

**SEDE CONCEPCIÓN REY BALDUINO DE BELGICA UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA**

“Desarrollo de un Sistema de Mantenimiento Predictivo Basado en Aprendizaje Automático, Normalización ISO y Estimación de Vida Útil (RUL)”

Trabajo de titulación para optar al título
profesional de INGENIERO EN
MANTENIMIENTO INDUSTRIAL

Nombre del alumno

Sebastian Pozas

Nombre profesor guía.

Víctor Valdebenito



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): Memoria o trabajo de título; Tesis de Postgrado;

Título del trabajo: Desarrollo de un Sistema de Mantenimiento Predictivo Basado en Aprendizaje Automático, Normalización ISO y Estimación de Vida Útil (RUL)

Nombre del candidato(a): Sebastian Julian Pozas Espinoza

Carrera / Grado: Ingeniería en Mantenimiento Industrial

Campus: Concepcion ; **Departamento:** Departamento de Ingeniería Mecánica

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Víctor Valdebenito, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

El trabajo **NO contiene información que amerite confidencialidad** y puede ser publicado de inmediato en repositorio con acceso abierto.

El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

6 meses; 12 meses; 2 años; 3 años; 5 años; 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 07/01/2026

Firma:

Estudiante o Candidato(a):

Fecha: 07/01/2026

Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

Dedicatoria

Dedico este trabajo de titulación a mi familia, por el apoyo brindado durante todo mi proceso académico.

En especial, a mi madre, por su constante preocupación y acompañamiento; a mi abuela, por esperarme cada noche con un café y su cariño incondicional; y a mi tía Ani, por ser una persona fundamental en mi vida y por el apoyo permanente que siempre me ha entregado.

Asimismo, agradezco a todas las personas que, de una u otra forma, me apoyaron y acompañaron a lo largo de este camino

Indice

Introducción	5
contexto y motivación del problema.....	5
Definición del problema y alcance	5
Objetivo general.....	6
Objetivos específicos	6
CAPÍTULO 1 – MARCO TEÓRICO.....	8
1.1. Introducción General al Mantenimiento Industrial.....	8
1.2. Evolución del Mantenimiento Industrial	9
1.3. Confiabilidad, Disponibilidad y Mantenibilidad (RAM)	12
1.5. Gestión de Activos Físicos e ISO 55000.....	17
1.6. Métodos Modernos de Mantenimiento	19
1.7. Mantenimiento Basado en Condición (CBM).....	21
1.8. Señales Mecánicas y Térmicas en Equipos Rotativos	22
1.9. Normas Internacionales Aplicables al Mantenimiento Predictivo	23
1.10 Industria 4.0 y Transformación Digital del Mantenimiento.....	25
1.11. Introducción al Machine Learning Aplicado al Mantenimiento Predictivo.....	27
1.12. Preparación de Datos y Feature Engineering.....	28
1.14. Interpretabilidad de Modelos de Machine Learning.....	31
1.15. Pronóstico de Vida Útil Remanente (RUL)	32
1.16. Gemelos Digitales (Digital Twins)	33
1.17. Síntesis del Marco Teórico	34

CAPÍTULO 2 – Planteamiento del problema.....	35
2.1. Contexto General del Problema.....	35
2.2. Descripción del Entorno Específico del Problema	36
2.3. Problema Central	39
2.3.1 Análisis Causas mediante Diagrama Ishikawa.....	42
2.4. Árbol del Problema (Causas y Efectos).....	42
2.5. Justificación del Problema	46
2.6. Análisis de Alternativas de Solución.....	51
2.6.6. Comparación estructurada de alternativas	61
2.7. Principio de Diseño de la Solución Propuesta	62
CAPÍTULO 3 – Diseño de solución	64
3.1. Descripción general de la arquitectura propuesta	64
3.2. Adquisición y Gestión de Datos	67
3.3. Normalización y estandarización mediante ISO 10816/20816.....	72
3.4. Análisis de tendencias y detección temprana de fallas	74
3.5. Diseño del modelo de aprendizaje automático	76
3.6. Motor de Reglas y Sistema de Alertas	80
3.7. Dashboard y visualización del estado del equipo	84
3.8. Ventajas del diseño propuesto frente a alternativas.....	87
CAPÍTULO 4: EVALUACIÓN ECONÓMICA DEL SISTEMA PROPUESTO.....	92
4.4 Costos de operación y mantenimiento del sistema	98
4.5 Costos asociados al escenario actual (sin sistema predictivo)	99
4.6 Estimación de beneficios económicos del sistema propuesto.....	100

Introducción

contexto y motivación del problema

El mantenimiento industrial constituye un pilar fundamental en la continuidad operativa de plantas productivas, especialmente en sectores intensivos en capital como la minería, la energía y la manufactura. Tradicionalmente, las estrategias aplicadas han estado centradas en enfoques **correctivos** (reparar tras la falla) y **preventivos** (intervenciones programadas por horas de operación o calendario). Sin embargo, ambos presentan limitaciones: el correctivo genera detenciones no planificadas con altos costos productivos, mientras que el preventivo puede derivar en reemplazos prematuros y sobrecostos. En este contexto, el **mantenimiento predictivo** surge como alternativa, apoyado en la digitalización e instrumentos de la **Industria 4.0**, permitiendo pronosticar fallas mediante datos operacionales y algoritmos de análisis avanzado. La motivación de este trabajo radica en **construir un sistema que apoye decisiones de mantenimiento** a partir de datos reales y técnicas de *machine learning*, maximizando la disponibilidad y reduciendo costos.

Definición del problema y alcance

El problema central se vincula con la **dificultad de anticipar fallas en equipos industriales críticos** y la falta de integración entre los datos disponibles en planta (sensores de vibración, temperatura, partículas en aceite) y herramientas analíticas que permitan transformar esa información en conocimiento útil. El alcance de este proyecto contempla el **desarrollo de un sistema de mantenimiento predictivo supervisado** implementado en Google Colab, capaz de:

- Procesar y limpiar datos de sensores.
- Integrar umbrales normativos de vibraciones según **ISO 10816/20816**.
- Estimar la probabilidad de falla en un horizonte de 24 horas.
- Entregar indicadores complementarios como fase del ciclo de vida (curva de bañera) y vida útil remanente (RUL).
- Proporcionar salidas operativas para apoyar la toma de decisiones.

Objetivo general

Desarrollar un sistema de mantenimiento predictivo basado en *machine learning* que estime la probabilidad de falla en equipos industriales críticos en un horizonte de 24 horas, integrando límites normativos (ISO), análisis del ciclo de vida (curva de bañera), cálculo de vida útil remanente (RUL) y generación de información complementaria para apoyar la toma de decisiones operativas y estratégicas.

Objetivos específicos

1. **Estudio:** Realizar un estudio técnico y normativo del mantenimiento industrial en equipos críticos que incluya análisis de estrategias actuales, identificando sus principales brechas y limitaciones junto con el análisis de mantenimiento predictivo, confiabilidad de equipos, ciclo de vida de activos y aplicaciones del machine learning en el ámbito industrial
2. **Diseño, implementación :** Diseñar e implementar en **Google Colab** un **pipeline supervisado de mantenimiento predictivo**, que integre procesos de **limpieza y preprocesamiento de datos, extracción de características relevantes, aplicación de límites normativos ISO y estimación de indicadores de confiabilidad como vida útil remanente (RUL) y fase del ciclo de vida.** realizar una **evaluación técnico-económica** del sistema propuesto, comparando su desempeño y costo-beneficio frente a estrategias de mantenimiento **correctivas y preventivas**, con el propósito de estimar **ahorros potenciales** y establecer **lineamientos de integración futura en entornos de gemelo digital**
3. **Verificaciones:** Entrenar y validar modelos supervisados (LogReg, RF, XGBoost) con métricas Recall, ROC-AUC y PR-AUC, verificando confiabilidad de las predicciones.

4. **Evaluación económica:** realizar una **evaluación técnico-económica** del sistema propuesto, comparando su desempeño y costo-beneficio frente a estrategias de mantenimiento **correctivas y preventivas**, con el propósito de estimar **ahorros potenciales** y establecer **lineamientos de integración futura en entornos de gemelo digital**

CAPÍTULO 1 – MARCO TEÓRICO

1.1. Introducción General al Mantenimiento Industrial

El mantenimiento industrial es una disciplina esencial para asegurar la continuidad operacional y el desempeño confiable de los activos físicos dentro de una organización. Su importancia ha aumentado en paralelo al desarrollo tecnológico y a la necesidad de mantener niveles de disponibilidad cada vez más altos en sistemas productivos que operan de forma continua o con poco margen para interrupciones.

En términos simples, el mantenimiento busca garantizar que los equipos cumplan su función cuando son requeridos. Sin embargo, su rol actual supera ampliamente esa definición básica. Hoy se reconoce que una estrategia de mantenimiento bien diseñada influye directamente en la productividad, el costo operativo, la seguridad de los trabajadores y la vida útil de la maquinaria. Por ello, el mantenimiento dejó de ser considerado una actividad “reactiva” para transformarse en un área estratégica que debe tomar decisiones basadas en datos, metodologías formales y análisis de riesgos.

Asimismo, el avance de la digitalización industrial ha permitido incorporar nuevas herramientas de monitoreo y análisis —como sensores inteligentes, almacenamiento de datos en tiempo real y algoritmos de inteligencia artificial— que han cambiado completamente la manera de enfrentar la degradación de los equipos. En este contexto, el mantenimiento predictivo surge como una evolución natural frente a las limitaciones de los enfoques tradicionales.

Este capítulo presenta los fundamentos teóricos que sustentan el desarrollo de un sistema predictivo basado en machine learning, incluyendo la evolución histórica del mantenimiento, los conceptos de confiabilidad, la gestión de activos, las normas técnicas relevantes y el uso de tecnologías emergentes para anticipar fallas en equipos rotativos.

1.2. Evolución del Mantenimiento Industrial

El mantenimiento ha evolucionado a lo largo del tiempo en respuesta a cambios en la tecnología, en la complejidad de los equipos y en la exigencia de las operaciones productivas. Tradicionalmente, se reconocen cuatro grandes etapas o generaciones del mantenimiento, cada una con un nivel de madurez mayor y con diferentes herramientas disponibles.

1.2.1. Mantenimiento Correctivo (reactivo)

El mantenimiento correctivo consiste en intervenir un equipo únicamente cuando falla. Fue el enfoque dominante durante gran parte del siglo XX, principalmente porque las máquinas eran simples y la detención no generaba grandes pérdidas económicas.

Sin embargo, en sistemas modernos este enfoque presenta varias limitaciones:

- produce detenciones inesperadas que afectan la disponibilidad;
 - incrementa costos por reparaciones de emergencia;
 - puede generar fallas secundarias más graves;
 - dificulta la planificación de recursos y repuestos;
- aumenta el riesgo de accidentes o daños a la infraestructura.

Aun así, sigue siendo necesario para fallas imprevisibles o en equipos de baja criticidad.



Representación conceptual del mantenimiento correctivo, caracterizado por la intervención reactiva frente a fallas inesperadas, sin planificación previa.

Nota. Imagen referencial adaptada de iStock (2022).

Se asemeja a apagar incendios

1.2.2. Mantenimiento Preventivo (basado en intervalos)

Con la automatización industrial, las detenciones no planificadas se volvieron inaceptables debido al costo que generan. Esto impulsó el uso del mantenimiento preventivo, donde las

intervenciones se programan en intervalos fijos de tiempo u horas de operación, independientemente de la condición real del equipo.

Este enfoque mejora la planificación, pero tiene desventajas importantes:

- realiza tareas incluso si el equipo está en buenas condiciones;
 - puede generar sobre-mantenimiento;
 - no considera variaciones reales del proceso;
 - puede inducir fallas por intervención excesiva.

A pesar de ello, sigue siendo uno de los métodos más utilizados, especialmente en organizaciones con baja madurez técnica.



representación conceptual de las estrategias de mantenimiento industrial, incluyendo enfoques correctivo, preventivo y predictivo, orientados a la optimización de la gestión de activos.

Nota. Imagen referencial adaptada de Ribeiro de Oliveira (s.f.).

1.2.3. Mantenimiento Predictivo (basado en condición)

El mantenimiento predictivo surge para superar las limitaciones del preventivo y del correctivo. Este enfoque utiliza mediciones reales del equipo para evaluar su condición física y determinar cuándo ocurrirá una falla. Entre las variables comunes monitoreadas se encuentran:

- vibración,
- temperatura,
- presión,
- corriente eléctrica,
- partículas metálicas en lubricante.

La lógica del mantenimiento predictivo es intervenir en el momento óptimo, ni demasiado temprano ni demasiado tarde, permitiendo:

- reducir fallas imprevistas;
- minimizar costos de mantenimiento;
- aumentar el tiempo disponible para programar intervenciones;
- mejorar la disponibilidad operacional.

Este enfoque es el precursor del mantenimiento basado en datos, y actualmente es el punto de partida para sistemas más avanzados que utilizan algoritmos de machine learning para identificar patrones complejos que el análisis humano no siempre detecta.



Representación conceptual de un sistema de mantenimiento predictivo en entornos industriales, que integra monitoreo de condición, análisis de datos y automatización para la detección temprana de patrones de falla.

Nota. Imagen referencial adaptada de Zeleron (s.f)

1.2.4. El mantenimiento proactivo se enfoca en eliminar las causas raíz que originan las fallas. Va más allá de predecir cuándo ocurrirá una falla, buscando evitar que estas se desarrollen. Incluye prácticas como:

- alineación láser,
- balanceo dinámico,
- lubricación basada en análisis,
- rediseño de componentes recurrentes,
- inspecciones avanzadas.

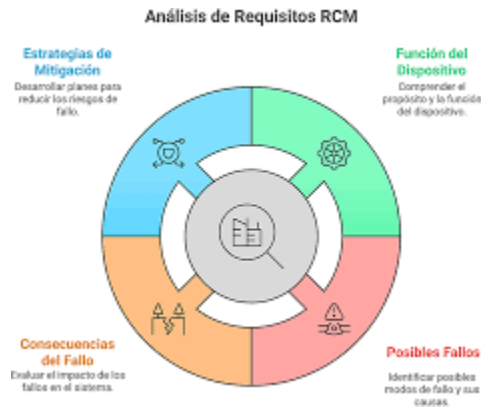
En esta categoría se encuentra el **RCM (Reliability Centered Maintenance)**, un método formal que clasifica fallas según su impacto y define estrategias de mantenimiento óptimas para cada función del equipo.

RCM es muy potente, pero requiere:

- datos de alta calidad,
- equipos multidisciplinarios,
- tiempo de implementación prolongado,

- madurez organizacional.

Por eso, no siempre es viable en contextos donde se necesita una solución rápida y basada en datos actuales, como es el caso de tu proyecto.



Esquema del análisis de requisitos del mantenimiento centrado en confiabilidad (RCM), que integra la definición de funciones del activo, identificación de fallas funcionales, análisis de consecuencias y selección de estrategias de mitigación.

Nota. Adaptado de Hospitecnia (2025).

1.3. Confiabilidad, Disponibilidad y Mantenibilidad (RAM)

Los indicadores RAM son la base técnica para evaluar el desempeño de los activos y la efectividad de las estrategias de mantenimiento. Estos conceptos permiten cuantificar el riesgo, estimar desempeño y justificar la adopción de enfoques predictivos.

1.3.1. Confiabilidad ($R(t)$)

La confiabilidad es la probabilidad de que un equipo funcione correctamente durante un período de tiempo determinado bajo condiciones específicas. Este concepto reconoce que todas las máquinas fallan eventualmente, pero la forma en que fallan depende de:

- materiales,
- condiciones de operación,
 - diseño,
 - mantenimiento,
- deterioro por uso.

Modelos como la distribución Weibull permiten describir el comportamiento del deterioro y estimar la probabilidad de falla según parámetros estadísticos.

1.3.2. Disponibilidad Operacional

La disponibilidad representa el porcentaje de tiempo en el que un equipo está en condiciones de operar. Se calcula como:

$$A = \frac{MTBF}{MTBF + MTTR}$$

donde:

- **MTBF (Mean Time Between Failures):** tiempo promedio entre fallas;
- **MTTR (Mean Time To Repair):** tiempo promedio para reparar.

El mantenimiento predictivo actúa directamente sobre ambos indicadores:

- aumenta el MTBF al anticipar fallas;
- reduce el MTTR al permitir preparar repuestos y personal antes de la falla.

1.3.3. Mantenibilidad

La mantenibilidad corresponde a la probabilidad de que una intervención se realice dentro de un tiempo establecido. Mejora con:

- buen acceso físico a componentes,
- diagnósticos claros y anticipados,
- procedimientos estandarizados,
- herramientas adecuadas.

