud considerable al comparársele con las demás autocorrelaciones, señal de que puede ser necesario incorporar un término autorregresivo al modelo que se proponga.
- En las figuras restantes no se notan mayores diferencias en los patrones de comportamiento de las autocorrelaciones más allá de una autocorrelación. Esto indica que como máximo puede ser necesario un término de media móvil y/o uno autorregresivo.
-

Figura 4. FNI - ACF, PACF

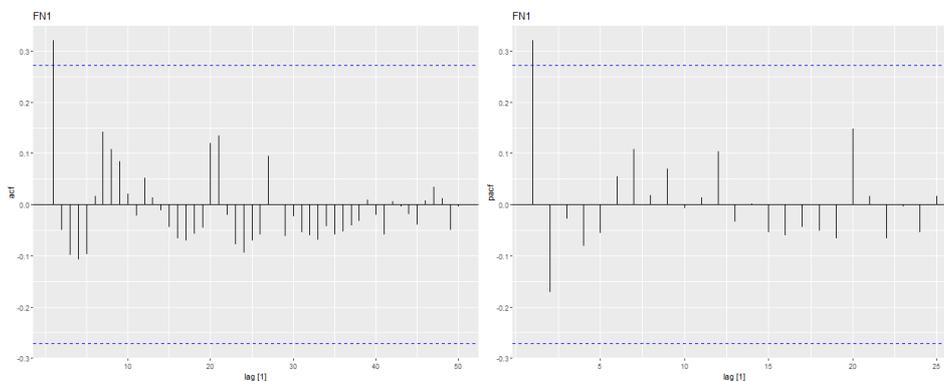


Figura 5. FN2 - ACF, PACF

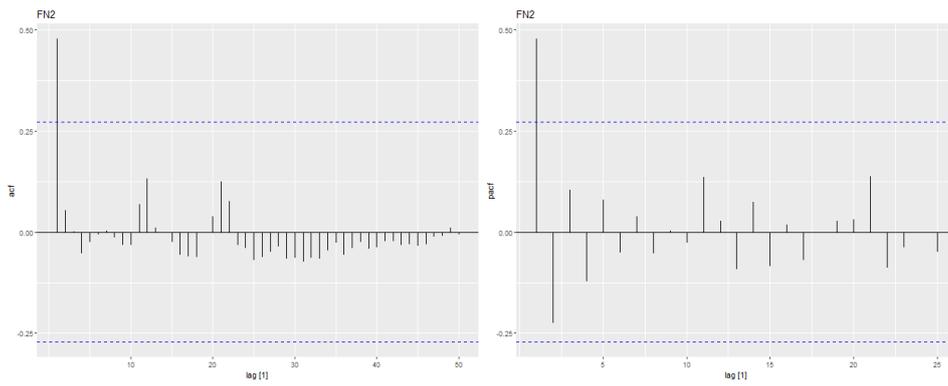


Figura 6. FN3 - ACF, PACF

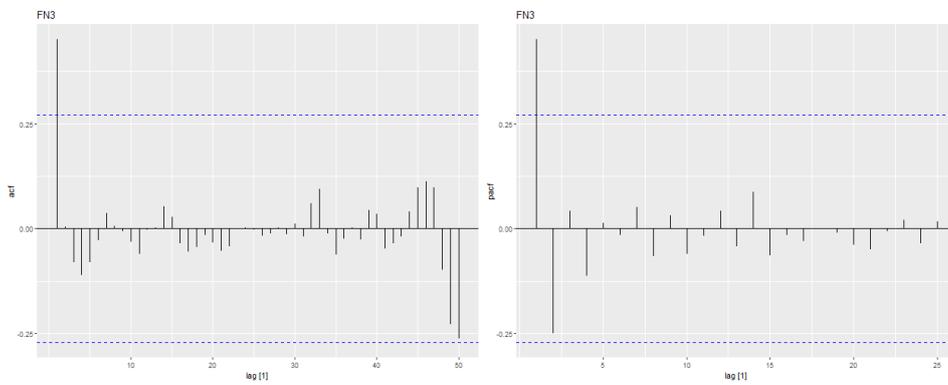


Figura 7. FN4 - ACF, PACF

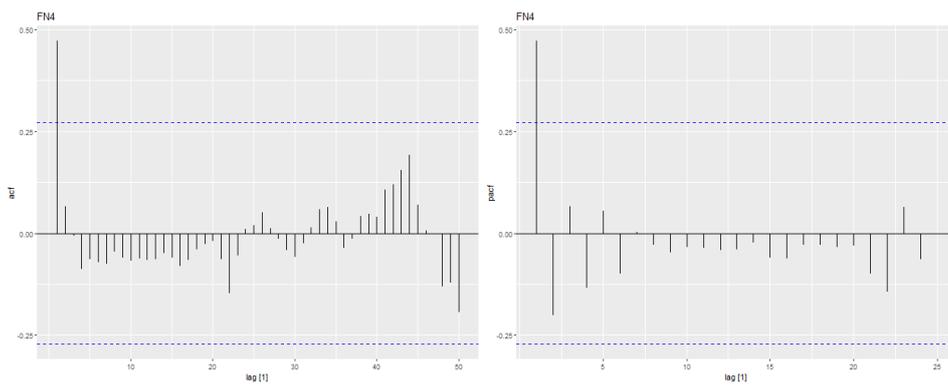


Figura 8. *FN5 - ACF, PACF*

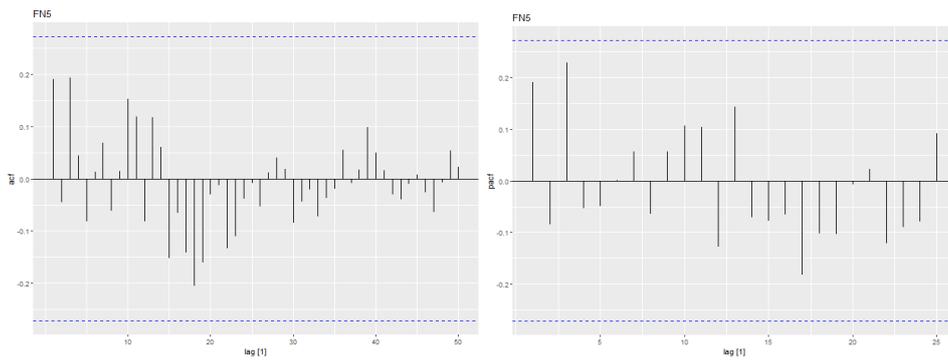


Figura 9. *FN6 - ACF, PACF*

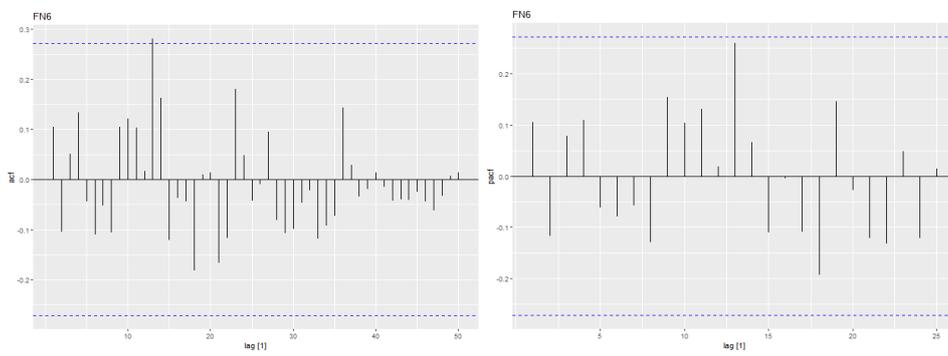


Figura 10. *FN7 - ACF, PACF*

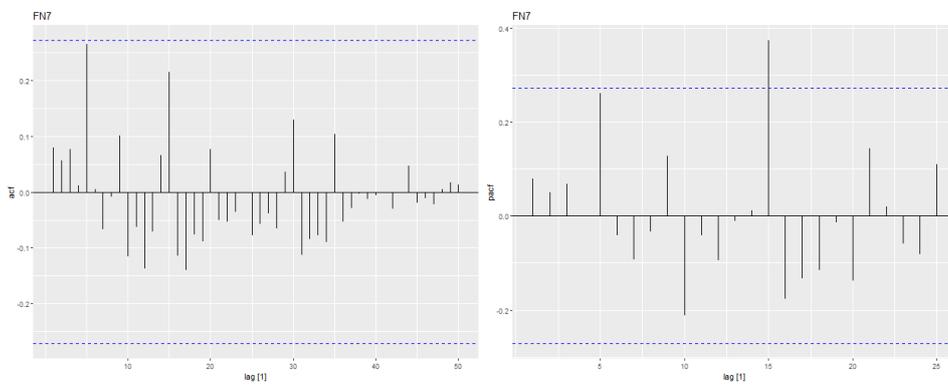
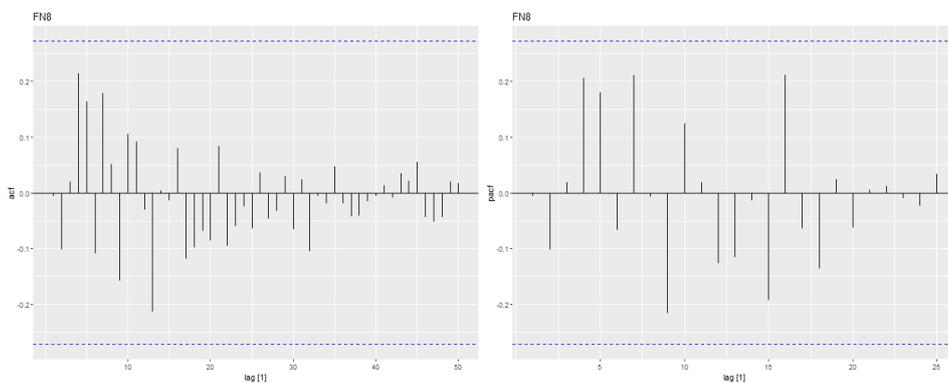


Figura 11. *FN8 - ACF, PACF*



Toma de decisiones

Este es el último paso en la decisión de mantenimiento, y se puede dividir en dos categorías principales:

- Diagnóstico
- Pronóstico

El diagnóstico se centra en la detección e identificación de fallas cuando ocurren, mientras que el pronóstico pretende predecir dichas fallas antes de que sucedan. Ambos, se complementan entre sí, ya que el primero es el insumo de información que necesita el segundo para desarrollarse (Jiménez - Cortadi et al. 2020).

Como los datos están clasificados, de acuerdo con el estándar ISO 14694, según sus medidas de vibración en mm/s, los indicadores de mantenimiento se asocian con dicho estándar y se diagnostica el estado de los FNs para escalar a la etapa de pronóstico (ver **Tabla 5**).