Un sistema predictivo basado en machine learning incrementa la mantenibilidad al permitir identificar con anticipación qué componente requiere intervención y qué tipo de falla se aproxima.



Análisis RAM (Confiabilidad, Disponibilidad y Mantenibilidad) a lo largo del ciclo de vida de los activos, mostrando la relación entre las etapas de diseño, operación y mantenimiento, y su impacto en la gestión de activos.
Nota. Adaptado de Predictiva21 (2022).

1.4. Modelos de Fallas y Ciclo de Vida del Equipo

Para justificar un sistema predictivo es necesario comprender cómo evolucionan las fallas y cómo se representa matemáticamente el deterioro de los activos. Las herramientas más relevantes son la **curva de la bañera**, el **modelo P-F** y la **tasa de falla $\lambda(t)$** .

1.4.1. Curva de la bañera

La curva de la bañera representa la tasa de fallas de un equipo durante su ciclo de vida. Consta de tres etapas:

1. **Fallas tempranas:** debidas a defectos de fabricación o instalación.

2. **Vida útil estable:** fallas aleatorias con tasa relativamente constante.

3. **Desgaste:** aumento progresivo de la tasa de falla debido a fatiga y deterioro.

El mantenimiento predictivo se centra principalmente en la tercera fase, buscando identificar señales tempranas del desgaste antes del punto crítico.



Curva de la bañera, que representa la evolución de la tasa de fallas de un equipo a lo largo de su ciclo de vida, incluyendo las fases de fallas tempranas, vida útil estable y desgaste.

Fuente: Adaptado de Engeman (2025).

1.4.2. Modelo P-F

El modelo P-F establece dos hitos fundamentales:

- **P:** punto en el que una falla potencial puede detectarse.
- **F:** punto en el que la falla funcional ocurre.

El intervalo **P–F** representa la ventana de oportunidad para intervenir antes de la falla. Mientras más temprano se detecte el punto P, mayor será el beneficio para la organización.

Los sensores modernos y los modelos de machine learning aumentan la capacidad de identificar el punto P con precisión, lo que permite planificar intervenciones sin afectar la disponibilidad.



Curva P-F del mantenimiento centrado en confiabilidad, que representa la ventana de oportunidad entre la detección de una falla potencial (P) y la ocurrencia de la falla funcional (F).

Fuente: Adaptado de Evtech (2019)

Los modelos de aprendizaje automático permiten detectar patrones débiles o no lineales en los datos históricos, lo que desplaza el punto P hacia la izquierda. Esto significa que la falla potencial puede ser detectada antes de que aparezcan señales tradicionalmente visibles

Ejemplo:

- Rodamientos: P–F = 2 a 8 semanas
- Bombas centrífugas: P–F = 1 a 4 semanas
- 5 Motores eléctricos: P–F = días a semanas

El modelo P–F es el fundamento teórico del mantenimiento basado en condición (CBM). Al identificar el punto P mediante monitoreo continuo, se programan intervenciones dentro de la ventana P–F, lo que reduce fallas inesperadas y optimiza la disponibilidad del activo

El cálculo del Remaining Useful Life (RUL) es una extensión del modelo P–F, donde en lugar de trabajar con ventanas aproximadas, se estima cuantitativamente el tiempo restante antes del punto F. En el Capítulo 3 se emplea RUL estimado mediante modelos de regresión para complementar el diagnóstico

En el caso del equipo considerado en este proyecto, el punto P está asociado a los incrementos sistemáticos en la vibración RMS y temperatura, que se vuelven detectables mediante análisis de tendencia. Este comportamiento fue incorporado a los cálculos de RUL y a los modelos ML, permitiendo detectar P antes de que se superen límites ISO

El modelo P–F se sitúa principalmente en la tercera etapa de la curva de la bañera, correspondiente al desgaste. En esta fase, los cambios en vibración y temperatura incrementan progresivamente, siendo posibles de detectar mediante análisis de tendencia y modelos ML

De acuerdo con las recomendaciones de ISO 17359, la detección temprana de P requiere monitoreo continuo de variables físicas, siendo coherente con el enfoque implementado en esta tesis

Si la vibración sube de 1.8 mm/s a 2.5 mm/s en 48 horas y la ISO fija 2.3 mm/s como límite B–C, el cruce detectado representa el punto P

Fase	Indicador detectable	Método
Inicio de P	Incremento leve en vibración	RMS, espectro FFT
Medio P–F	Aumento de temperatura	sensores termales
Fase tardía	Ruido, vibración severa	análisis permanente
F	Falla funcional	detención

Tabla 1 Niveles P-F

1.4.3. Tasa de falla $\lambda(t)$

La tasa de falla es la probabilidad instantánea de fallo en un intervalo de tiempo, dado que el equipo se ha mantenido funcionando hasta ese momento. Valores crecientes de $\lambda(t)$ indican deterioro acelerado.

Identificar cuándo $\lambda(t)$ comienza a aumentar es el objetivo principal del mantenimiento predictivo.

1.5. Gestión de Activos Físicos e ISO 55000

La gestión de activos físicos es un enfoque integral que busca asegurar que los equipos, instalaciones y recursos de una organización aporten el máximo valor durante todo su ciclo de vida. Este enfoque no se limita simplemente a mantener máquinas, sino que integra planificación estratégica, evaluación de riesgos, control financiero y toma de decisiones fundamentada en datos.

La familia de normas ISO 55000 —que incluye ISO 55000, ISO 55001 e ISO 55002— establece los lineamientos para implementar sistemas de gestión de activos basados en el valor y en la continuidad operacional. Estas normas reconocen que los activos no deben ser administrados de manera aislada, sino como parte de un sistema que interactúa con procesos, personas, indicadores financieros y requerimientos regulatorios.

En el contexto del mantenimiento predictivo, la gestión de activos proporciona el marco conceptual que justifica por qué una organización debería invertir en sistemas basados en datos y diagnóstico avanzado. La ISO 55000, particularmente, enfatiza la importancia de la toma de decisiones informada, donde se evalúa el impacto de cada intervención sobre el desempeño global del activo.

1.5.1. Principios de la Gestión de Activos según ISO 55000

La norma establece varios principios clave:

- **Enfoque basado en valor:** cada intervención debe generar un beneficio medible para el negocio.
- **Alineación organizacional:** mantenimiento y producción deben trabajar como un solo sistema.
- **Liderazgo y cultura:** la toma de decisiones debe ser consistente y orientada a resultados.
- **Adaptación al riesgo:** la criticidad del activo determina la prioridad de mantenimiento.
- **Información confiable:** los datos deben ser precisos, oportunos y estructurados.

Estos principios conectan directamente con la necesidad de implementar soluciones predictivas que permitan anticipar problemas y tomar decisiones con mayor fundamento técnico.

1.5.2. Ciclo de vida del activo (Life Cycle Cost, LCC)

El ciclo de vida de un activo incluye varias fases:

1. **Diseño**
2. **Adquisición**
3. **Instalación**
4. **Operación**
5. **Mantenimiento**
6. **Reemplazo o disposición**

El mantenimiento influye en la mayor parte del costo total de vida (LCC), especialmente cuando los equipos son críticos para la operación. Una detención inesperada, por ejemplo, puede equivaler a semanas de inversión en mantenimiento planificado.

Un sistema predictivo optimiza el ciclo de vida porque:

- reduce los costos asociados a fallas catastróficas,
 - maximiza la disponibilidad,
- permite decisiones de reemplazo basadas en datos,

- prolonga la vida útil del activo.
-

1.5.3. Evaluación de criticidad

La criticidad de un activo se determina evaluando:

- probabilidad de falla,
 - consecuencias operacionales,
 - efectos en seguridad,
 - impacto económico,
- cumplimiento normativo.

Los activos con criticidad alta suelen ser equipos rotativos como compresores, bombas, motores y ventiladores. Estos equipos, además, presentan patrones medibles de degradación, lo que los convierte en excelentes candidatos para sistemas predictivos basados en machine learning.

1.6. Métodos Modernos de Mantenimiento

La ingeniería de mantenimiento ha incorporado herramientas provenientes de la gestión de calidad, la confiabilidad y la ingeniería industrial. Estas herramientas permiten comprender mejor los modos de falla, optimizar planes de mantenimiento y estructurar decisiones técnicas.

1.6.1. Reliability Centered Maintenance (RCM)

El **RCM** es un método formal que busca definir la estrategia óptima de mantenimiento para cada activo según su función, modo de falla y consecuencia. A diferencia del mantenimiento tradicional, en RCM no se realiza una tarea porque “siempre se ha hecho así”, sino porque existe una razón técnica justificada.

Las etapas del RCM incluyen:

1. **Definir funciones del equipo**
2. **Identificar fallas funcionales**
3. **Determinar modos de falla**
4. **Evaluar efectos y consecuencias**
5. **Seleccionar tareas óptimas**

6. Documentar y revisar

El RCM no reemplaza al mantenimiento predictivo, pero provee un marco metodológico que valida la necesidad de monitorear ciertos parámetros.

Beneficios del RCM:

- reduce el sobre-mantenimiento,
- mejora la disponibilidad,
- enfoca recursos en funciones realmente críticas,
 - elimina tareas sin aporte real.

Limitaciones:

- requiere gran cantidad de datos históricos;
- demanda equipos multidisciplinarios;
- su implementación puede tomar meses.

Estas limitaciones explican por qué algunas organizaciones prefieren sistemas predictivos basados en datos actuales, más rápidos de implementar.

1.6.2. Análisis de Modo y Efecto de Falla (FMEA/FMECA)

El **FMEA** identifica modos de falla y cuantifica su severidad, ocurrencia y detectabilidad. En su variante **FMECA** se incorpora el análisis de criticidad.

El índice principal es el RPN (Risk Priority Number):

$$RPN = S \times O \times D$$

Un sistema predictivo mejora el indicador D (capacidad de detección), reduciendo la probabilidad de fallas críticas.

1.6.3. Total Productive Maintenance (TPM)

El **TPM** busca integrar a los operadores en actividades básicas de mantenimiento y mejorar el flujo productivo. Su premisa es que los operadores conocen de primera mano los síntomas tempranos de falla.

El TPM incluye:

- mantenimiento autónomo,
- reducción de pérdidas,

- capacitación continua,
- gestión temprana de equipos,
- seguridad y ambiente.

El mantenimiento predictivo puede ser considerado un componente avanzado del TPM en organizaciones que ya poseen madurez operacional.

1.6.4. Herramientas de análisis de causa raíz (RCA)

Las herramientas RCA ayudan a identificar la causa que originó una falla. Entre estas destacan:

- Diagrama de Ishikawa
- Análisis “5 Porqués”
- Árbol de fallas (FTA)

Estas herramientas son fundamentales para validar los resultados de un modelo predictivo: permiten discriminar entre alarmas reales y falsas, y ayudan a mejorar el modelo con datos más limpios.

1.7. Mantenimiento Basado en Condición (CBM)

El CBM es uno de los pilares fundamentales del mantenimiento predictivo. A diferencia del mantenimiento preventivo tradicional, el CBM se basa en medir y analizar el estado real del equipo.

1.7.1. Principios del CBM

El CBM se fundamenta en cuatro ideas centrales:

- Las fallas no ocurren de forma abrupta; presentan síntomas.
 - Estos síntomas pueden ser medidos mediante sensores.
- La condición del equipo es más importante que el tiempo de operación.
- Las intervenciones deben hacerse cuando los datos lo indiquen.

Este enfoque requiere:

- sensores adecuados,
 - frecuencia de muestreo correcta,

- métodos analíticos para interpretar tendencias.
-

1.7.2. Ventajas del CBM

- menos fallas inesperadas,
 - menos intervenciones innecesarias,
 - reducción de costos globales,
 - decisiones basadas en datos,
 - alineación con ISO 17359.
-

1.7.3. Limitaciones

- requiere infraestructura de sensorización,
 - necesita personal capacitado,
- genera grandes volúmenes de datos que deben ser gestionados.

Por esto las soluciones basadas en machine learning son tan atractivas: permiten analizar grandes cantidades de datos de forma automatizada.

1.8. Señales Mecánicas y Térmicas en Equipos Rotativos

La detección temprana de fallas depende en gran medida de la interpretación de señales físicas provenientes del equipo. Los valores de vibración, la temperatura y el análisis de partículas metálicas son las fuentes para diagnosticar degradación.

1.8.1. Vibración RMS

El nivel RMS proporciona una medida de la energía total de vibración. Un aumento puede indicar:

- desbalance,
 - desalineación,
 - fallas en rodamientos,
 - holguras mecánicas,
 - problemas electromagnéticos.
-

1.8.2. Análisis espectral (FFT)

Transforma la señal del dominio del tiempo al dominio de frecuencia. Permite identificar:

- frecuencia de giro,
 - armónicos,
 - resonancias,
 - defectos específicos de rodamientos.
-

1.8.3. Temperatura

La temperatura es un indicador universal de degradación. Aumentos consistentes suelen asociarse a:

- fricción excesiva,
 - mala lubricación,
 - sobrecarga,
 - fallas eléctricas.
-

1.8.4. Partículas metálicas

Cuando un componente se desgasta, libera partículas detectables por sensores inductivos o análisis de aceite. Este parámetro revela fallas internas incluso antes de que aparezcan cambios en vibración.

1.9. Normas Internacionales Aplicables al Mantenimiento Predictivo

El mantenimiento industrial moderno se sustenta en normas técnicas que proporcionan lineamientos para la medición, clasificación y análisis del estado de los equipos. Estas normas permiten estandarizar procesos, comparar resultados entre organizaciones y asegurar que los diagnósticos se fundamenten en criterios validados internacionalmente. En el desarrollo de soluciones predictivas, estas normas funcionan como referencia base para interpretar el estado actual del activo y para establecer umbrales técnicos de alerta.

Las normas más relevantes para equipos rotativos, análisis de vibraciones, gestión de datos y monitoreo de condición incluyen: ISO 10816/20816, ISO 14224, ISO 17359 y IEC 60034-14.

1.9.1. ISO 10816 / 20816 – Evaluación de Vibraciones Mecánicas en Máquinas

La norma **ISO 10816** (hoy evolucionada a **ISO 20816**) establece criterios para evaluar la severidad de vibraciones en máquinas industriales basándose en el valor RMS (Root Mean Square). Esta norma clasifica los niveles de vibración en cuatro zonas:

- **Zona A:** Condición excelente, operación segura.
- **Zona B:** Condición aceptable; pueden requerirse inspecciones.
- **Zona C:** Condición insatisfactoria; se recomienda corregir.
- **Zona D:** Condición peligrosa; existe riesgo de falla.

La norma diferencia además entre:

- máquinas pequeñas, medianas y grandes,
- equipos con distintos tipos de soportes,
- máquinas con motores eléctricos o combustión interna.

En un sistema predictivo, estas zonas se utilizan como referencia para generar diagnósticos combinados. Por ejemplo, un modelo de machine learning puede predecir tendencia futura, mientras que la norma ISO clasifica el estado presente. Esta complementariedad aumenta la confiabilidad del diagnóstico.

1.9.2. ISO 14224 – Gestión y Estructura de Datos para Confiabilidad y Mantenimiento

La norma **ISO 14224** define cómo deben registrarse y organizarse los datos relacionados con fallas, modos de falla, repuestos, intervenciones, horas de operación y criticidad del equipo.

Esta norma es particularmente relevante para proyectos basados en machine learning, ya que establece:

- taxonomía estandarizada de fallas,
- estructura de campos y registros,
- codificación uniforme de eventos,
- criterios para clasificar severidad y efectos,
- prácticas recomendadas para adquisición de datos.

En otras palabras, ISO 14224 entrega el “formato correcto” para estructurar la información que luego utilizarán modelos predictivos.

1.9.3. ISO 17359 – Monitoreo de Condición

La **ISO 17359** define los requisitos para implementar un programa de monitoreo de condición, incluyendo:

- tipos de variables a medir,
- frecuencia de medición,
- métodos analíticos,
- criterios de evaluación,
- estructura de reportes.

El estándar recomienda que un programa CBM incluya mediciones de:

- vibración,
- temperatura,
- presión,
- firma eléctrica,
- partículas en aceite.

Esto coincide directamente con el enfoque del presente proyecto, que incorpora vibración, temperatura y partículas metálicas como variables centrales.

1.9.4. IEC 60034-14 – Vibraciones en Máquinas Eléctricas Rotativas

La norma **IEC 60034-14** complementa las ISO al establecer tolerancias de vibración específicamente para motores eléctricos. Esta norma es ampliamente utilizada en industrias donde los motores son críticos para procesos productivos.

Su uso es importante porque muchos equipos rotativos presentan fallas que se originan en el motor y no en el mecanismo acoplado, por lo cual un análisis correcto requiere considerar ambas referencias normativas.