Tabla 5. Indicadores RAM y campos ISO14694

Indicadores	Campos ISO 14694
Disponibilidad	Máquina nueva o reacondicionada
Confiabilidad	Máquina puede operar indefinidamente
Mantenibilidad	Máquina no puede operar un tiempo prolongado
Mantenibilidad	Vibración está provocando daños

Un enfoque sólido para el pronóstico de series de tiempo lo proporciona el modelo autorregresivo integrado de media móvil, ARIMA (p,d,q) , por sus siglas en inglés (Stavropoulos Ch.N. et al, 2000). Este modelo utiliza la información de los términos autorregresivos p , de medias móviles q y de diferenciación d , sugeridos por las funciones ACF y PACF, ajustando los parámetros como combinaciones lineales de las observaciones pasadas, para producir los pronósticos (Dindarloo S., 2015).

RESULTADOS Y DISCUSIÓN

Obtener valores válidos que puedan ser considerados en una predicción, a corto o mediano plazo, sobre la condición que tomen los ventiladores estudiados, sin duda aporta en el sentido de las ideas de la Industria 4.0. Considerar una predicción científica del estado de salud de las máquinas y los posibles

modos de falla futuros, como una forma de mantenimiento proactiva, puede eliminar o mitigar su impacto en la organización (Bousdekis A. et al. 2019).

Pero, no se trata tan solo de obtener valores predichos, sino de analizarlos en relación con los indicadores principales de mantenimiento, que son los que serán útiles para la selección de políticas y estrategias que mejoren la productividad de la planta (Alya M. F. et al. 2018).

El mantenimiento predictivo ha cambiado de manera radical las operaciones comunes de mantenimiento al predecir las fallas. Se ha convertido en la columna vertebral de la operación de la planta, y es que, en torno al concepto de “falla” se desarrolla todo el estudio probabilístico que determina el efecto que se produce, cuando la máquina deja de cumplir con su propósito (Yañez Medina M. et al. 2004).

Comparación estadística de ventiladores

En primera instancia, se despliegan histogramas de la vibración máxima para cada ventilador (**ver Figuras 12 a 15**). La distribución de los datos muestra que los cuatro primeros se acercan a una distribución de Bernoulli, en la que son considerablemente más frecuentes las vibraciones bajas que las altas. Los cuatro siguientes, se acercan gráficamente a una distribución exponencial, lo cual induce a creer que en estos ventiladores existen más cambios de estado respecto a los anteriores.

Figura 12. Histograma FN1 – FN2

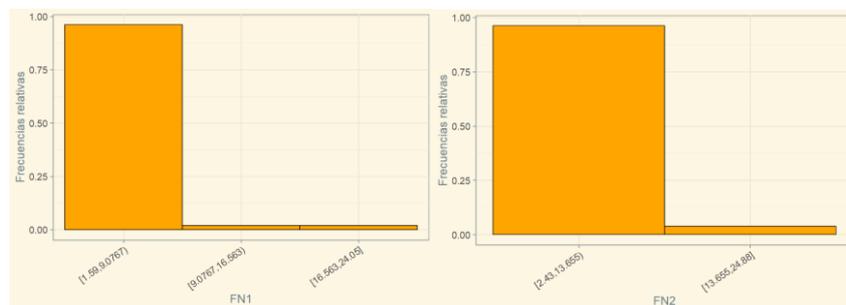


Figura 13. Histograma FN3 – FN4

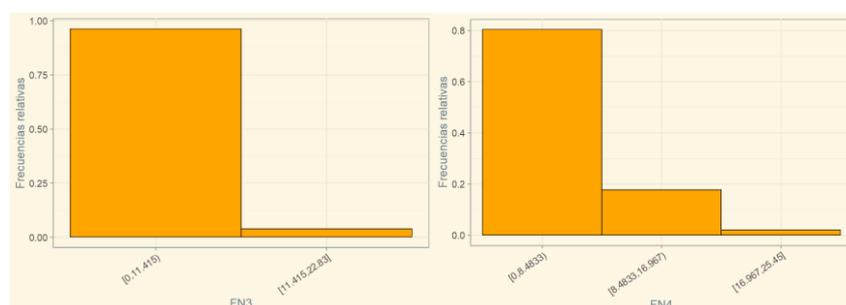


Figura 14. Histograma FN5 – FN6

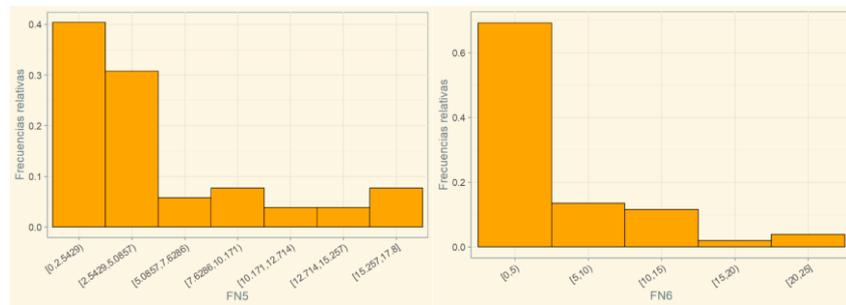
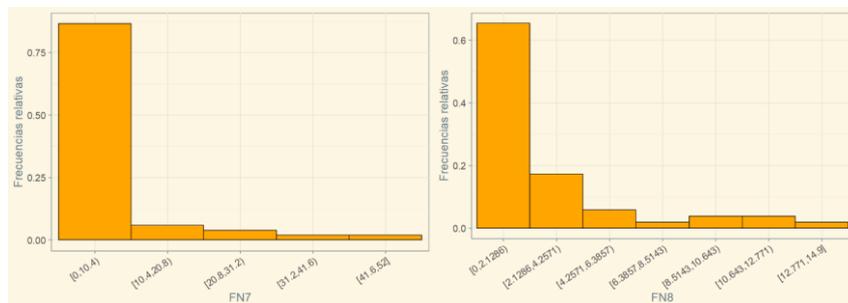


Figura 15. Histograma FN7 – FN8



Por otro lado, para examinar si existen diferencias importantes entre los valores máximos (promedios) de vibración de los ventiladores, se aplica la prueba de hipótesis para la diferencia de medias entre pares de ventiladores, basada en la distribución *t-Student* y considerando un nivel de significación $\alpha=0.05$. La **Tabla 6** contiene los resultados. En esta prueba, la hipótesis nula (H_0) y la hipótesis alternativa (H_a) son las siguientes:

- H_0 : Las medias de las vibraciones máximas son diferentes dependiendo del ventilador.
- H_a : Las medias de las vibraciones máximas no son diferentes entre los ventiladores

Como cabría esperar luego de un análisis cuidadoso de la **Figura 3**, las pruebas de hipótesis sobre las diferencias de medias de vibraciones máximas, contenidas en la **Tabla 6**, sugieren que:

- La vibración máxima promedio de FN1 es diferente a las de FN3 y FN4, pero no se encuentra evidencia suficiente en la muestra para afirmar que sea diferente a las vibraciones máximas promedio de FN2, FN5, FN6, FN7 y FN8.
- La de FN2 es diferente a las de FN4 y FN8, pero no se encuentra evidencia para afirmar que sea diferente a las de FN3, FN5, FN6 y FN7.
- La de FN3 es diferente a las de FN4 y FN8, pero no se encuentra evidencia para afirmar que sea

diferente a las de FN5, FN6 y FN7.

- La de FN4 es diferente a las de FN5, FN6 y FN8, pero no se encuentra evidencia para afirmar que sea diferente a la de FN7.
- La de FN5 es diferente a la de FN8, pero no se encuentra evidencia para afirmar que sea diferente a las de FN6 y FN7.
- La de FN6 es diferente a la de FN8, pero no se encuentra evidencia para afirmar que sea diferente a la de FN7.
- Por último, la de FN7 es diferente a la de FN8.