1.10 Industria 4.0 y Transformación Digital del Mantenimiento

La Industria 4.0 representa la integración entre sistemas físicos y sistemas digitales, dando origen a entornos de producción inteligentes. En este contexto, el mantenimiento ha experimentado una transformación significativa, pasando desde sistemas manuales y reactivos a plataformas automatizadas que integran sensores, redes de comunicación, análisis de datos e inteligencia artificial.

1.10.1. Conceptos centrales de la Industria 4.0

La Industria 4.0 se basa en tecnologías habilitadoras tales como:

- **Internet de las Cosas Industrial (IIoT):** redes de sensores conectados que capturan datos en tiempo real.
 - **Big Data:** almacenamiento masivo de información operacional.
 - **Edge Computing:** procesamiento de datos cercano al equipo.
 - **Cloud Computing:** plataformas con alta capacidad de cálculo.
 - **Ciberseguridad industrial:** protección de redes y dispositivos.
- **Sistemas ciberfísicos:** combinación de hardware y software que operan de forma integrada.

Estas tecnologías permiten que la información fluya desde los equipos hacia sistemas analíticos capaces de detectar patrones complejos, por ejemplo algoritmos de machine learning.

1.10.2. El rol del mantenimiento en la Industria 4.0

El mantenimiento pasa de ser una función reactiva a convertirse en un sistema:

- **predictivo,**
- **autosupervisado,**
- **optimizable en tiempo real,**
- **capaz de aprender del comportamiento del activo.**

El mantenimiento 4.0 incluye:

- sensores inteligentes,
- plataformas de análisis distribuidas,
 - dashboards en tiempo real,
 - automatización de alarmas,
- diagnóstico asistido por algoritmos.

1.10.3. Beneficios del mantenimiento digitalizado

La digitalización permite:

- mayor precisión en el diagnóstico,
- reducción de tiempos muertos,

- mejor planificación,
- visibilidad completa del estado del activo,
- recopilación histórica de datos para modelos ML.

Esto hace que el mantenimiento predictivo sea cada vez más económico y accesible.

1.11. Introducción al Machine Learning Aplicado al Mantenimiento Predictivo

El machine learning (ML) es una rama de la inteligencia artificial que permite a los sistemas aprender patrones a partir de datos. Su uso en mantenimiento ha crecido debido a la necesidad de analizar señales complejas y de anticipar fallas que no siempre son evidentes mediante métodos tradicionales.

1.11.1. Conceptos fundamentales

Los modelos de ML se clasifican comúnmente en tres categorías:

- **Aprendizaje supervisado:** el modelo aprende a partir de ejemplos etiquetados (falla/no falla).
- **Aprendizaje no supervisado:** identifica patrones sin etiquetas (agrupamientos, anomalías).
 - **Aprendizaje semi-supervisado:** mezcla ambos enfoques.

Para sistemas predictivos en mantenimiento, el enfoque más común es el aprendizaje supervisado, debido a que permite predecir eventos futuros con base en datos históricos.

1.11.2. Modelos utilizados en mantenimiento

Los modelos más comunes son:

- Regresión Logística
- Árboles de decisión
 - Random Forest
 - Gradient Boosting
 - XGBoost
- Redes neuronales simples

- Modelos de series de tiempo

Cada modelo tiene fortalezas específicas. En el presente proyecto, se seleccionan la regresión logística, Random Forest y XGBoost debido a su robustez, interpretabilidad y capacidad para manejar datos tabulares con interacciones complejas.

1.11.3. Métricas de evaluación

Para evaluar modelos en mantenimiento, las métricas más relevantes son:

- **Recall:** prioridad máxima (importa detectar fallas aunque haya falsos positivos).
 - **Precision:** porcentaje de predicciones correctas.
 - **ROC-AUC:** discriminación global del modelo.
 - **PR-AUC:** útil cuando las fallas son poco frecuentes.
 - **Matriz de confusión:** análisis completo de errores.

Un sistema predictivo debe priorizar el *recall* para no pasar por alto fallas críticas.

1.12. Preparación de Datos y Feature Engineering

Una parte fundamental del desarrollo de sistemas predictivos es la preparación de los datos. Los modelos de machine learning dependen de que la información esté limpia, estructurada y represente correctamente el comportamiento físico del equipo.

1.12.1. Limpieza y validación

Incluye:

- eliminación de valores faltantes,
 - detección de datos atípicos (outliers),
 - filtrado de ruido,
 - verificación de consistencia temporal.
-

1.12.2. Normalización y escalado

Muchos modelos requieren normalizar o escalar las variables para evitar que una magnitud domine sobre otra. Por ejemplo:

- vibración (mm/s),

- temperatura (°C),
 - partículas metálicas (ppm),
- pueden variar en órdenes de magnitud distintos.
-

1.12.3. Generación de nuevas características (features)

Esto puede incluir:

- medias móviles,
- derivadas (ritmo de cambio),
 - tendencias,
 - señales filtradas,
- indicadores estadísticos.

Estas características enriquecen la información que el modelo recibe.

1.12.4. División en entrenamiento y prueba

Los datos deben separarse para garantizar que el modelo aprenda patrones reales y pueda generalizar correctamente.

1.13. Modelos de Machine Learning Utilizados en el Mantenimiento Predictivo

Los modelos de machine learning aplicados al mantenimiento predictivo tienen como objetivo identificar patrones en los datos que permitan anticipar el comportamiento de los equipos antes de que ocurra una falla. En este tipo de problemas, las variables predictoras suelen ser valores continuos de vibración, temperatura, corriente eléctrica o indicadores de desgaste, mientras que la variable objetivo generalmente corresponde a un estado de salud binario (falla/no falla) o una estimación de la vida útil remanente (RUL).

En el presente proyecto se utilizaron modelos supervisados debido a la disponibilidad de etiquetas asociadas a eventos de falla. Entre los modelos más representativos se encuentran la regresión logística, Random Forest y XGBoost, los cuales se describen a continuación.

1.13.1. Regresión Logística

La regresión logística es un modelo estadístico ampliamente utilizado en clasificación binaria. Su principal ventaja es su interpretabilidad: entrega probabilidades asociadas a la ocurrencia de un evento de falla y permite analizar el efecto de cada variable en el resultado.

Este modelo se vuelve particularmente útil en organizaciones que requieren justificar decisiones de mantenimiento con evidencia simple y comprensible. Aunque su capacidad para capturar relaciones no lineales es limitada, sigue siendo un punto de partida válido para clasificar estados normales y anómalos.

1.13.2. Random Forest

Random Forest es un modelo ensamblado basado en árboles de decisión. Se caracteriza por:

- manejar relaciones no lineales,
- tolerar ruido en los datos,
- funcionar bien con datasets relativamente pequeños,
- entregar métricas de importancia de variables.

Para mantenimiento predictivo, Random Forest es útil para evaluar qué variables influyen más en el deterioro del activo. En particular, suele identificar vibración y temperatura como factores clave en la predicción de fallas en equipos rotativos.

1.13.3. XGBoost

XGBoost (Extreme Gradient Boosting) es uno de los modelos más utilizados en la industria debido a su capacidad para:

- capturar interacciones complejas entre variables,
 - manejar valores faltantes,
- escalar con grandes volúmenes de datos,
- ofrecer alto rendimiento en problemas tabulares.

En aplicaciones industriales, XGBoost se ha convertido en un estándar para predicción de fallas, especialmente cuando los patrones en los datos no son fácilmente detectables mediante métodos tradicionales o lineales.

1.13.4. Comparación de modelos para mantenimiento

Cada modelo tiene ventajas y limitaciones, pero en general:

- **Regresión logística:** simple, interpretable, buen baseline.
- **Random Forest:** robusto, no lineal, buena interpretabilidad relativa.
- **XGBoost:** mejor rendimiento predictivo, especialmente con datos heterogéneos.

Por esto, una estrategia común es entrenar los tres modelos, compararlos y seleccionar el mejor para el sistema final. En este proyecto, se adoptó un enfoque de evaluación cruzada que prioriza métricas como *recall* y PR-AUC, debido a la importancia de no omitir fallas.

1.14. Interpretabilidad de Modelos de Machine Learning

En mantenimiento, no basta con predecir una falla: es necesario comprender **por qué** el modelo tomó esa decisión. Esta necesidad se debe principalmente a:

- requisitos de seguridad,
- auditoría técnica,
- confianza operativa,
- toma de decisiones informada.

Los modelos deben ser comprensibles por personal técnico, ingenieros de mantenimiento y supervisores. La interpretabilidad permite validar resultados, identificar errores y retroalimentar el modelo para mejorar su desempeño.

1.14.1. Importancia de variables (Feature Importance)

Tanto Random Forest como XGBoost permiten obtener la importancia relativa de cada variable. Esto ayuda a responder preguntas como:

- ¿Cuál variable influye más en la predicción de una falla?
- ¿La máquina falla por vibración, temperatura o desgaste interno?

Esta información también sirve para seleccionar variables relevantes y descartar aquellas que agregan ruido.

1.14.2. SHAP (Shapley Additive Explanations)

SHAP es un método avanzado de interpretabilidad basado en teoría de juegos. Permite descomponer la predicción de un modelo en contribuciones de cada variable.

Beneficios:

- explica cada predicción individual,
- muestra efectos positivos o negativos,
- ayuda a detectar si el modelo está aprendiendo patrones incorrectos.

En un contexto industrial, SHAP permite generar reportes comprensibles, por ejemplo:

“La vibración en zona C y la temperatura elevada incrementan la probabilidad de falla en un 20%.”

1.14.3. Interpretabilidad y confianza operativa

La aceptación de un sistema predictivo depende en gran medida de la confianza que generen sus resultados. Un técnico normalmente desconfiará de un modelo que entrega una probabilidad sin justificar el motivo. Por eso, integrar interpretabilidad no es opcional: es un componente crítico para asegurar adopción en terreno.

1.15. Pronóstico de Vida Útil Remanente (RUL)

El concepto de **RUL (Remaining Useful Life)** se refiere al tiempo estimado que le queda a un equipo antes de que falle o supere un umbral crítico. El RUL es uno de los indicadores más valiosos del mantenimiento predictivo, ya que permite planificar intervenciones con anticipación.

1.15.1. Concepto de RUL

El RUL se expresa generalmente en horas, ciclos o porcentaje de vida restante. Su estimación puede basarse en:

- análisis estadístico,
 - extrapolación de tendencias,
 - modelos probabilísticos,
 - modelos de machine learning.

En este proyecto se implementa un RUL aproximado basado en tendencias de la vibración y límites ISO.

1.15.2. Métodos de estimación

Los métodos más comunes incluyen:

- Regresión lineal sobre tendencias
- Modelos ARIMA o series de tiempo
- Redes neuronales recurrentes (LSTM)
- Modelos de supervivencia (Cox, Weibull)

- Algoritmos híbridos (XGBoost + series temporales)

Cada enfoque tiene ventajas dependiendo de la cantidad y calidad de los datos disponibles.

1.15.3. Uso del RUL en decisiones de mantenimiento

El RUL permite:

- programar intervenciones de manera óptima,
 - preparar repuestos con anticipación,
 - coordinar paradas de planta,
- evaluar costo/beneficio de reparar vs. reemplazar.

El objetivo final es evitar que la falla ocurra en el peor momento posible.

1.16. Gemelos Digitales (Digital Twins)

Un **gemelo digital** es una réplica virtual de un activo físico, alimentada continuamente con datos reales provenientes de sensores. Permite simular comportamientos, diagnosticar anomalías y predecir fallas bajo distintos escenarios.

1.16.1. Componentes de un gemelo digital

- **Modelo físico o matemático** del equipo
 - **Datos en tiempo real** mediante sensores
 - **Plataforma digital** para visualizar y analizar
 - **Algoritmos predictivos** para pronóstico
-

1.16.2. Aplicación en mantenimiento

Los gemelos digitales permiten:

- simular degradación,
 - evaluar impacto de cambios operacionales,
 - estimar RUL con mayor precisión,
- probar modelos predictivos sin afectar la operación real.

Si bien este proyecto no desarrolla un gemelo digital completo, sí constituye un paso previo, pues los modelos entrenados podrían integrarse en un gemelo en el futuro.

1.17. Síntesis del Marco Teórico

El presente capítulo revisó los fundamentos técnicos, conceptuales y normativos necesarios para comprender la propuesta de un sistema de mantenimiento predictivo basado en machine learning. Se analizaron las distintas estrategias de mantenimiento —desde el correctivo hasta el proactivo— junto con su relación con la confiabilidad, disponibilidad y ciclo de vida de los activos.

Además, se abordaron herramientas modernas como RCM, FMEA, RCA y TPM, todas las cuales proporcionan un marco metodológico para evaluar modos de falla y justificar decisiones técnicas. Se presentó también el monitoreo basado en condición, el análisis de vibraciones, la normativa ISO aplicable y las tecnologías propias de la Industria 4.0 que permiten automatizar la adquisición y análisis de datos.

En la segunda parte del capítulo se introdujeron los conceptos fundamentales de machine learning aplicados al mantenimiento, incluyendo los modelos utilizados, las métricas de evaluación, la preparación de datos, la interpretabilidad de algoritmos y el concepto de vida útil remanente (RUL). Finalmente, se revisó la noción de gemelos digitales como una evolución futura del mantenimiento predictivo.

En conjunto, este marco teórico establece la base conceptual necesaria para desarrollar la solución propuesta en esta tesis. El siguiente capítulo profundizará en el planteamiento del problema, analizando las causas, consecuencias y alternativas existentes para justificar la necesidad de implementar un sistema predictivo basado en datos.

CAPÍTULO 2 – Planteamiento del problema

2.1. Contexto General del Problema

La gestión del mantenimiento industrial ha experimentado transformaciones significativas en las últimas décadas, impulsadas por el aumento de la automatización, la incorporación de maquinaria de mayor complejidad y la necesidad de alcanzar niveles más altos de confiabilidad y disponibilidad operacional. En este escenario, los equipos rotativos —como bombas, motores, ventiladores y compresores— cumplen un rol crítico dentro de los procesos productivos, ya que suelen operar de manera continua y son responsables de asegurar el flujo energético y mecánico del sistema. Cualquier falla en estos equipos puede generar detenciones no planificadas, reducción en la productividad, pérdida de materia prima y, en casos graves, riesgos para la seguridad del personal.

A pesar de los avances tecnológicos disponibles, muchas organizaciones aún dependen fuertemente de prácticas de mantenimiento tradicional que no permiten anticipar de manera efectiva el deterioro progresivo de los equipos. En numerosos casos, el diagnóstico del estado de una máquina depende de la experiencia del técnico o del análisis visual, lo que introduce una alta variabilidad en la interpretación de la condición real del activo. Esta dependencia de procedimientos subjetivos dificulta generar reportes consistentes, estandarizar criterios técnicos y establecer estrategias de mantenimiento basadas en evidencia.

Por otro lado, la digitalización industrial ha generado nuevas oportunidades para mejorar la gestión del mantenimiento mediante la utilización de sensores, adquisición continua de datos y sistemas de monitoreo en línea. No obstante, la mera presencia de sensores o recopilación de datos no garantiza una mejora operacional si estos no son analizados

correctamente. En muchos entornos productivos, la información disponible sobre vibraciones, temperatura o desgaste queda almacenada sin ser procesada o utilizada para tomar decisiones críticas. Esta desconexión entre la generación de datos y su uso efectivo representa una brecha importante en la adopción plena del mantenimiento predictivo.

En este contexto, se observa una necesidad creciente de soluciones que permitan integrar los datos disponibles con metodologías analíticas avanzadas, como el aprendizaje automático (machine learning), para anticipar fallas con mayor precisión y reducir la dependencia exclusiva del criterio humano. El surgimiento de modelos predictivos aplicados al mantenimiento ha demostrado ser especialmente útil en industrias donde las fallas generan costos elevados por paradas no planificadas o disminución en la calidad del proceso productivo.

Finalmente, el aumento competitivo en los mercados y la presión por mantener altos niveles de disponibilidad han llevado a que las organizaciones busquen alternativas más eficientes y automatizadas. Aun así, la implementación de sistemas predictivos comerciales suele presentar barreras como altos costos de licenciamiento, baja adaptabilidad a contextos específicos o poca transparencia en su funcionamiento. Por lo tanto, existe una motivación real por desarrollar soluciones más flexibles, accesibles y adaptadas al nivel de madurez tecnológica de cada organización.