Tabla 6. Resultado de la prueba *t* de igualdad de medias

Test	<i>t</i>	p-valor	Ho
t.test(FN1, FN2)	-1.1365	0.2585	no se rechaza
t.test(FN1, FN3)	-2.4357	0.0166	se rechaza
t.test(FN1, FN4)	-4.3038	3.933e-05	se rechaza
t.test(FN1, FN5)	-1.0461	0.2983	no se rechaza
t.test(FN1, FN6)	-0.8238	0.4125	no se rechaza
t.test(FN1, FN7)	-1.5286	0.1315	no se rechaza
t.test(FN1, FN8)	1.7206	0.0884	no se rechaza
t.test(FN2, FN3)	-1.0207	0.3099	no se rechaza
t.test(FN2, FN4)	-2.8225	0.0057	se rechaza
t.test(FN2, FN5)	0.0275	0.9781	no se rechaza
t.test(FN2, FN6)	0.0659	0.9475	no se rechaza
t.test(FN2, FN7)	-0.8912	0.3759	no se rechaza
t.test(FN2, FN8)	2.6501	0.0093	se rechaza
t.test(FN3, FN4)	-2.0789	0.0402	se rechaza
t.test(FN3, FN5)	0.8824	0.3799	no se rechaza
t.test(FN3, FN6)	0.8724	0.3856	no se rechaza
t.test(FN3, FN7)	-0.3715	0.7115	no se rechaza
t.test(FN3, FN8)	4.1049	8.299e-05	se rechaza
t.test(FN4, FN5)	2.5286	0.0130	se rechaza
t.test(FN4, FN6)	2.3432	0.0213	se rechaza
t.test(FN4, FN7)	0.6901	0.4925	no se rechaza
t.test(FN4, FN8)	5.8056	7.73e-08	se rechaza
t.test(FN5, FN6)	0.0849	0.9325	no se rechaza
t.test(FN5, FN7)	-0.8456	0.4005	no se rechaza
t.test(FN5, FN8)	2.4078	0.0180	se rechaza
t.test(FN6, FN7)	-0.8679	0.3879	no se rechaza
t.test(FN6, FN8)	2.0298	0.0456	se rechaza
t.test(FN7, FN8)	2.3555	0.0216	se rechaza

Este resultado no es de extrañar, dadas las características disímiles de los ventiladores y el hecho de que han sido sometidos a distintas cargas de operación.

Modelos de series temporales de ventiladores

En este trabajo, los modelos ARIMA propuestos se implementan utilizando R studio 4.1.3 (R Core Team, 2022), específicamente la función **autoarima** que, luego de ajustar varios modelos candidatos, se decide por aquel que produzca el menor Criterio de Información de Akaike (AIC).

Se llevan a cabo corridas de varios programas para implementar el enfoque propuesto, en la predicción de las condiciones que tomarían los ventiladores industriales, en términos de indicadores de mantenimiento, para los próximos 12 meses. Las **Tablas 7 y 8** muestran un resumen de la aplicación del modelo encontrado para cada una de las series.

Tabla 7. Resumen del modelo ARIMA para cada serie

Ventilador	ARIMA	Coef.	Interc.	Error Coef.	Error Interc.
FN1	(0,0,1)	0.3677	3.9137	0.1309	0.5902
FN2	(1,0,0)	0.7841	1.2661	0.1272	0.4486
FN3	(1,0,0)	0.6508	2.0056	0.1356	0.3740
FN4	(1,0,0)	0.8571	1.1536	0.1159	0.3861
FN5	(0,0,1)	0.2793	4.7887	0.1722	0.8483
FN6	(0,0,0)	-	4.5908	-	0.8056
FN7	(0,0,0)	-	5.7904	-	1.2545
FN8	(0,0,0)	-	2.6290	-	0.4720

Ventilador	ARIMA	AIC	BIC	σ^2	Ljung-Box
FN1	(0,0,1)	272.28	278.13	10.17	0.944
FN2	(1,0,0)	276.42	282.28	10.43	0.205
FN3	(1,0,0)	260.12	265.98	7.68	0.610
FN4	(1,0,0)	266.98	272.83	8.63	0.425
FN5	(0,0,1)	316.81	322.66	23.37	0.910
FN6	(0,0,0)	334.55	338.45	14.11	0.283
FN7	(0,0,0)	380.61	384.51	81.83	0.557
FN8	(0,0,0)	278.94	282.85	11.58	0.962

Con respecto al modelado de las series temporales, en las figuras desde la **Figura 4** a la **Figura 11**, se aprecia que las ACFs de los FNs se parecen al de una serie de ruido blanco. Sólo una autocorrelación está fuera de los límites del 95% de confianza, indicando que las series tienen una media y varianza constantes, por lo que pueden suponerse estacionarias.

Los modelos ARIMA encontrados se ajustan bien a los datos, según lo sugiere el estadístico de Ljung-Box (**ver Tabla 8**). Este estadístico produce *p-valores* mayores al nivel de significación $\alpha=0.05$, en todos los casos. La prueba calcula los residuos del modelo y verifica si pueden ser considerados ruido blanco, cual es uno de los supuestos originales.

FN6, FN7, FN8 son ajustados con un modelo sin parámetros, ni autorregresivos ni de media móvil, lo que sugiere que sus datos no aportan información útil para el pronóstico (se les puede considerar ruido blanco, en sí mismos). La función ARIMA FIT aplicada a dichas series, no encontró ningún coeficiente AR o MA que mejore el modelo en los mencionados FNs.

Este resultado puede deberse a que los datos registrados de estos FNs corresponden a ventiladores que, a lo largo del tiempo, no se utilizaron continuamente, ya que su funcionamiento dependía de si se necesitaba o no compensar la presión estática de los FNs principales. Esto lleva a pensar, que sus registros contienen información un tanto errática, ya que no actuaban bajo las mismas condiciones que el resto.

La predicción de la condición de los FNs se realiza para los siguientes 12 meses, considerando cada uno de los valores obtenidos como picos en mm/s que se asocian a la clasificación dada por la ISO 14694. Además, como ya se indicó en el párrafo que antecede, los datos históricos de los ventiladores FN6, FN7 y FN8 no aportan información que permita realizar una predicción. Las **Figuras de la 16 a la 20** contienen los pronósticos de los modelos para los ventiladores 1 al 5.

Figura 16. *Pronósticos para FNI*

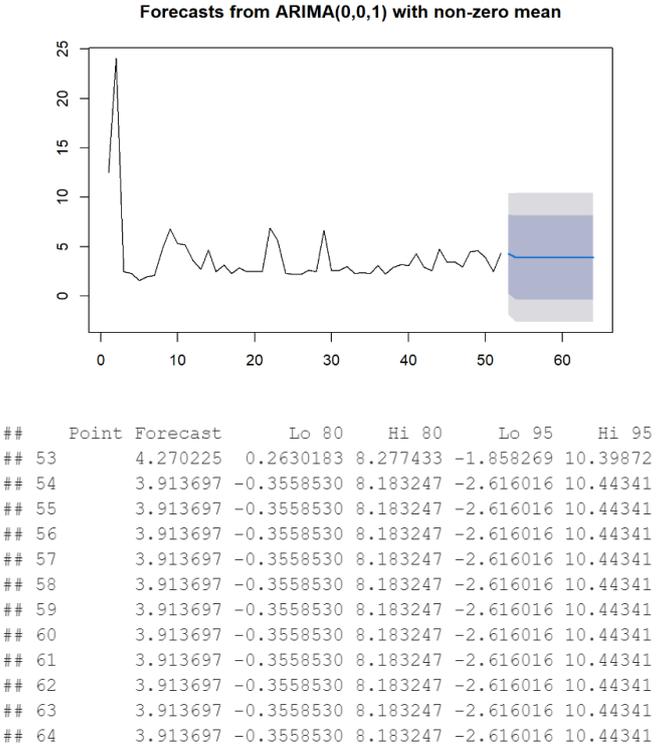


Figura 17. Pronósticos para FN2

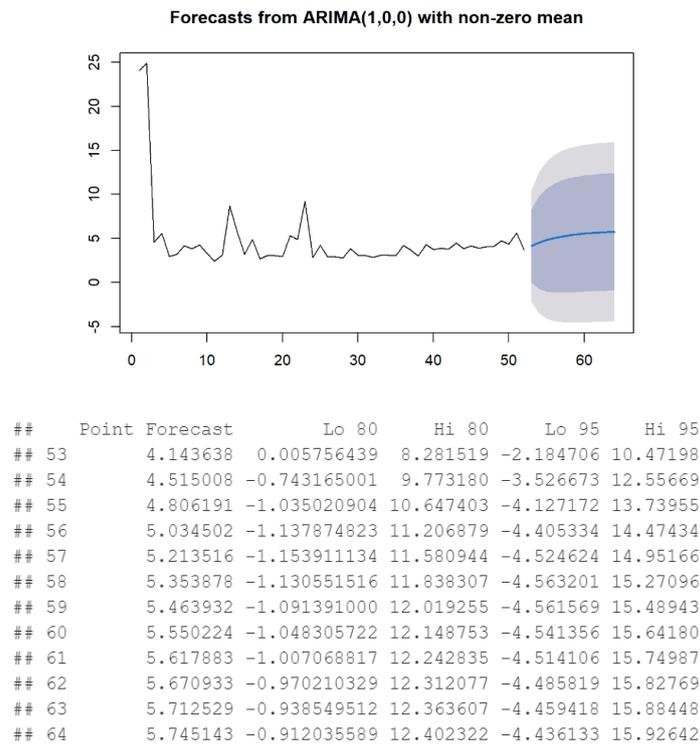


Figura 18. Pronósticos para FN3

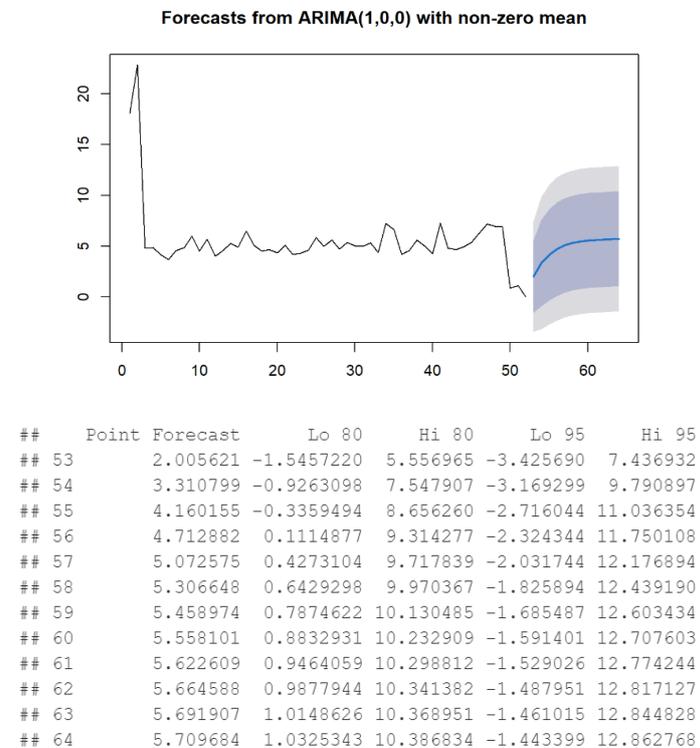


Figura 19. Pronósticos para FN4

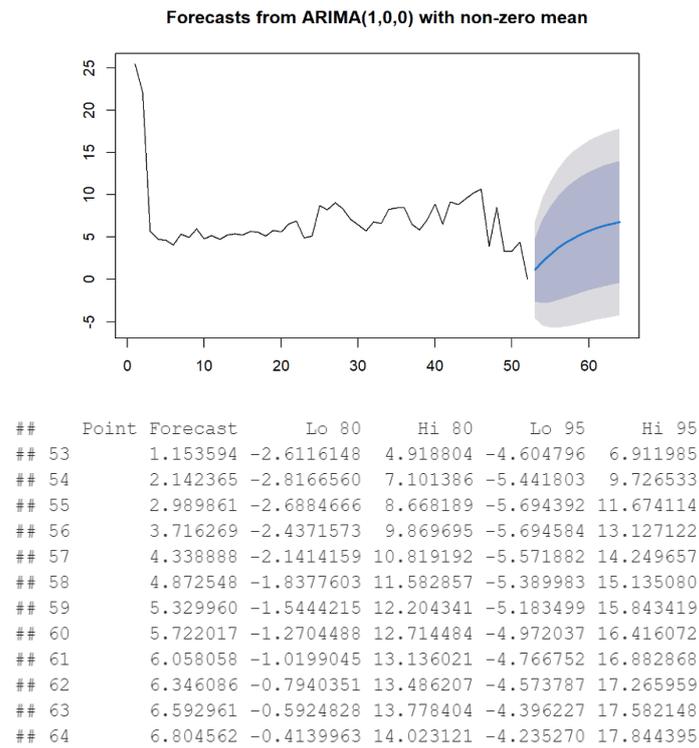
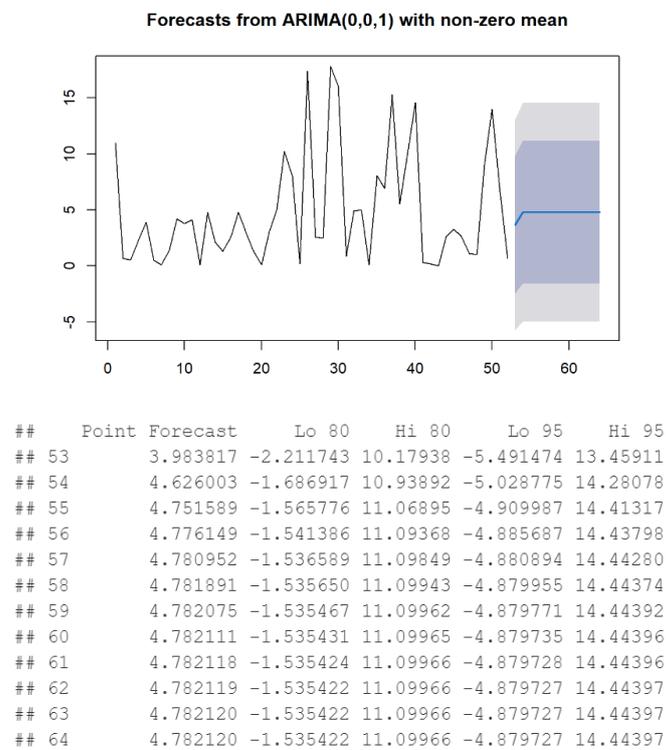


Figura 20. Pronósticos para FN5



Los valores de vibración obtenidos se asocian a los estados del equipo y éstos a cada uno de los indicadores RAM, por lo que, para estimar estos últimos, se consideran los cambios de estado de los equipos, pero esta vez en función del tiempo, es decir, se calculan los tiempos que cada ventilador permanece en los diferentes estados y se los asocia en términos de las ecuaciones (1), (2) y (3) que hacen referencia a tiempos disponibles y de reparación de las máquinas.

La **Tabla 9** muestra los resultados del cálculo de los indicadores de Confiabilidad $C(t)$, Disponibilidad $D(t)$ y Mantenibilidad $M(t)$ de los ventiladores, utilizando los datos históricos, mientras que la **Tabla 10** realiza el mismo cálculo con los datos pronosticados.

Tabla 9. *Indicadores RAM - datos históricos*

Ventilador	T. Oper (h)	MTTR (h)	C(t)	D(t)	M(t)
FN1	30336	552	0.9818	0.9634	1.0000
FN2	30336	372	0.9877	0.9693	1.0000
FN3	30336	372	0.9877	0.9693	1.0000
FN4	30336	372	0.9877	0.9693	1.0000
FN5	30336	630	0.9792	0.9608	1.0000
FN6	30336	864	0.9715	0.9531	1.0000
FN7	30336	744	0.9755	0.9571	1.0000
FN8	30336	0	1.0000	0.9816	1.0000

Tabla 10. *Indicadores RAM - datos pronosticados*

Ventilador	T. Oper (h)	MTTR (h)	C(t)	D(t)	M(t)
FN1	8760	0	1.0000	0.9904	1.0000
FN2	8760	0	1.0000	0.9904	1.0000