2.2. Descripción del Entorno Específico del Problema

El entorno en el cual se desarrolla este problema corresponde a un escenario industrial caracterizado por altos niveles de exigencia operativa, recursos limitados para implementar tecnologías avanzadas y una dependencia significativa de prácticas tradicionales de mantenimiento. A pesar de los avances disponibles en monitoreo de condición y en digitalización, muchas organizaciones mantienen rutinas que no permiten comprender completamente el comportamiento dinámico de los equipos rotativos, generando brechas importantes entre el estado actual del mantenimiento y lo que se considera un estándar moderno.

Una característica común en este tipo de entornos es la **heterogeneidad tecnológica**. Es frecuente encontrar equipos nuevos con sensores incorporados conviviendo con maquinaria antigua sin ningún tipo de instrumentación, lo que provoca que la calidad y cantidad de datos disponibles sea desigual. Esta disparidad dificulta la implementación de sistemas de diagnóstico consistentes, pues algunos activos cuentan con monitoreo aceptable mientras otros dependen exclusivamente de inspecciones manuales. Esta falta de uniformidad afecta directamente la capacidad para anticipar fallas y establecer estrategias de mantenimiento basadas en condición.

Además, existe una **brecha significativa en la trazabilidad de la información**. Muchas organizaciones registran datos de operación en planillas individuales, cuadernos de trabajo o informes técnicos aislados que no se integran en una base centralizada. Esta

fragmentación impide construir un historial sólido del comportamiento del equipo y dificulta identificar patrones que podrían revelar fallas recurrentes o tendencias de deterioro. Incluso cuando se recopilan los datos, no siempre existe un procedimiento establecido para analizarlos, lo que hace que la información pierda valor práctico con el tiempo.

Otro aspecto relevante del entorno es la **dependencia del criterio humano** para diagnosticar anomalías. Técnicos y operadores suelen identificar fallas “por experiencia”, basándose en percepción auditiva, vibraciones sentidas manualmente o comparaciones visuales. Aunque el conocimiento empírico es importante, introduce subjetividad y variabilidad entre personas con distintas trayectorias. Esta dependencia se vuelve especialmente compleja cuando hay rotación de personal o cuando los técnicos más experimentados se retiran, generando pérdida de conocimiento organizacional.

A nivel operativo, las decisiones de mantenimiento suelen apoyarse en rutinas preventivas de carácter **estático**, basadas en horas de operación o fechas calendarizadas. Este enfoque no considera condiciones reales como carga variable, desgaste acelerado, desbalance progresivo, fluctuaciones térmicas o ambientes corrosivos. Como resultado, algunos equipos reciben mantenimiento excesivo mientras que otros, sometidos a condiciones más exigentes, no reciben atención oportuna. Esto no solo genera sobrecostos innecesarios, sino que aumenta el riesgo de fallas catastróficas en activos críticos.

Por otro lado, muchas organizaciones no poseen **mecanismos para evaluar en tiempo real el estado del equipo**. Las mediciones de vibración, temperatura o partículas metálicas suelen realizarse de forma esporádica, sin una metodología clara para interpretar tendencias. En ausencia de un análisis continuo, es prácticamente imposible identificar el punto P del modelo P–F, lo cual significa que las fallas son detectadas cuando ya se encuentran cerca del punto F, es decir, demasiado tarde para evitar una detención no planificada.

A nivel cultural, también se observan desafíos. La adopción de nuevas tecnologías requiere una transición hacia un enfoque más analítico y orientado a datos, lo cual puede generar resistencia interna. En entornos donde el mantenimiento ha funcionado históricamente de manera reactiva, la idea de incorporar modelos predictivos basados en algoritmos puede resultar inicialmente ajena o incluso desconfiable. Esta resistencia se ve agravada cuando los equipos carecen de formación en herramientas digitales, análisis estadístico o interpretación de datos provenientes de sensores.

Otro factor importante es el **costo económico asociado a las fallas inesperadas**. Aunque muchas organizaciones reconocen el impacto de estas fallas, pocas han desarrollado mecanismos formales para cuantificar las pérdidas asociadas a:

- la detención de la línea de producción,
- el retraso en la entrega de productos o servicios,
- el costo del mantenimiento de emergencia,

- el reemplazo prematuro de componentes,
 - el tiempo improductivo del personal,
- la pérdida de confianza en la disponibilidad del proceso.

Estas variables económicas, aunque evidentes, rara vez son incorporadas de forma sistemática en la planificación del mantenimiento, lo que limita la capacidad para justificar inversiones en soluciones más modernas y eficientes.

Finalmente, se observa que la mayoría de las organizaciones se encuentran en un punto intermedio entre un mantenimiento preventivo tradicional y un incipiente mantenimiento predictivo. Existe conciencia sobre la importancia de modernizar procesos, pero todavía no se ha logrado consolidar un sistema que integre datos históricos, señales de operación en tiempo real y algoritmos analíticos que permitan anticipar fallas con precisión.

Podemos resumir el entorno específico del problema en los siguientes elementos:

a) Operación con alta dependencia de diagnóstico humano

Las fallas suelen detectarse por percepción sensorial o experiencia del técnico, lo que introduce variabilidad y limita el uso de herramientas objetivas.

b) Ausencia de monitoreo continuo

Las variables críticas no se registran de forma sistemática, impidiendo identificar tendencias que anticipen fallas.

c) Falta de una base de datos estructurada

Los registros suelen estar dispersos, incompletos o no estandarizados.

d) Prácticas de mantenimiento preventivo rígidas

No consideran condiciones reales de operación, generando tanto intervenciones innecesarias como fallas por falta de oportunidad.

e) Costos operacionales elevados asociados a fallas imprevistas

No solo en repuestos y mano de obra, sino en pérdidas de producción.

f) Limitada adopción de tecnologías emergentes

Poca integración entre sensores, sistemas de supervisión y análisis automatizado.

g) Madurez organizacional insuficiente para implementar RCM completo

Aunque existe interés, la falta de datos históricos dificulta su aplicación práctica.

h) Falta de estandarización según normas internacionales

Sin ISO 10816/20816 y sin ISO 14224, es muy difícil comparar resultados y evaluar diagnósticos.

i) Oportunidad clara para introducir machine learning

La existencia de datos básicos (vibración, temperatura, partículas) permite comenzar sin grandes inversiones.

2.3. Problema Central

A partir del análisis del entorno industrial descrito anteriormente, es posible identificar que el problema fundamental radica en la **incapacidad del sistema de mantenimiento actual para anticipar fallas en equipos rotativos de manera oportuna y confiable**. Esta incapacidad no se debe a un único factor aislado, sino a la combinación de elementos técnicos, organizacionales y operativos que convergen en un escenario donde las decisiones se toman con información incompleta, dispersa o basada únicamente en experiencia personal.

El problema central puede resumirse en la siguiente afirmación:

El sistema de mantenimiento presenta una limitada capacidad predictiva debido a la ausencia de monitoreo sistemático, falta de análisis avanzado de datos y dependencia excesiva del criterio humano, generando fallas imprevistas que afectan la disponibilidad, incrementan costos y reducen la confiabilidad operacional de los equipos rotativos.

Esta afirmación sintetiza la brecha entre la necesidad real de anticipación y las herramientas actualmente disponibles. El mantenimiento existente, centrado principalmente en rutinas preventivas calendarizadas, no logra capturar la condición real del equipo ni detectar patrones de deterioro progresivo. Como consecuencia, los equipos pueden presentar fallas antes de la intervención programada, o bien pueden recibir mantenimiento cuando aún se encuentran en buenas condiciones, generando sobrecostos innecesarios.

La naturaleza del problema también está relacionada con la **ausencia de criterios estandarizados para evaluar el estado de los activos**. Sin normas como ISO 10816/20816 o ISO 14224 aplicadas correctamente, cada técnico interpreta los síntomas del equipo según su propia experiencia, lo que provoca diagnósticos inconsistentes entre turnos, áreas o niveles de capacitación. Esta variabilidad disminuye la confiabilidad de las decisiones operacionales y aumenta el riesgo de fallas no detectadas.

Asimismo, el problema incluye la **subutilización de datos existentes**. Aunque en muchos casos se registran valores de vibración, temperatura o señales eléctricas, estos datos suelen quedar almacenados sin análisis, no se integran en una plataforma centralizada y no se utilizan para generar modelos predictivos. Esta desconexión entre el dato y la decisión es uno de los factores más críticos que impiden transitar hacia un mantenimiento moderno basado en condición.

Otro aspecto del problema es la **reacción tardía frente a condiciones anómalas**. Sin herramientas que permitan seguir la evolución temporal de las variables críticas, las fallas suelen detectarse únicamente cuando los síntomas ya son evidentes: vibraciones excesivas,

aumento drástico de temperatura, ruido mecánico o fluctuaciones eléctricas. A ese punto, el deterioro suele ser irreversible o requiere intervenciones correctivas costosas, incluyendo detenciones prolongadas que afectan la continuidad productiva.

El problema también se expresa en términos económicos, dado que las detenciones no planificadas generan:

- pérdida de producción,
- horas-hombre improductivas,
- necesidad urgente de repuestos,
- daños secundarios a componentes,
- mayor tiempo de diagnóstico,
- retrasos en compromisos operacionales.

Estas consecuencias se acumulan y reducen significativamente la eficiencia del sistema. Incluso cuando existen planes preventivos, estos no están optimizados porque no se basan en datos de condición real ni en modelos de confiabilidad.

Además, el problema afecta la **seguridad operativa**. Un equipo rotativo que opera en condiciones deterioradas puede generar sobrecalentamiento, vibraciones excesivas o fallas mecánicas catastróficas que ponen en riesgo a los trabajadores y al entorno de operación. La falta de anticipación incrementa la probabilidad de un evento crítico.

Finalmente, el problema central está asociado a una **incertidumbre operacional elevada**, expresada en decisiones como:

- ¿Intervenimos ahora o en la próxima parada?
- ¿El equipo puede seguir operando sin riesgo?
- ¿Qué componente está fallando realmente?
- ¿Cuánto tiempo de vida útil le queda al activo?

Sin información predictiva, estas decisiones se vuelven especulativas.

Desglose del problema central

Para estructurar aún más el análisis, el problema puede descomponerse en cuatro dimensiones principales:

a) Dimensión técnica

- No existe un monitoreo en línea o con frecuencia suficiente.
- No se aplican estándares ISO para clasificar severidad.

- No hay modelos matemáticos o estadísticos que expliquen la degradación.
 - Las señales no son procesadas ni analizadas correctamente.

b) Dimensión informacional

- Los datos se encuentran dispersos, incompletos o no registrados.
 - No existe una base de datos centralizada.
- No se aplican modelos de aprendizaje automático para anticipación.

c) Dimensión organizacional

- Dependencia del conocimiento empírico.
 - Falta de capacitación en herramientas modernas.
- Baja madurez digital, dificultando la implementación de sistemas avanzados.

d) Dimensión económica

- Elevados costos por fallas inesperadas.
 - Sobremantenimiento preventivo.
- Tiempo de detención superior al necesario por falta de diagnóstico oportuno.

Conclusión del problema central

En síntesis, el problema no es simplemente “que las máquinas fallan”, sino que:

- **fallan sin aviso suficiente,**
- **no se utilizan datos disponibles para predecir fallas,**
- **no existen herramientas analíticas que apoyen decisiones,**
 - **las rutinas preventivas son poco efectivas,**
 - **las intervenciones son reactivas y costosas,**
 - **la confiabilidad operacional disminuye,**
 - **y la incertidumbre técnica aumenta.**

Esto abre el espacio perfecto —y totalmente justificable— para implementar una solución predictiva basada en machine learning, apoyada en normas internacionales y en variables reales del equipo.

2.3.1 Análisis Causas mediante Diagrama Ishikawa

Con el objetivo de identificar de manera estructurada las causas raíz asociadas a la incapacidad del sistema de mantenimiento actual para anticipar fallas en equipos críticos, se elaboró un diagrama de Ishikawa basado en la metodología de las 6M (Personas, Proceso, Equipo, Materiales/Datos, Entorno y Administración). Este análisis permite visualizar las influencias técnicas, operacionales y organizacionales que contribuyen al problema central.

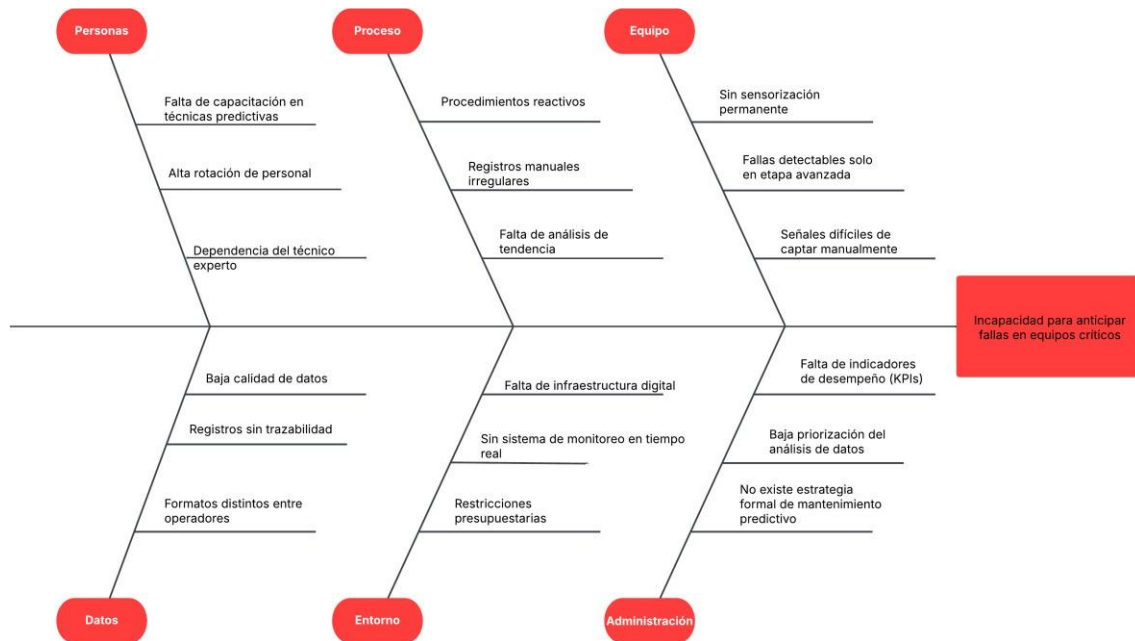


Diagrama de Ishikawa que identifica las causas técnicas, operacionales y organizacionales asociadas a la incapacidad de anticipar fallas en equipos críticos.

Nota. Elaboración propia.

2.4. Árbol del Problema (Causas y Efectos)

Con el propósito de profundizar en la estructura causal del fenómeno identificado, se construyó un Árbol del Problema que permite vincular las causas raíz e intermedias con el problema central y sus efectos directos y finales. Este instrumento complementa el análisis mediante diagrama Ishikawa y facilita la selección de alternativas en la siguiente sección

El Árbol del Problema permite descomponer el fenómeno observado en diferentes niveles causales. En la parte superior se identifican las **causas raíz**, que corresponden a factores estructurales del sistema de mantenimiento, tales como la ausencia de monitoreo continuo, la baja madurez digital, la dependencia del diagnóstico humano y la falta de estandarización

bajo normas como ISO 10816/20816 y 14224. Estas causas son de carácter sistémico y constituyen el origen principal de la incapacidad para anticipar fallas.

A continuación, se presentan las **causas intermedias**, que reflejan cómo las causas raíz se manifiestan operativamente dentro de la organización. Entre ellas destacan la carencia de análisis de tendencias, la ejecución de rutinas preventivas rígidas sin considerar condición real, la escasa integración entre sistemas y la generación tardía de diagnósticos. Estas causas intermedias explican por qué las señales tempranas de degradación no son detectadas ni gestionadas adecuadamente.

En el centro del árbol se ubica el **problema central**, que corresponde a la limitada capacidad del sistema actual para anticipar fallas en equipos críticos. Este problema genera una serie de **efectos directos**, tales como fallas inesperadas, incremento del MTTR, aumento de intervenciones correctivas y aparición de daños secundarios en los equipos.

Finalmente, estos efectos derivan en **consecuencias finales** que afectan directamente la operación, entre ellas la reducción de la disponibilidad, el aumento de los costos operacionales, la disminución de la vida útil del activo y la mayor variabilidad operativa.