FN3	8760	0	1.0000	0.9904	1.0000
FN4	8760	0	1.0000	0.9904	1.0000
FN5	8760	0	1.0000	0.9904	1.0000
FN6	8760	-	-	-	-
FN7	8760	-	-	-	-
FN8	8760	-	-	-	-

Los resultados de los indicadores RAM calculados para el período del pronóstico, indican que para los cinco primeros ventiladores, puede estimarse un 100% de confiabilidad en su operación durante los 12

meses siguientes. Además, se estima un 99,04% de disponibilidad, considerando o no el mantenimiento programado, y un 100% de mantenibilidad, ya que los números muestran que tienen la capacidad de ser reparados en el mínimo tiempo.

Comparando los indicadores RAM de los datos pronosticados con los datos históricos, obviamente existe una diferencia, especialmente en su mantenibilidad $M(t)$, ya que al ser un indicador cuyo parámetro principal es el tiempo de reparación, éste se presenta generalmente al transcurrir un intervalo de tiempo de operación más largo, que dé oportunidad a que se degrade el equipo. Esto no se aprecia en el pronóstico, ya que está proyectado para 12 meses, que es apenas un cuarto del tiempo respecto al tomado para el análisis.

Es evidente que para afinar estos resultados serán necesarias muchas más muestras, tomadas con una planificación mejorada que atienda a los requerimientos de los modelos. Las comparaciones entre los resultados con datos históricos y pronósticos se muestran de forma gráfica en las **Figuras 21, 22 y 23**.

Figura 21. *Confiabilidad (históricos vs pronosticados)*

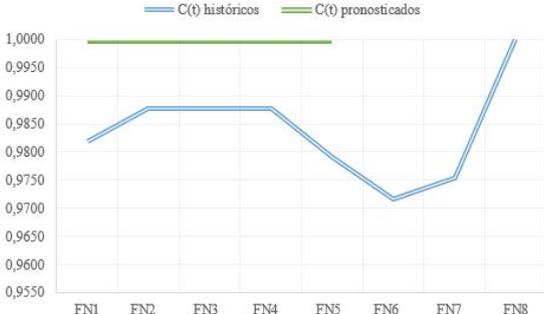


Figura 22. *Disponibilidad (históricos vs pronosticados)*

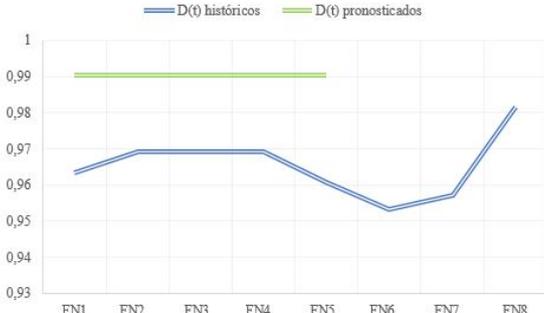
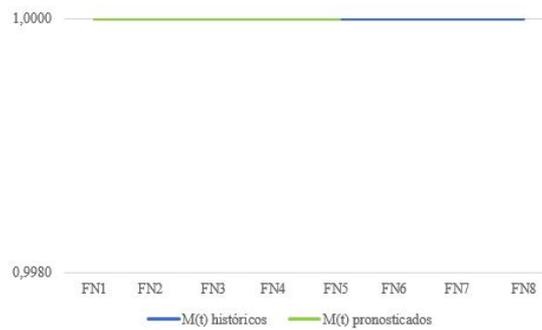