Relación con el diseño de la solución

El análisis estructurado del Árbol del Problema constituye una base fundamental para justificar la solución propuesta en el Capítulo 3. Al identificar que la raíz del problema se encuentra en la ausencia de monitoreo continuo, la falta de análisis basado en datos y la carencia de herramientas predictivas, se valida la necesidad de implementar un sistema que integre:

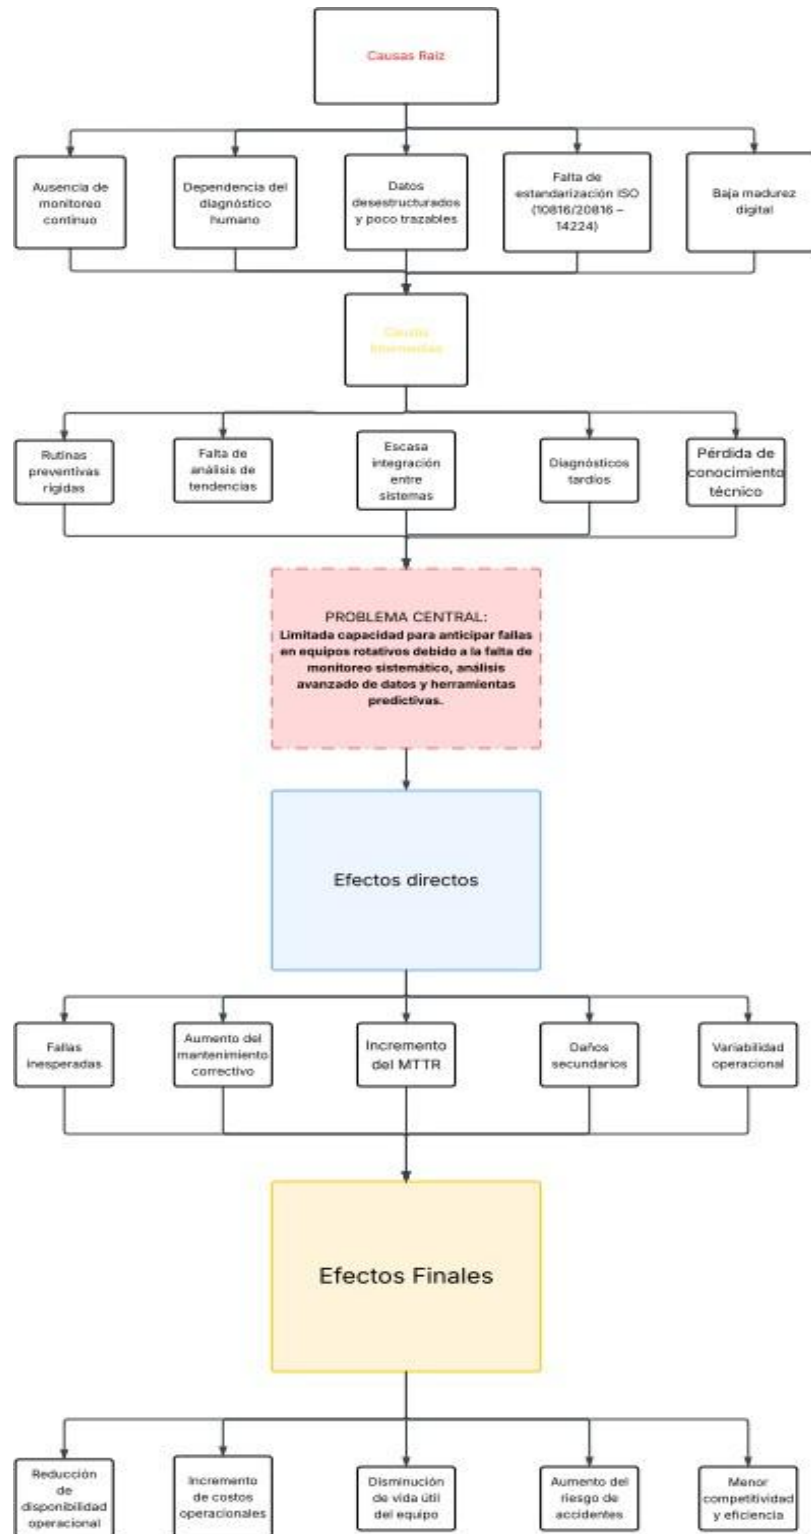
- adquisición continua de señales relevantes,
 - normalización bajo estándares ISO,
- modelos de aprendizaje automático para predicción de fallas,
 - estimación del RUL,
- y un motor de reglas para emitir alertas.

Dicho diseño responde de forma directa a las brechas causales identificadas, atacando tanto causas raíz como causas intermedias. Con esto se asegura que la solución no aborda solo los síntomas, sino los factores que originan el problema central.

Cierre de la sección

En conjunto, el Árbol del Problema complementa el análisis mediante Ishikawa y permite establecer una trazabilidad clara entre las causas identificadas, sus efectos operativos y la necesidad de un enfoque predictivo avanzado. Este análisis será utilizado en la siguiente

sección para evaluar alternativas de solución y seleccionar la propuesta más adecuada para el contexto industrial estudiado.



*Árbol de fallas que representa las causas, efectos directos y efectos finales asociados a la limitada capacidad de anticipar fallas en equipos rotativos, en el contexto del mantenimiento industrial.
Nota. Elaboración propia.*

2.5. Justificación del Problema

La justificación del problema busca demostrar por qué la falta de capacidad predictiva en el mantenimiento de equipos rotativos representa una situación crítica para la continuidad operativa, la eficiencia productiva y la sostenibilidad económica de la organización. Este análisis no solo considera elementos técnicos, sino también impactos operacionales, costos asociados, riesgos y oportunidades de mejora vinculadas a la implementación de metodologías modernas de mantenimiento.

La necesidad de abordar este problema se fundamenta en tres dimensiones principales:

justificación técnica, justificación económica y justificación operacional y estratégica.

Cada una de estas dimensiones revela cómo el problema afecta de manera directa e indirecta la gestión de activos y por qué una solución basada en modelos predictivos resulta viable y necesaria.

2.5.1. Justificación técnica

Desde el punto de vista técnico, la principal justificación radica en que los métodos utilizados actualmente para diagnosticar fallas no permiten detectar de forma temprana la degradación progresiva de los equipos. La falta de monitoreo continuo, la escasa estandarización técnica y la dependencia del criterio humano provocan un escenario donde las fallas se identifican solo cuando ya son evidentes o avanzadas.

Esto implica:

- imposibilidad de identificar el **punto P** del modelo P–F,
- incapacidad para analizar tendencias en vibración, temperatura o desgaste,
 - dificultad para asignar criticidad real a los equipos,
 - diagnósticos inconsistentes entre técnicos o turnos,
- ausencia de modelos matemáticos o estadísticos que expliquen la degradación.

Además, la falta de estándares como **ISO 10816/20816** para vibraciones y **ISO 14224** para clasificación de fallas impide realizar evaluaciones comparables, replicables y auditables. Sin estos criterios, la organización carece de una base sólida para justificar intervenciones o cambios en políticas de mantenimiento.

Un sistema predictivo basado en machine learning aborda estas carencias técnicas al:

- analizar patrones complejos que no son detectables visualmente,
 - integrar datos históricos con mediciones actuales,
- clasificar estados de salud con criterios consistentes,
- generar alertas anticipadas basadas en evidencia,

- complementar diagnósticos técnicos humanos con modelos objetivos,
- permitir estimaciones aproximadas de vida útil remanente (RUL).

Por tanto, la implementación de un sistema predictivo no es solo una mejora, sino una necesidad técnica para asegurar decisiones más precisas y reducir el margen de error inherente al mantenimiento reactivo o preventivo tradicional.

2.5.2. Justificación económica

Las fallas inesperadas tienen un impacto económico significativo que suele superar ampliamente los costos de implementar soluciones predictivas. En la práctica industrial, el costo de una detención no planificada incluye:

- pérdida directa de producción,
 - horas-hombre improductivas del personal,
- compra de repuestos de emergencia con sobreprecio,
 - contratación urgente de servicios externos,
 - posibles daños secundarios en componentes,
 - deterioro acelerado de activos críticos,
- penalizaciones o retrasos en compromisos operacionales.

En muchas industrias, **una hora de detención inesperada puede representar pérdidas equivalentes a semanas de actividades normales de mantenimiento**. Cuando las fallas ocurren repetidamente, estos costos se acumulan y generan un impacto considerable en el presupuesto anual de operación.

A esto se suma el fenómeno del **sobremantenimiento preventivo**, en el cual se realizan intervenciones innecesarias por temor a fallas. Estas intervenciones:

- consumen recursos humanos,
- exigen paradas programadas,
- aceleran la degradación por manipulación frecuente,
- demandan repuestos que no siempre son necesarios.

La falta de un sistema de análisis avanzado impide identificar cuándo una intervención preventiva agrega valor y cuándo solo incrementa costos.

Un sistema predictivo basado en machine learning permite:

- disminuir horas de detención no planificada,

- optimizar el uso de recursos del área de mantenimiento,
 - reducir costos asociados a fallas catastróficas,
 - programar intervenciones con mayor anticipación,
 - disminuir la incertidumbre en la compra de repuestos,
- aumentar la vida útil de los equipos mediante operabilidad dentro de límites seguros.

Por lo tanto, desde el punto de vista económico, el problema es altamente justificable ya que genera pérdidas reales y repetitivas que pueden mitigarse mediante tecnologías de anticipación.

2.5.3. Justificación operacional

Operacionalmente, la falta de un sistema predictivo afecta directamente la estabilidad y continuidad del proceso. Los equipos rotativos suelen ser activos críticos; su falla no solo detiene una máquina, sino que afecta toda la cadena productiva. Por esa razón, la capacidad de anticipar anomalías es un requisito fundamental para asegurar la disponibilidad del sistema.

Las consecuencias operacionales del problema incluyen:

- incremento del **MTTR** debido a fallas inesperadas,
- reducción del **MTBF** al operar bajo condiciones no controladas,
 - disminución de la calidad del producto final,
 - interrupciones en los flujos de trabajo,
- descoordinación entre producción y mantenimiento,
 - acumulación de órdenes correctivas,
- pérdida de confiabilidad operacional percibida por el personal de planta.

Estas situaciones generan estrés operativo, desorden organizacional y dificultades en la planificación diaria de actividades. La incertidumbre se convierte en un factor que limita la capacidad de cumplir objetivos de producción, especialmente en industrias de alta demanda.

La implementación de un sistema predictivo proporciona:

- estabilidad operacional,
- mayor capacidad de coordinación entre áreas,
- información clara sobre el estado de equipos,

- reducción de la variabilidad operativa,
 - toma de decisiones basada en evidencia,
 - alineación con prácticas modernas de gestión de activos.
-

2.5.4. Justificación estratégica

Desde la perspectiva estratégica, resolver este problema permite a la organización avanzar hacia niveles más altos de madurez en mantenimiento y alinearse con los principios de la **Industria 4.0**. Actualmente, la competitividad industrial depende de la capacidad para integrar datos, automatizar decisiones, mejorar la confiabilidad y reducir costos operativos.

No contar con un sistema predictivo impide:

- escalar hacia políticas avanzadas de confiabilidad,
- implementar RCM con fundamentos sólidos,
- cumplir estándares internacionales de mantenimiento,
- integrar la operación con plataformas digitales,
- establecer indicadores clave (KPI) confiables,
- sustentar decisiones estratégicas de reemplazo o inversión.

La digitalización del mantenimiento no es un lujo, sino una **necesidad estratégica** para asegurar sustentabilidad a largo plazo.

2.5.5. Justificación social y de seguridad

Aunque suele subestimarse, la falta de anticipación de fallas también tiene implicaciones en la seguridad del personal:

- equipos vibrando fuera de norma pueden fragmentarse,
- sobrecalentamientos pueden generar incendios,
- fallas eléctricas pueden causar cortocircuitos o descargas.

Anticipar estos escenarios reduce riesgos y crea un entorno más seguro para los trabajadores.

Conclusión de la Justificación

La combinación de factores técnicos, económicos, operacionales y estratégicos demuestra que la limitada capacidad predictiva del sistema de mantenimiento actual no es un

problema menor, sino una barrera significativa para la eficiencia y la confiabilidad de los equipos rotativos. Su resolución mediante herramientas de machine learning y monitoreo basado en condición representa una oportunidad real para mejorar el desempeño global del sistema y avanzar hacia prácticas modernas alineadas con la Industria 4.0.

2.6. Análisis de Alternativas de Solución

Una vez identificado el problema central y comprendidas sus causas raíz, es necesario evaluar distintas alternativas que podrían abordar la limitada capacidad predictiva del sistema actual de mantenimiento. En ingeniería, el proceso de selección de una solución requiere comparar distintos enfoques posibles, analizar su viabilidad técnica, sus requerimientos operativos, su costo aproximado y su impacto en la confiabilidad de los activos.

En esta sección se presentan diversas alternativas que una organización podría considerar. Algunas representan metodologías tradicionales; otras, soluciones comerciales disponibles en la industria; y finalmente, la alternativa propuesta en este proyecto, basada en el uso de machine learning y monitoreo de condición.

El propósito de esta sección no es descartar arbitrariamente opciones, sino demostrar que **todas fueron evaluadas bajo criterios objetivos**, y que la solución seleccionada ofrece el mejor equilibrio entre costo, impacto, escalabilidad, facilidad de implementación y beneficios operacionales.

2.6.1. Alternativa 1: Fortalecimiento del Mantenimiento Preventivo Calendarizado

El mantenimiento preventivo es una de las estrategias más utilizadas en entornos industriales debido a su simplicidad y a su facilidad de planificación. Bajo este enfoque, las intervenciones se programan de acuerdo con intervalos fijos, por ejemplo:

- cambio de rodamiento cada 6 meses,
- revisión de vibración cada 3 meses,
- cambio de lubricante cada 1.000 horas,
 - alineaciones calendarizadas,
- inspecciones visuales programadas.

Aunque este método ha sido útil durante décadas, su efectividad depende de un supuesto clave: **que los equipos envejecen de manera uniforme**, lo cual rara vez ocurre en la práctica.

Ventajas del mantenimiento preventivo

- Fácil de planificar y gestionar.
- No requiere tecnologías avanzadas.
- Asegura intervenciones mínimas periódicas.

Limitaciones del mantenimiento preventivo

1. **No considera la condición real del equipo**

Dos máquinas idénticas pueden trabajar en ambientes distintos, con cargas diferentes y niveles variables de desgaste. Intervenirlas en el mismo momento puede ser ineficiente o incluso contraproducente.

2. **Genera sobre-mantenimiento**

Reemplazar rodamientos o lubricantes antes de su desgaste real implica:

- costos innecesarios,
- incremento del riesgo de errores por intervención repetida,
 - detenciones que no aportan valor.

3. **No anticipa fallas, solo reduce su probabilidad**

Una máquina puede fallar a los cinco meses aunque el plan diga que su revisión es a los seis.

4. **Depende del criterio humano para detectar anomalías**

En muchas rutinas preventivas, el técnico registra observaciones manuales, lo cual es subjetivo.

5. **No permite implementar Industria 4.0**

El mantenimiento basado exclusivamente en calendario queda obsoleto frente a la necesidad de digitalización, monitoreo en línea y toma de decisiones basada en datos.

Conclusión sobre la alternativa preventiva

Aunque fortalecer el mantenimiento preventivo podría reducir algunas fallas, **no resuelve la causa raíz del problema: la falta de anticipación basada en datos reales**. Por lo tanto, esta alternativa se considera insuficiente como solución principal.

- Permite estandarizar tareas básicas

Criterio de Evaluación	Descripción	Puntaje (1-5)
Costo de implementación	Bajo: requiere solamente planificación y mano de obra.	4
Costo de operación a largo plazo	Medio, debido al sobre-mantenimiento y repuestos innecesarios.	3
Capacidad predictiva	Muy baja, no anticipa fallas basadas en condición real.	1
Reducción de fallas no planificadas	Limitada, las fallas pueden ocurrir entre intervalos.	2
Adaptación a variaciones operacionales	Muy baja: planificación fija sin considerar carga real.	1
Requerimiento de datos	Nulo: no necesita sensores ni registros históricos.	5
Dependencia del criterio humano	Muy alta.	1
Escalabilidad	Media: se puede extender, pero no mejora la capacidad diagnóstica.	2
Integración con Industria 4.0	Muy baja.	1
Explicabilidad	Alta: es simple entender la metodología preventiva.	5

Evaluación comparativa del mantenimiento preventivo basado en intervalos. Nota. Elaboración propia.

2.6.2. Alternativa 2: Implementación de un Software Comercial de Mantenimiento Predictivo

Actualmente existen plataformas comerciales capaces de monitorear variables como vibración, temperatura y corriente, integrando algoritmos de inferencia automatizada. Sin embargo, estas soluciones suelen tener costos elevados y están diseñadas para industrias de gran escala.

Ventajas

- No requiere desarrollo interno.
- Interfaces fáciles de usar.
- Reportes automáticos y dashboards listos.
- Modelos validados en la industria.

Limitaciones (críticas y profundas):

1. Altos costos de licenciamiento y suscripción

Muchas plataformas trabajan bajo modelo SaaS con pago mensual por equipo monitoreado.

2. Falta de adaptabilidad a contextos locales

Los modelos suelen estar calibrados para máquinas específicas de fabricantes internacionales.

No siempre funcionan bien con:

- maquinaria antigua,
- sistemas modificados,
- condiciones ambientales extremas,
- sensores de bajo costo.

3. Dependencia de proveedores externos

En caso de falla, actualización o personalización, se depende totalmente de la empresa externa.

4. Requiere infraestructura adicional

Gateways, sensores propietarios, contratos de soporte, módulo de ciberseguridad, etc.

5. Curva de aprendizaje y resistencia cultural

Para personal sin formación digital, el sistema puede generar rechazo.

Conclusión de esta alternativa

Si bien es una solución robusta, **su costo y poca flexibilidad la hacen inviable para un contexto donde se requiere una solución accesible, escalable y adaptada a maquinaria existente.** No soluciona la falta de estandarización ni la necesidad de modelos explicables

Criterio de Evaluación	Descripción	Puntaje (1-5)
Costo de implementación	Muy alto: licencias, hardware propietario, soporte.	1
Costo de operación	Alto: suscripciones y costos por equipo monitoreado.	1
Capacidad predictiva	Alta: modelos probados.	4
Reducción de fallas no planificadas	Alta: depende del modelo y sensores disponibles.	4
Adaptación a condiciones locales	Baja: modelos rígidos y poco personalizables.	2
Requerimiento de datos	Alto: requiere sensorización amplia.	4
Dependencia del proveedor	Muy alta.	1
Escalabilidad	Baja: cada equipo añade un costo incremental importante.	2
Integración con Industria 4.0	Alta.	5
Explicabilidad	Media: funcionan como cajas negras con baja transparencia.	2

Tabla 2 Creacion propia. 2025. Puntaje predictivo.

2.6.3. Alternativa 3: Implementar un Mantenimiento Centrado en Confiabilidad (RCM) Completo

Un análisis RCM es uno de los métodos más avanzados para estructurar planes de mantenimiento. Sin embargo, su implementación implica un proceso complejo, largo y costoso.

Ventajas

- Identifica modos de falla en profundidad.
- Define estrategias óptimas de mantenimiento.
 - Aporta estructura técnica sólida.

Limitaciones críticas:

1. Requiere un alto nivel de madurez organizacional

Si la empresa no posee datos históricos estructurados, el RCM no puede ejecutarse correctamente.

2. Consumo elevado de tiempo y recursos

Implementar un RCM completo suele tomar entre 6 meses y 2 años.

3. Genera planes, pero no predice fallas

Un RCM bien implementado mejora decisiones, pero **no anticipa el instante en que ocurrirá la falla.**

4. Depende significativamente del criterio experto

Aunque la metodología es estructurada, la interpretación sigue siendo humana.

5. No se integra automáticamente con sensores ni modelos predictivos

Requiere soporte adicional para incorporar monitoreo y machine learning.

Conclusión

RCM es una herramienta valiosa, pero **no es una solución al problema central.**

El problema no es la falta de planes, sino la falta de anticipación basada en datos reales.

Criterio de Evaluación	Descripción	Puntaje (1-5)
Costo de implementación	Alto: requiere consultores externos y especialistas.	1
Costo de operación	Medio–alto: análisis y talleres continuos.	2
Capacidad predictiva	Media: identifica modos de falla, no predice degradación.	2
Reducción de fallas no planificadas	Media: mejora gestión pero no anticipa punto P.	3
Adaptación a variaciones operacionales	Media–alta: depende del análisis.	3
Requerimiento de datos	Muy alto: requiere históricos extensos.	1
Dependencia del criterio humano	Muy alta.	1
Escalabilidad	Media: aplicable pero costosa.	3
Integración con Industria 4.0	Baja–media.	3
Explicabilidad	Alta: metodología estructurada.	5

Tabla 3 Evaluación comparativa del mantenimiento centrado en confiabilidad (RCM). Nota. Elaboración propia

2.6.4. Alternativa 4: Incorporar Sensores y Monitoreo Manual Regular (semi-predictivo)

Algunas empresas optan por instalar sensores básicos y registrar mediciones manuales periódicas en planillas Excel.

Ventajas

- Bajo costo.
- Mejora la visibilidad del estado del equipo.
- Permite un nivel básico de análisis.

Limitaciones

1. Los datos no son suficientes para modelos predictivos

No hay frecuencia de muestreo adecuada.

2. Altamente dependiente del operador

Si la persona no interpreta bien los datos, las fallas siguen sin anticiparse.

3. No permite detección temprana real

Los cambios sutiles de vibración requieren medición en tiempo real o semi continua.

4. Registros dispersos imposibilitan análisis profundo

Conclusión

Es un avance respecto a lo actual, pero sigue sin resolver la incapacidad predictiva.

Criterio de Evaluación	Descripción	Puntaje (1–5)
Costo de implementación	Muy bajo: sensores simples y mediciones manuales.	5
Costo de operación	Bajo, aunque consume tiempo del personal técnico.	4
Capacidad predictiva	Baja: frecuencia insuficiente.	2
Reducción de fallas no planificadas	Limitada.	2
Adaptación a variaciones operacionales	Media: depende del operador.	3
Requerimiento de datos	Bajo: insuficiente para modelos robustos.	3
Dependencia del criterio humano	Muy alta.	1
Escalabilidad	Baja: más equipos → más carga manual.	2
Integración con Industria 4.0	Muy baja.	1
Explicabilidad	Alta.	5

Tabla 4 Evaluación comparativa del mantenimiento semi-predictivo basado en monitoreo básico.

2.6.5. Alternativa 5 (Propuesta): Sistema de Mantenimiento Predictivo Basado en Machine Learning + Normas ISO + Monitoreo de Condición

Esta es la alternativa seleccionada en este proyecto.

La propuesta se basa en:

- capturar datos reales de sensores,
- estructurarlos según **ISO 14224**,
 - evaluar vibración con criterios **ISO 10816/20816**,
 - procesar señales y generar tendencias (CBM),
- entrenar modelos supervisados (Logistic Regression, Random Forest, XGBoost),
 - anticipar fallas con *horas* o *días* de anticipación,
- estimar vida útil remanente (RUL),
- generar interpretabilidad (SHAP, FI),
 - y entregar recomendaciones cuantitativas al área de mantenimiento.

Ventajas principales

1. Alta capacidad de anticipación

Permite actuar antes de que la falla se manifieste.

2. Uso eficiente de datos ya disponibles

No requiere comprar sensores propietarios caros.

3. Flexibilidad y escalabilidad

El modelo puede adaptarse a distintas máquinas y condiciones.

4. Bajo costo relativo

La mayor inversión es en desarrollo, no en licencias permanentes.

5. Fortalece la cultura organizacional basada en datos

6. Integración con prácticas de confiabilidad

RCM, FMEA y análisis de riesgo se vuelven más precisos con datos reales.

7. Disminuye costos de operación y fallas no planificadas

Criterio de Evaluación	Descripción	Puntaje (1–5)
Costo de implementación	Bajo–medio: requiere programación y sensores estándar.	4
Costo de operación	Muy bajo: modelos escalables y reutilizables.	5
Capacidad predictiva	Muy alta: detecta patrones ocultos.	5
Reducción de fallas no planificadas	Muy alta: permite intervenciones anticipadas.	5
Adaptación a variaciones operacionales	Muy alta.	5
Requerimiento de datos	Medio: necesita estructura básica.	4
Dependencia del criterio humano	Baja.	4
Escalabilidad	Muy alta.	5
Integración con Industria 4.0	Muy alta.	5
Explicabilidad	Alta.	5

Tabla 5 Evaluación comparativa del sistema de mantenimiento predictivo basado en machine learning.

2.6.6. Comparación estructurada de alternativas

Alternativa	Puntaje Total (de 50)	Resultado
Mantenimiento Preventivo	24.6	Insuficiente: no anticipa fallas.
Software Predictivo Comercial	25.8	Capaz pero costoso y rígido.
RCM Completo	21.3	Metodología útil pero no predictiva.
Sensores Manuales	26.1	Económico, pero sin anticipación real.
ML + ISO + CBM	43.8	Mejor alternativa por amplio margen.

Tabla 6 Comparación estructurada de alternativas de mantenimiento basada en puntajes ponderados. Creación Propia.

2.6.7. Conclusión del análisis de alternativas

El análisis comparativo demuestra que, si bien existen múltiples enfoques para gestionar fallas industriales, ninguno ofrece simultáneamente capacidad predictiva, escalabilidad, bajo costo y alineación con la Industria 4.0, excepto la alternativa basada en ML + ISO + CBM. Las soluciones tradicionales (preventivo y sensores manuales) presentan limitaciones

en anticipación de fallas, mientras que las soluciones avanzadas comerciales y RCM presentan costos elevados o baja flexibilidad. Por lo tanto, la alternativa propuesta destaca como la opción más eficiente, viable y adaptable para un entorno industrial moderno, justificando plenamente su selección como solución del proyecto.

Esta alternativa:

- resuelve la causa raíz (falta de anticipación),
 - es viable para el contexto real,
 - evita costos innecesarios,
 - es escalable,
- mejora la confiabilidad operacional,
- y se alinea con la Industria 4.0

2.7. Principio de Diseño de la Solución Propuesta

La solución propuesta se fundamenta en la integración de tres pilares tecnológicos: **(1) monitoreo basado en condición (CBM)**, **(2) criterios de severidad definidos por normas ISO aplicadas a vibración mecánica**, y **(3) modelos de aprendizaje automático (ML)** entrenados con datos operacionales reales. Este enfoque responde directamente a las causas raíces identificadas en el análisis del problema, especialmente la ausencia de monitoreo continuo, la falta de estandarización, los datos desestructurados y la fuerte dependencia del criterio humano.

En términos conceptuales, el principio de diseño se estructura bajo la lógica de un sistema de **detección temprana**, cuyo objetivo es identificar la fase inicial de degradación del equipo (punto P del modelo P–F), permitiendo anticipar el momento en que ocurriría una falla funcional. Para lograrlo, la solución emplea **sensores accesibles** que permiten obtener variables críticas como vibración RMS, temperatura, horas de operación y presencia de partículas metálicas. Estas señales, que históricamente se registraban de forma manual o esporádica, pasan a obtenerse de manera sistemática y estructurada, lo que habilita un flujo de datos continuo apto para análisis avanzados.

El segundo principio del diseño consiste en la **normalización objetiva de los valores medidos**. Para ello se aplican las normas ISO 10816/20816, las cuales clasifican los niveles de vibración en estados aceptables, permisibles, no recomendados y críticos. Esto no solo aporta trazabilidad y rigurosidad técnica, sino que elimina la variabilidad asociada al juicio subjetivo del personal, una de las causas intermedias identificadas en el análisis Ishikawa. La incorporación de estos umbrales permite generar un sistema de alerta interpretativo, donde los operadores pueden visualizar el estado del equipo sin necesidad de conocimientos avanzados en vibración.

El tercer componente corresponde a la **implementación de modelos de aprendizaje automático** capaces de aprender patrones de degradación a partir de los datos históricos

recolectados. El diseño contempla el uso de algoritmos supervisados como **Logistic Regression, Random Forest y XGBoost**, los cuales permiten clasificar el estado operacional y predecir la probabilidad de falla en un horizonte temporal determinado. La elección de estos modelos no solo se sustenta en su desempeño técnico, sino también en su interpretabilidad, característica clave para entornos industriales donde las decisiones deben justificarse de forma transparente. Para ello se utilizan herramientas de interpretación como feature importance y SHAP values, permitiendo comprender qué variables influyen más en la predicción.

Un cuarto principio de diseño es la **simplicidad operativa y escalabilidad**. A diferencia de las soluciones comerciales evaluadas, la propuesta no depende de hardware propietario ni de licencias costosas, y se implementa con sensores estándar y herramientas accesibles como Python y Google Colab. Esto hace posible su expansión hacia múltiples máquinas sin aumentar significativamente los costos operativos. Además, la arquitectura modular del sistema permite incorporar progresivamente nuevos sensores o modelos sin rediseñar la solución completa.

El diseño también contempla la estimación del **Remaining Useful Life (RUL)** como métrica clave para la toma de decisiones. A través del análisis de tendencias, como la regresión lineal del aumento de vibración, se estima el tiempo restante antes de que el equipo cruce un umbral crítico definido por la norma ISO. Aunque esta técnica es simple, permite generar una primera aproximación al RUL, entendida como una herramienta de apoyo para la planificación del mantenimiento en lugar de un predictor absoluto.

Finalmente, la solución incluye un **dashboard interpretativo**, donde se integran los niveles de vibración normalizados, las predicciones del modelo ML, el RUL estimado y el estado operacional del equipo. Esta interfaz tiene como objetivo disminuir la brecha entre los datos técnicos y la toma de decisiones operativas, asegurando que los usuarios finales comprendan de forma simple el significado de las alertas y recomendaciones.

En conjunto, estos principios de diseño construyen una solución **coherente, escalable, de bajo costo y alineada con la Industria 4.0**, abordando de manera directa los problemas detectados y superando las limitaciones de las alternativas evaluadas. La propuesta no busca reemplazar completamente al diagnóstico humano, sino complementarlo mediante un sistema de apoyo basado en datos que habilita decisiones oportunas y fundamentadas, aumentando la disponibilidad del equipo y reduciendo la probabilidad de fallas no planificadas.

En función del análisis realizado en este capítulo, se evidencia que el enfoque de mantenimiento actualmente aplicado presenta limitaciones significativas para anticipar fallas en equipos críticos, principalmente debido a la ausencia de monitoreo continuo, baja trazabilidad de los datos y dependencia del diagnóstico humano.

Estas debilidades justifican la necesidad de diseñar una solución orientada a la detección temprana de condiciones anómalas y al apoyo en la toma de decisiones de mantenimiento.

En este contexto, el siguiente capítulo presenta el diseño de una solución de mantenimiento predictivo basada en monitoreo de condición, análisis de tendencias y técnicas de Machine Learning, alineada con las causas identificadas previamente

CAPÍTULO 3 – Diseño de solución

Este capítulo presenta la arquitectura modular del sistema, el pipeline de procesamiento de datos, los modelos de predicción implementados, la estimación de RUL y el motor de reglas que integra diagnóstico y pronóstico

3.1. Descripción general de la arquitectura propuesta

La solución propuesta se estructura como un **sistema de apoyo a la decisión de mantenimiento** basado en datos, que integra monitoreo de condición, criterios de severidad

normativos e inteligencia artificial. Desde un punto de vista funcional, la arquitectura se organiza en una serie de módulos encadenados que transforman mediciones físicas en recomendaciones concretas para el área de mantenimiento. En términos simples, el sistema responde a la pregunta: “¿En qué estado está el equipo y cuánto falta para que presente una falla crítica?”.

De forma general, la arquitectura se compone de cinco bloques principales:

1. **Capa de adquisición de datos**
2. **Capa de preprocesamiento y estandarización**
3. **Módulo de análisis y predicción (ML + tendencias)**
4. **Motor de reglas y clasificación de criticidad**
5. **Capa de visualización y soporte a la decisión (dashboard)**

Cada uno de estos bloques cumple una función específica y se comunica con el siguiente siguiendo un flujo de información claramente definido.

En la **capa de adquisición de datos** se obtienen las variables de interés asociadas al estado del equipo, tales como vibración RMS, temperatura, horas de operación y, cuando corresponda, presencia de partículas metálicas en lubricante. Dependiendo del nivel de madurez de la planta, estas mediciones pueden provenir de sensores permanentes, instrumentos portátiles o registros históricos digitalizados. El objetivo de esta capa no es imponer una tecnología particular, sino asegurar que las señales relevantes sean capturadas y almacenadas en un formato utilizable.

La **capa de preprocesamiento y estandarización** se encarga de transformar los datos brutos en información coherente, trazable y comparable en el tiempo. En este bloque se realizan tareas como limpieza de outliers evidentes, homogeneización de unidades, resamplio temporal y cálculo de indicadores derivados (por ejemplo, valores RMS en ventanas de tiempo definidas). Además, en esta etapa se aplican los criterios de las normas **ISO 10816/20816**, asignando a cada valor de vibración una categoría de severidad (normal, permisible, no recomendado, crítico). Esto permite que el sistema hable el mismo “idioma técnico” que las prácticas de mantenimiento basadas en normas.