Figura 23. *Mantenibilidad (históricos vs pronosticados)*



CONCLUSIONES

Aplicar los conceptos de la cuarta revolución industrial y llevarlos a prácticas habituales de mantenimiento, cambia el escenario de producción en una planta dado que, a través de la aplicación de técnicas matemáticas, como el modelado de datos para la predicción, puede prolongarse la vida útil de las máquinas y reducir los tiempos de indisponibilidad, gracias a la atención temprana que se les pueda dar.

El análisis RAM en máquinas rotatorias, a través del tratamiento de sus datos de vibración, reduce la probabilidad de un paro no programado en la planta, brindándole al mantenimiento predictivo la oportunidad de manejar programas que generen una capacidad de producción extendida, ya que al identificar oportunamente el elemento cuya condición esté vulnerada de alguna manera, podrán tomarse acciones que prolonguen su vida útil y reducir su tiempo fuera de servicio.

A través de análisis de datos históricos de medidas de vibraciones de ventiladores industriales, se pudo clasificar el estado de las máquinas, y a partir de allí, calcular los tiempos de operación y de indisponibilidad que cuantifican los indicadores principales de mantenimiento. No obstante, se hizo clara la necesidad de contar con un mayor volumen de datos, poniendo especial atención en colectarlos según lo requieren los modelos de pronóstico.

La naturaleza estocástica del proceso de fabricación de *clinker* y las maneras habituales de obtención de datos para el mantenimiento de sus componentes rotatorios, motivó la selección de un modelo de predicción que se ajustara a las características aleatorias propias de su proceso, y aprovechara los datos históricos disponibles, para poder proyectar su condición a los siguientes doce meses.

Generalmente, un análisis RAM se realiza en función de la distribución probabilística a la que se ajustan sus datos de tiempo de falla y reparación (datos que no siempre están disponibles). Sin embargo, existen otras alternativas, como la presentada en este trabajo, que lo realizan a través de la aplicación de modelos estocásticos que predigan medidas de vibración, a partir de datos históricos de la máquina. Obtenidos los pronósticos, se procede a la clasificación de sus estados para asociarlos al cálculo de indicadores RAM y así orientar la toma de decisiones, dentro del proceso de mantenimiento del activo industrial. El beneficio clave de usar este tipo de modelos radica en el uso de datos históricos que solo dependen de una variable, lo que facilita el acopio y tratamiento de la información. Esta propuesta es recomendable para máquinas rotatorias, cuyos datos de vibración permitan la clasificación de los estados de la máquina.

LISTA DE REFERENCIAS

- Achouch M., Dimitrova M., Ziane K., Karganroudi SS., Dhouib R., Ibrahim H., Adda M. (2022). On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. *Applied Sciences-Basel, Volume12, Issue16, Article Number8081, Aug 2022*. DOI10.3390/app12168081
- Alves F., Badikyan H., Moreira A., Azevedo J., Moreira P.M., Romero L., Leitao P. (2020). Deployment of a Smart and Predictive Maintenance System in an Industrial Case Study. *IEEE International Symposium on Industrial Electronics*, vol. 2020-June, pp. 493–498. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ISIE45063.2020.9152441>
- Aly, M. F., Afefy, I. H., Abdel-Magied, R. K., Elhalim, E. K. (2018). A comprehensive model of reliability, availability, and maintainability (RAM) for industrial systems evaluations. *JJMIE*, 12(1), 59-67
- Alya M. F., Afefya I. H., Abdel-Magiedb R. K., Abd Elhalimc E. K. (2018). A Comprehensive Model of Reliability, Availability, and Maintainability (RAM) for Industrial Systems Evaluations. *Jordan Journal of Mechanical and Industrial Engineering*, Volume 12 Number 1, June. 2018, ISSN 1995-6665, Pages 59 - 67
- Barbu V.S., Vergne N. (2019). Reliability and Survival Analysis for Drifting Markov Models: Modeling and Estimation. *Methodol Comput. Appl Probab* 21, 1407–1429. <https://doi.org/10.1007/s11009-018-9682-8>

- Bousdekis A., Apostolou D., Mentzas G. (2019). Predictive Maintenance in the 4th Industrial Revolution: Benefits, Business Opportunities and Managerial Implications. IEEE Engineering Management Review. DOI 10.1109/EMR.2019.2958037
- Bousdekis A., Apostolou D., Mentzas G. (2020). Predictive Maintenance in the 4th Industrial Revolution: Benefits, Business Opportunities, and Managerial Implications. IEEE Engineering Management Review, vol. 48, no. 1, pp. 57-62, 1 Firstquarter. doi: 10.1109/EMR.2019.2958037
- Cachada A. et al. (2018). Maintenance 4.0: Intelligent and Predictive Maintenance System Architecture. 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA), Turin, Italy, 2018, pp. 139-146, doi: 10.1109/ETFA.2018.8502489.
- Cebreiro N., Rodríguez (2021). Principios básicos de las cadenas de Markov. <http://hdl.handle.net/10347/28790.2021>
- Chen B., Liu Y., Zhang C., Wang Z. (2020). Time Series Data for Equipment Reliability Analysis With Deep Learning. IEEE Access, 8, 105484–105493, May 2020. doi:10.1109/access.2020.3000006
- Dindarloo S. (2015). Reliability Forecasting of a Load-Haul-Dump Machine: A Comparative Study of ARIMA and Neural Networks. Wiley Online Library July 2015. DOI: 10.1002/qre.1844
- Gámiz M.L., Limnios N., Segovia-García M.d.C. (2023). Hidden markov models in reliability and maintenance. European Journal of Operational Research, Volume 304, Issue 3, Pages 1242-1255, ISSN 0377-2217. <https://doi.org/10.1016/j.ejor.2022.05.006>
- Gonçalves S., Fruett F., Dalfré Filho G., Giesbrecht M. (2021). Faults detection and classification in a centrifugal pump from vibration data using markov parameters. Mechanical Systems and Signal Processing, Volume 158, 2021, 107694, ISSN 0888-3270. <https://doi.org/10.1016/j.ymssp.2021.107694>
- Hyndman R.J., Athanasopoulos G., (2021). Forecasting: principles and practice, 3rd edition, OTexts: Melbourne, Australia. [OTexts.com/fpp3](https://www.otexts.com/fpp3)
- Jagtap H.P., Bewoor A.K., Kumar R. (2020). RAM analysis and availability optimization of thermal power plant water circulation system using PSO. Energy Reports. <https://doi.org/10.1016/j.egyr.2020.12.025>