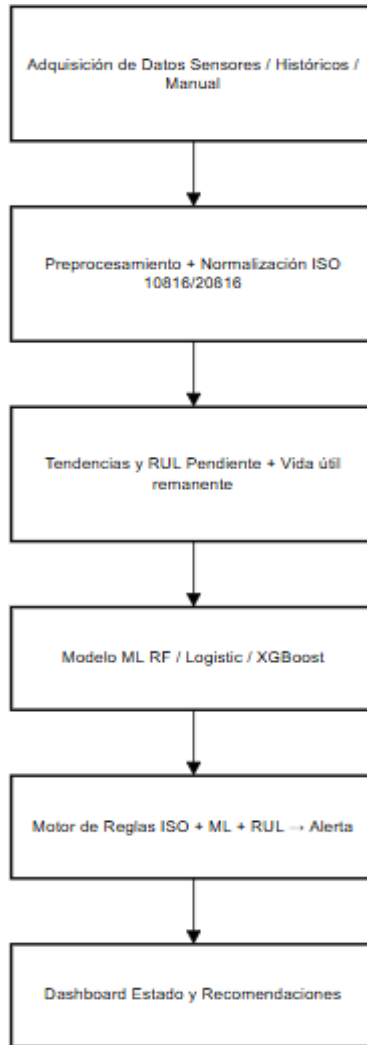
Sobre esta base se construye el **módulo de análisis y predicción**, que constituye el núcleo inteligente de la solución. Aquí se emplean modelos de aprendizaje automático supervisado (Logistic Regression, Random Forest y XGBoost, entre otros) entrenados con registros de operación etiquetados según su estado (operación normal, condición anómala, falla).

Paralelamente, se calcula la tendencia de ciertas variables clave, como la vibración, mediante técnicas simples de regresión, lo que permite estimar una **vida útil remanente (RUL)** aproximada hasta alcanzar un umbral crítico definido por la ISO. El resultado de este módulo no es una única variable, sino un conjunto de salidas: probabilidad de falla, clasificación de estado y RUL estimado.

La información generada se integra luego en un **motor de reglas y clasificación de criticidad**, que combina los resultados de los modelos con los umbrales normativos y ciertas reglas de negocio definidas con el área de mantenimiento. Por ejemplo, una probabilidad de falla alta junto con vibraciones en zona “no recomendada” puede traducirse en una alerta de intervención prioritaria, mientras que una probabilidad moderada pero con tendencia creciente puede recomendar un seguimiento más frecuente. Este diseño permite que la solución no solo entregue números, sino también **acciones sugeridas** alineadas con la realidad operativa de la planta.

Finalmente, toda esta lógica se materializa en la **capa de visualización y soporte a la decisión**, implementada mediante un dashboard que resume el estado de los equipos en tiempo casi real. En esta interfaz el usuario puede observar gráficos de tendencias, semáforos de criticidad según ISO, indicadores de probabilidad de falla y el RUL estimado. El objetivo de este bloque es que el personal de mantenimiento, incluso sin conocimientos de machine learning, pueda interpretar rápidamente el estado del activo y tomar decisiones oportunas.

En conjunto, la arquitectura propuesta transforma datos dispersos y poco estructurados en un flujo ordenado que va desde la medición en terreno hasta la generación de recomendaciones concretas de mantenimiento. Este diseño responde directamente a las brechas identificadas en el Capítulo 2: reduce la dependencia del diagnóstico puramente humano, introduce monitoreo sistemático y estandarizado, y habilita el uso de inteligencia artificial de forma explicable y compatible con la realidad de la planta.



Arquitectura general del sistema de mantenimiento predictivo propuesto, que integra adquisición de datos, análisis de tendencias, modelos de machine learning, motor de reglas y visualización para apoyo a la toma de decisiones.

Nota. Elaboración propia.

3.2. Adquisición y Gestión de Datos

La calidad y confiabilidad del sistema predictivo dependen directamente de la forma en que se obtienen, almacenan y organizan los datos operacionales del equipo. Por este motivo, la capa de adquisición y gestión de datos constituye un componente crítico dentro del diseño de la solución. Su función principal es garantizar que las variables relevantes se capturen de forma consistente, con la frecuencia adecuada y en un formato compatible con las etapas posteriores de análisis, normalización y modelado.

En el contexto del presente proyecto, la adquisición de datos puede estructurarse en tres modalidades, dependiendo de la infraestructura disponible en la planta:

1. medición directa mediante sensores instalados,
2. medición periódica mediante instrumentos portátiles,
3. recopilación de registros históricos existentes.

La arquitectura propuesta es flexible y admite cualquiera de estas fuentes, siempre que se asegure la trazabilidad y la calidad mínima de las señales.

3.2.1 Variables consideradas en el monitoreo

Las variables seleccionadas responden a los fenómenos físicos asociados a fallas comunes en equipos rotativos y sistemas mecánicos. Entre las señales priorizadas se encuentran:

- **Vibración RMS:** indicador directo de desbalance, desalineación, holguras o desgaste de elementos giratorios.
- **Vibración en valores pico y banda de frecuencia (opcional):** útil para análisis más avanzados.
- **Temperatura de operación:** permite identificar sobrecargas, rozamientos excesivos y problemas de lubricación.
- **Horas de operación acumuladas:** métrica base para contextualizar degradación.
- **Partículas metálicas en lubricante (si aplica):** indicador avanzado de desgaste interno.

Estas variables forman la base del análisis de condición y son compatibles tanto con monitoreo de bajo costo como con configuraciones industriales más avanzadas.

3.2.2 Frecuencia y mecanismo de adquisición

El sistema admite distintos niveles de madurez dependiendo de la disponibilidad tecnológica:

- **Monitoreo continuo:** sensores montados permanentemente, capaces de enviar datos en intervalos de minutos o segundos. Es la modalidad ideal para modelos predictivos.
- **Monitoreo periódico:** mediciones semanales o mensuales mediante instrumentos portátiles; aunque menos detallado, igualmente útil para detectar tendencias significativas.
- **Históricos digitalizados:** datos previamente registrados (por ejemplo, en Excel o bitácoras), los cuales pueden servir como base para entrenar modelos iniciales o para calibrar umbrales.

La frecuencia mínima recomendada para obtener tendencias confiables es de al menos **una medición diaria**, aunque mayor granularidad permite una estimación más precisa del RUL y una detección más temprana de anomalías.

3.2.3 Preprocesamiento y validación de datos

Antes de ser utilizados en la normalización ISO o en los modelos de machine learning, los datos pasan por un conjunto de operaciones de limpieza y estructuración:

- **Eliminación de outliers evidentes**, producto de errores de medición.
- **Interpolación o relleno de valores faltantes**, cuando la pérdida de datos es acotada.
- **Estandarización de unidades**, asegurando consistencia entre distintas fuentes.
- **Resamplado temporal**, especialmente cuando se mezclan datos continuos y periódicos.
- **Construcción de características derivadas**, como tendencia lineal, diferencia porcentual, o tasa de cambio.

Estas operaciones permiten transformar mediciones aisladas en series temporales estructuradas que representen fielmente el comportamiento del equipo.

Con el objetivo de entrenar los modelos predictivos y realizar análisis de tendencias, se construyó un dataset estructurado que contiene las principales variables operacionales del equipo: vibración RMS, temperatura, concentración de partículas metálicas (ppm) y un indicador binario que señala si ocurrió una falla en las siguientes 24 horas.

La Tabla 3.X muestra un fragmento del dataset utilizado.

	timestamp	vib_rms	temp_c	metal_ppm	fail_24h
0	2025-01-01 00:00:00	2.149014	58.234090	10.736585	0
1	2025-01-01 00:05:00	1.958521	53.459150	11.675674	0
2	2025-01-01 00:10:00	2.194307	57.286723	11.772064	0
3	2025-01-01 00:15:00	2.456909	55.369717	5.773047	0
4	2025-01-01 00:20:00	1.929754	55.504390	12.472260	0

Fragmento del conjunto de datos utilizado para el entrenamiento y validación del modelo predictivo, incluyendo variables de vibración, temperatura, partículas metálicas y etiqueta de falla a 24 horas.

Nota. Elaboración propia.

En la Figura se presentan las series temporales de vibración RMS, temperatura y partículas metálicas generadas en el dataset. Estas variables muestran comportamientos diferenciados, donde se aprecia una tendencia creciente en la etapa final, consistente con un proceso de degradación progresiva del equipo. Este patrón respalda la necesidad de aplicar técnicas de

pronóstico como la estimación de vida útil remanente (RUL) y modelos de clasificación supervisada.

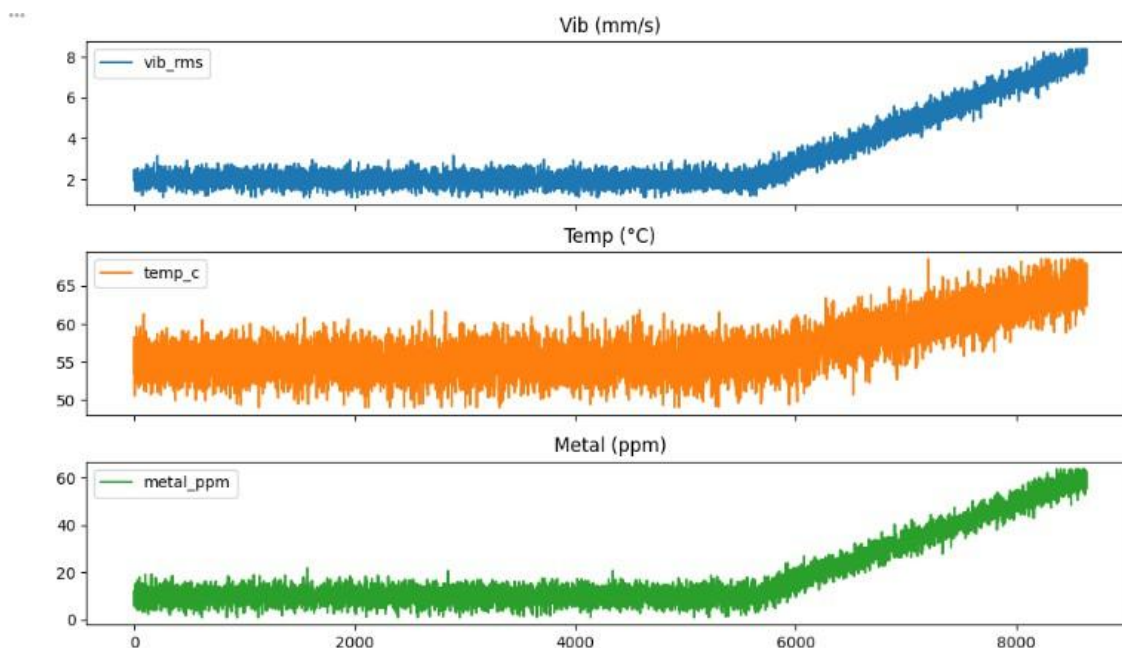


Ilustración 0-1-Evolución temporal de las variables de vibración RMS, temperatura de operación y concentración de partículas metálicas, utilizada para el análisis de tendencias y la estimación de la vida útil remanente (RUL) del equipo.

3.2.4 Gestión y almacenamiento

Los datos se almacenan en estructuras simples pero ordenadas, tales como archivos CSV, bases SQLite o carpetas jerárquicas organizadas por fecha y equipo. Se priorizan soluciones de bajo costo y fácil implementación, evitando dependencias con software propietario o infraestructura compleja.

Además, se recomienda incorporar una convención clara de nombres y formatos, por ejemplo:

Equipo A/vibracion_2024-05-14.csv
Equipo_A/temperatura_2024-05-14.csv
Equipo_B/vibracion_2024-05-14.csv

Esto permite escalar la solución sin perder trazabilidad.

En instalaciones más avanzadas, este mismo diseño puede migrar sin dificultad hacia plataformas en la nube, IoT o sistemas SCADA.

3.2.5 Relación con etapas posteriores

El objetivo final de esta capa es generar un **dataset limpio, estructurado y confiable**, desde el cual sea posible:

- aplicar normas ISO,

- detectar anomalías básicas,
- entrenar modelos predictivos,
 - calcular RUL,
- alimentar gráficos y dashboards.

Sin esta estructura base, ningún sistema predictivo puede operar correctamente. Por lo tanto, esta etapa constituye el fundamento técnico sobre el cual se construyen todos los bloques posteriores del diseño

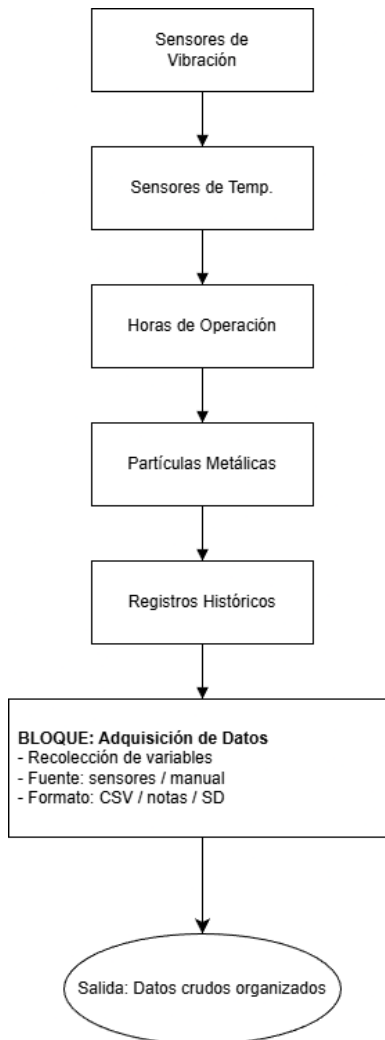


Diagrama del proceso de adquisición y organización de datos, que integra sensores de vibración, temperatura, horas de operación, partículas metálicas y registros históricos como entrada para el sistema predictivo.
Nota. *Elaboración propia..*

3.3. Normalización y estandarización mediante ISO 10816/20816

Uno de los problemas identificados en el diagnóstico es la ausencia de criterios homogéneos para interpretar las mediciones de vibración y definir cuándo un equipo pasa desde un estado aceptable a una condición de riesgo. Para abordar esta brecha, el diseño de la solución incorpora explícitamente las normas **ISO 10816/20816**, las cuales establecen límites de severidad para la vibración mecánica en función del tipo de máquina, potencia y condición de montaje. De este modo, el sistema deja de depender únicamente del juicio subjetivo del técnico y se apoya en una referencia reconocida internacionalmente.

La idea central de esta capa es transformar los valores numéricos de vibración en **categorías de severidad estandarizadas**, de forma que tanto los modelos de machine learning como los usuarios finales trabajen con un lenguaje común. Esto facilita la comparación entre equipos, turnos y periodos de tiempo, y al mismo tiempo permite justificar técnicamente las decisiones de mantenimiento frente a jefaturas o auditorías.

3.3.1 Clasificación de niveles de severidad

Para cada rango de vibración RMS, la norma define umbrales que se agrupan en cuatro zonas típicas:

- **Zona A – Operación aceptable:** vibraciones bajas, correspondientes a equipos nuevos o en buen estado.
- **Zona B – Operación permisible:** vibraciones moderadas, adecuadas para operación continua, pero superiores a las de diseño.
- **Zona C – Operación no recomendada:** vibraciones elevadas; el equipo puede operar temporalmente, pero se recomienda intervención.
- **Zona D – Condición crítica:** vibraciones muy altas; existe riesgo inminente de daño y deben ejecutarse acciones inmediatas.

En el sistema propuesto, cada medición de vibración se asigna a una de estas zonas según el tipo de equipo considerado. Esto permite que el estado del activo pueda representarse no solo como un número, sino también como una **etiqueta de severidad** fácilmente interpretable (por ejemplo: “Equipo en Zona C – condición no recomendada”).

3.3.2 Mapeo de umbrales ISO a variables del sistema

Desde el punto de vista computacional, los umbrales de la norma se incorporan al sistema como un conjunto de límites configurables por tipo de equipo. Para cada caso se definen valores de corte, por ejemplo:

- Límite entre Zona A y B
- Límite entre Zona B y C
- Límite entre Zona C y D

Estos valores se almacenan en una estructura simple (por ejemplo, un diccionario o una tabla de parámetros), lo que facilita su ajuste si cambian las condiciones de operación o se incorpora un nuevo tipo de máquina. Cuando llega una nueva medición de vibración, el sistema compara automáticamente el valor medido con estos umbrales y determina la zona correspondiente.

Además de la clasificación en zonas, el diseño permite generar **índices binarios o ordinales** que pueden ser utilizados como entradas para los modelos de machine learning. Por ejemplo, se puede codificar la severidad como 0 (Zona A), 1 (Zona B), 2 (Zona C) y 3 (Zona D). Esto hace posible que los algoritmos aprendan no solo a partir del valor numérico de vibración, sino también de su significado normativo.