- Ji W., Abou Rizk S.M. (2018). Data-Driven Simulation Model for Quality-Induced Rework Cost Estimation and Control Using Absorbing Markov Chains. *Journal of Construction Engineering and Management*, 144(8), 04018078. doi:10.1061/(asce)co.1943-7862.0001534
- Jimenez-Cortadi A., Irigoien I., Boto F., Sierra B., Rodriguez G. (2020). Predictive Maintenance on the Machining Process and Machine Tool. *Applied Sciences-Basel*, Volume10, Issue1, Article Number224, JAN 2020. DOI10.3390/app10010224
- Komal, Sharma S.P., Dinesh Kumar. (2010). RAM analysis of repairable industrial systems utilizing uncertain data. *Applied Soft Computing* 10 (2010) 1208–1221 doi:10.1016/j.asoc.2009.12.019
- Manco G., Ritacco E., Rullo P., Gallucci L., Astill W., Kimber D., Antonelli M. (2017). Fault Detection and Explanation through Big Data Analysis on Sensor Streams, *Expert Systems With Applications*. doi: 10.1016/j.eswa.2017.05.079
- Mishra S., Bordin C., Taharaguchi K., Purkayastha A. (2022). Predictive analytics beyond time series: Predicting series of events extracted from time series data. *Wind Energy*, Volume25, Issue9, Page1596-1609, SEP 2022. DOI: 10.1002/we.2760
- Naderkhani F., Jafari L., Makis V. (2017) Optimal CBM policy with two sampling intervals. *Journal of Quality in Maintenance Engineering*, Volume23, Issue1, Page95-112, March 2017. DOI10.1108/JQME-07-2015-0030
- Quezada A., Rodríguez L., Pérez J., Rodríguez I. (2018). Stochastic processes applied in degradation data analysis - literature review. *Mundo FESC*, ISSN-e 2216-0388, ISSN 2216-0353, Vol. 8, N°. 16, 2018, págs. 85-94
- R Core Team (2022). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria. <https://www.R-project.org/>
- Reis A.S. T., Campos F.C. (2021). Industry 4.0 influences on maintenance operation: a bibliometric analysis. *Conference on Emerging Technologies and Factory Automation (ETFA)*, Volume 53, Issue 2, pp. 01-08. doi:10.1109/ETFA45728.2021.9613499
- Ruiz-Sarmiento J., Monroy J., Moreno F., Galindo C., Bonelo J., Gonzalez-Jimenez J. (2020). A predictive model for the maintenance of industrial machinery in the context of industry 4.0. *Eng. Appl. Artif. Intell.* 87, C. <https://doi.org/10.1016/j.engappai.2019.103289>

- Saini M., Kumar A., Sinwar D. (2022). Parameter estimation, reliability and maintainability analysis of sugar manufacturing plant. *Int J Syst Assur Eng Manag* 13, 231–249. February 2022. <https://doi.org/10.1007/s13198-021-01216-6>
- Sezer E., Romero D., Guedea F., Macchi M., Emmanouilidis C. (2018). An Industry 4.0-enabled Low Cost Predictive Maintenance Approach for SMEs: A Use Case Applied to a CNC Turning Centre. *2018 IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC)*, 2018, 978-1-5386-1469-3/18
- Spendla L., Kebisek M., Tanuska P., Hrcka L. (2017). Concept of predictive maintenance of production systems in accordance with industry 4.0. *IEEE 15th International Symposium on Applied Machine Intelligence and Informatics (SAMI)*, pp. 000405-000410, doi: 10.1109/SAMI.2017.7880343
- Stavropoulos Ch.N., Fassois S.D. (2000). Non-stationary functional series modeling and analysis of hardware reliability series: a comparative study using rail vehicle interfailure times. *Reliability Engineering and System Safety* 68 (2000) 169–183
- Teoh Y. K., Gill S. S., Parlikad A. K. (2021). IoT and Fog Computing based Predictive Maintenance Model for Effective Asset Management in Industry 4.0 using Machine Learning. *IEEE Internet of Things Journal*. doi: 10.1109/JIOT.2021.3050441.
- Topic D., Sljivac D., Stojkov M. (2016). Reliability model of different wind power plant configuration using sequential Monte Carlo simulation. *Eksploatacja I Niezawodnosc-Maintenance and Reliability*, Volume18, Issue2, pp 237-244. DOI10.17531/ein.2016.2.11
- Tsarouhas, P. (2019). Statistical analysis of failure data for estimating reliability, availability and maintainability of an automated croissant production line. *Journal of Quality in Maintenance Engineering*, 25(3), 452-475.
- Villanustre F. (2015). Industrial Big Data Analytics: Lessons from the Trenches. *IEEE/ACM 1st International Workshop on Big Data Software Engineering*, pp. 1-3. doi: 10.1109/BIGDSE.2015.8

Voigt T. et al., (2021). Advanced Data Analytics Platform for Manufacturing Companies. 26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA), Vasteras, Sweden, 2021, pp. 01-08, doi: 10.1109/ETFA45728.2021.9613499.

Yañez Medina M., Gómez de la Vega H., Valbuena Chourio G. (2004).Ingeniería de Confiabilidad y Análisis Probabilístico de Riesgo. Reliability and Risk Management, S. A., ISBN: 980-12-12-0116-9.