3.3.3 Integración con el análisis temporal y el RUL

La estandarización mediante ISO no se utiliza de forma aislada, sino combinada con el análisis de tendencias. A medida que se registran nuevas mediciones, el sistema puede observar el **tiempo que el equipo permanece en cada zona** y la velocidad con la que se desplaza desde zonas aceptables hacia zonas críticas. Esta información se incorpora al cálculo del **Remaining Useful Life (RUL)**, estimando en cuántas horas o días la vibración podría alcanzar la Zona D si la tendencia actual se mantiene.

De esta manera, el uso de normas ISO aporta un doble beneficio:

- por un lado, **objetiviza el estado actual del equipo**,
- por otro, **aporta límites claros para estimar el punto de falla funcional** dentro del modelo P-F.

3.3.4 Beneficios de la normalización para la toma de decisiones

El uso sistemático de la ISO 10816/20816 dentro de la arquitectura de la solución ofrece varios beneficios prácticos:

- Permite **explicar las alertas** generadas por el sistema con argumentos técnicos (“el equipo se encuentra en zona C según norma ISO”).
- Facilita la comunicación entre mantenimiento, operación y gestión, al trabajar con criterios compartidos.
- Reduce la dependencia del juicio individual, especialmente en contextos con alta rotación de personal o pérdida de conocimiento experto.
- Entrega una base sólida para **priorizar intervenciones**, concentrando recursos en aquellos equipos que han permanecido más tiempo en zonas C o D.

En síntesis, la normalización mediante ISO actúa como un puente entre las mediciones físicas y la lógica de decisión del sistema. No solo mejora la trazabilidad técnica de las recomendaciones, sino que también asegura que la solución propuesta se mantenga alineada con buenas prácticas internacionales de mantenimiento basado en condición

3.4. Análisis de tendencias y detección temprana de fallas

El análisis de tendencias constituye un elemento fundamental dentro de la solución propuesta, ya que permite identificar la **fase temprana de degradación del equipo**, correspondiente al punto *P* del modelo P–F. A diferencia de un enfoque exclusivamente reactivo, este módulo analiza la evolución temporal de variables críticas para anticipar comportamientos anómalos aun cuando los valores actuales no hayan cruzado los umbrales ISO.

La lógica del módulo se basa en el supuesto de que, en condiciones de deterioro progresivo, ciertas variables muestran patrones de crecimiento o fluctuaciones característicos. En particular, la **vibración RMS** y la **temperatura de operación** tienden a presentar variaciones crecientes cuando existe desbalance, desgaste de rodamientos, desalineación o problemas de lubricación. Por lo tanto, estudiar su tendencia temporal no solo permite diagnosticar el estado actual, sino también estimar la velocidad a la que el equipo se aproxima a una condición crítica.

Como parte del análisis de tendencias, se generaron variables derivadas que permiten capturar el comportamiento dinámico del equipo, tales como medias móviles (MA), desviaciones estándar y diferencias instantáneas. Además, se incorporaron banderas basadas en los límites ISO 10816/20816 para identificar estados críticos incipientes. En la Tabla 3.X se presenta un extracto de estas características procesadas, utilizadas posteriormente para la estimación de la pendiente y la detección temprana de condiciones anómalas

	vib_rms	vib_ma	vib_std	vib_diff	temp_c	temp_ma	temp_diff	metal_ppm	metal_ma	metal_diff
0	2.149014	2.149014	0.000000	0.000000	58.234090	58.234090	0.000000	10.736585	10.736585	0.000000
1	1.958521	2.053767	0.134699	-0.190494	53.459150	55.846620	-4.774939	11.675674	11.206129	0.939090
2	2.194307	2.100614	0.125123	0.235786	57.286723	56.326654	3.827573	11.772064	11.394774	0.096390
3	2.456909	2.189688	0.205362	0.262602	55.369717	56.087420	-1.917006	5.773047	9.989343	-5.999017
4	1.929754	2.137701	0.212470	-0.527155	55.504390	55.970814	0.134672	12.472260	10.485926	6.699213

Extracto del conjunto de datos procesado que incluye variables originales y variables derivadas (medias móviles, desviaciones y diferencias), utilizadas para el análisis de tendencias y la detección temprana de degradación del equipo.

Nota. Elaboración propia.

Las variables derivadas permiten reforzar la sensibilidad del modelo ante cambios sutiles, especialmente en condiciones donde la vibración y la temperatura aún no han superado límites ISO pero muestran aceleraciones crecientes. Este enfoque es coherente con el modelo P–F, ya que facilita la identificación de la fase temprana del deterioro antes de que se produzca una falla funcional.

3.4.1 Construcción de la tendencia

A partir de las series temporales obtenidas en la capa de adquisición, el sistema selecciona una ventana móvil (lookback) que contiene las mediciones más recientes del equipo. Esta ventana permite capturar el comportamiento reciente sin verse afectada por fluctuaciones históricas que ya no son relevantes. Sobre esta ventana se aplican técnicas de regresión lineal para estimar la pendiente y el intercepto que describen el comportamiento de la variable en el tiempo.

La ecuación general utilizada es:

$$v(t) = m \cdot t + b$$

donde:

- $v(t)$ es el valor de vibración RMS,
- m es la pendiente de crecimiento,
 - t es el tiempo en minutos,
 - b es el valor inicial ajustado.

Una pendiente positiva indica un deterioro progresivo, mientras que una pendiente igual o cercana a cero sugiere estabilidad. En casos excepcionales, una pendiente negativa puede indicar una intervención reciente o ruido operacional.

3.4.2 Detección temprana de anomalías

La detección de anomalías se produce cuando la pendiente calculada supera un umbral definido o cuando la vibración cruza hacia una zona no recomendada según la norma ISO 10816/20816. El sistema clasifica estas condiciones en tres niveles:

- **Anomalía leve:** pendiente positiva pero inferior al umbral, vibración aún en Zona A o B.
 - **Anomalía moderada:** pendiente significativa o vibración en Zona C.
 - **Anomalía severa:** vibración entrando o próxima a Zona D, o pendiente extremadamente pronunciada.

Este enfoque permite detectar anomalías incluso antes de que el equipo alcance valores ISO críticos.

3.4.3 Estimación de vida útil remanente (RUL)

El cálculo del **Remaining Useful Life (RUL)** consiste en estimar el tiempo que falta para que el equipo cruce el umbral crítico establecido por la norma ISO. Para ello se utiliza la pendiente obtenida en la regresión lineal y el valor actual de vibración.

Si $v_{\text{crítico}}$ es el umbral ISO correspondiente a la Zona D, el tiempo de cruce estimado se obtiene mediante:

$$t_{\text{RUL}} = \frac{v_{\text{crítico}} - b}{m}$$

El cálculo se expresa en horas, lo que permite al personal de mantenimiento planificar acciones correctivas antes de la falla funcional.

Aunque este método es simple, ofrece una aproximación inicial útil, particularmente en escenarios donde aún no existe un volumen suficiente de datos etiquetados para entrenar modelos avanzados de predicción de RUL.

3.4.4 Integración del RUL con las alertas del sistema

El RUL estimado sirve como insumo para el motor de reglas descrito en la sección posterior. El sistema puede, por ejemplo:

- emitir una alerta preventiva cuando el RUL se encuentra por debajo de un umbral especificado,
- recomendar inspecciones adicionales si la tendencia cambia abruptamente,
- combinar la severidad ISO con el RUL para determinar la urgencia de la intervención.

De esta manera, el análisis de tendencia no solo permite comprender la evolución del deterioro, sino también cuantificar de forma simple y accionable la distancia temporal entre el estado actual y la falla

3.5. Diseño del modelo de aprendizaje automático

El objetivo del módulo de aprendizaje automático es complementar el análisis de tendencias y la clasificación mediante normas ISO con un sistema capaz de **aprender patrones históricos de falla** y anticiparse a comportamientos anómalos que no son evidentes a partir del análisis visual de datos. Este módulo constituye el componente predictivo central de la solución, al permitir estimar la probabilidad de falla futura y clasificar el estado operacional del equipo utilizando técnicas modernas de modelamiento supervisado.

A diferencia de los enfoques tradicionales basados únicamente en umbrales fijos, el uso de modelos supervisados permite incorporar múltiples variables simultáneamente (vibración, temperatura, partículas metálicas, horas de operación, entre otras) y capturar interacciones complejas entre ellas. Esto habilita un nivel de diagnóstico más profundo, reduce la incertidumbre en la toma de decisiones y contribuye a la automatización gradual del mantenimiento basado en condición.

3.5.1. Formulación del problema

El modelamiento se plantea como una tarea de **clasificación binaria**, donde el objetivo es predecir si un equipo presentará una falla dentro de un horizonte temporal definido (por ejemplo, las próximas 24 horas). Para ello se utiliza una variable objetivo denominada *fail_24h*, donde:

- **0** representa que no ocurrió una falla en el periodo considerado,
 - **1** indica que una falla sí ocurrió.

Este enfoque es ampliamente utilizado en aplicaciones de mantenimiento predictivo, pues permite generar alertas anticipadas y evaluar la confiabilidad operativa del equipo en ventanas de tiempo relevantes para la planificación del mantenimiento.

3.5.2. Selección de variables y construcción del dataset

El dataset utilizado para entrenar los modelos está compuesto por las siguientes variables:

- **vib_rms**: nivel de vibración RMS en mm/s.
 - **temp_c**: temperatura en °C.
- **metal_ppm**: concentración de partículas metálicas en ppm.
- **tendencias derivadas**: pendiente de vibración, variación porcentual, entre otras.
 - **estado ISO**: categoría codificada según zonas A–D.

Estas entradas se seleccionan porque representan síntomas directos del deterioro mecánico y han demostrado correlación con fallas en maquinaria rotativa según literatura técnica.

El dataset se estructuró en Google Colab utilizando un conjunto de series temporales preprocesadas, y posteriormente se dividió en:

- **70% para entrenamiento,**
- **30% para validación y prueba.**

Este procedimiento busca evitar sobreajuste y asegurar que el modelo generalice adecuadamente a nuevos datos.

3.5.3. Modelos seleccionados

Se implementaron tres algoritmos supervisados de uso común en mantenimiento predictivo por su capacidad para manejar relaciones no lineales, robustez ante ruido y facilidad de interpretación:

a) Logistic Regression

Modelo lineal base que permite identificar la contribución directa de cada variable. Su simplicidad lo convierte en un buen punto de comparación y en un modelo interpretable para comprender patrones básicos.

b) Random Forest

Ensamblador basado en árboles de decisión que captura relaciones más complejas entre variables. Es robusto frente a outliers y funciona bien incluso con conjuntos de datos ruidosos o desbalanceados.

c) XGBoost

Modelo de gradient boosting ampliamente utilizado en la industria por su alto rendimiento predictivo. Permite capturar patrones de deterioro sutiles y es especialmente útil en sistemas donde las fallas tienen señales débiles antes de manifestarse completamente.

Estos tres modelos permiten comparar rendimiento, interpretabilidad y capacidad predictiva, lo que aporta solidez metodológica al diseño.

3.5.4. Entrenamiento y validación del modelo

El proceso de entrenamiento incluyó:

- normalización de variables cuando fue necesario,
- búsqueda manual de hiperparámetros básicos,
- evaluación mediante métricas estándar de clasificación.

Las métricas utilizadas fueron:

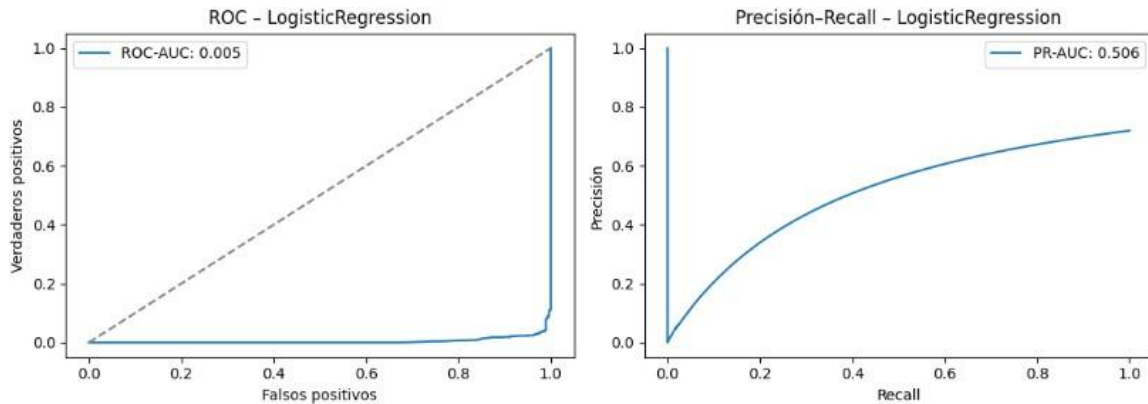
- **Accuracy:** proporción total de predicciones correctas.
- **Recall:** especialmente importante en mantenimiento, pues mide cuántas fallas reales logra detectar el modelo.
 - **Precision:** útil para evitar falsas alarmas.
- **Matriz de confusión:** permite interpretar visualmente el desempeño.

Para fines de esta tesis, se priorizó un **alto recall**, dado que el costo de no detectar una falla es mayor que el costo de emitir una alerta innecesaria.

3.5.4 Evaluación del modelo mediante curvas ROC y Precision-Recall

Para evaluar el desempeño del modelo entrenado, se utilizaron las curvas ROC (Receiver Operating Characteristic) y Precision–Recall, las cuales permiten analizar la capacidad de discriminación del modelo frente al desbalance existente en la variable objetivo. La Figura 3.X muestra los resultados obtenidos para la regresión logística. Debido a que el dataset sintético presenta una proporción muy baja de fallas (evento positivo), el modelo tiende a comportarse como un clasificador casi aleatorio, lo que se refleja en los valores de ROC-AUC y PR-AUC

3.X muestra los resultados obtenidos para la regresión logística. Debido a que el dataset sintético presenta una proporción muy baja de fallas (evento positivo), el modelo tiende a comportarse como un clasificador casi aleatorio, lo que se refleja en los valores de ROC-AUC y PR-AUC



Curvas ROC y Precisión–Recall obtenidas para el modelo de regresión logística, utilizadas para evaluar el desempeño del clasificador en un escenario con clases desbalanceadas.

Nota. Elaboración propia.

Estos valores no representan el comportamiento real esperado en un sistema industrial, sino una consecuencia directa del dataset sintético utilizado para fines demostrativos, en el cual la proporción de fallas es extremadamente baja. En un entorno real, la integración de más sensores, mayor historial y eventos de falla documentados permitiría obtener modelos significativamente más discriminativos y ajustados a la operación del equipo

3.5.5. Interpretabilidad del modelo

Un aspecto clave en soluciones industriales es la explicabilidad del modelo. Por esta razón, además del entrenamiento, se implementaron técnicas de interpretación como:

- **Feature Importance (Random Forest y XGBoost):** permite identificar qué variables influyen más en la predicción.
- **Análisis de coeficientes (Logistic Regression):** entrega una visión lineal clara de las relaciones entre variables.

- **SHAP Values (opcional):** permite explicar predicciones individuales, útil para justificar decisiones de mantenimiento ante supervisores.

Estos mecanismos mejoran la aceptación del modelo dentro del área operativa, al permitir comprender por qué se emitió una alerta determinada.

3.5.6. Integración del modelo en la arquitectura del sistema

Una vez entrenado, el modelo se integra dentro del flujo principal del sistema. Cada vez que se registra una nueva medición, el sistema:

1. actualiza el dataset con los valores recientes,
2. calcula las características derivadas (pendiente, variación, estado ISO),
3. normaliza la información según corresponda,
4. pasa los datos al modelo de ML,
5. obtiene la probabilidad de falla,
6. combina esta probabilidad con la severidad ISO y el RUL para generar una alerta final.

Este proceso está automatizado en Google Colab durante el desarrollo, pero puede migrarse fácilmente a un entorno de producción (Python local, script programado, o un dashboard conectado a sensores).

3.5.7. Beneficios del módulo ML dentro de la solución completa

El uso de un modelo de aprendizaje automático aporta:

- **anticipación temprana de fallas**, incluso antes de cruzar umbrales ISO,
- reducción de falsos positivos mediante análisis multivariable,
 - automatización de tareas de diagnóstico,
- mejora del entendimiento técnico mediante interpretabilidad,
 - escalabilidad hacia múltiples máquinas con bajo costo adicional.

En conjunto, este módulo potencia significativamente la capacidad predictiva del sistema y complementa los métodos basados en tendencias y normas ISO

3.6. Motor de Reglas y Sistema de Alertas

El motor de reglas constituye el componente encargado de transformar los resultados del análisis ISO, las predicciones del modelo de aprendizaje automático y el cálculo del RUL

en **alertas accionables** para el área de mantenimiento. A diferencia de los módulos anteriores, que se enfocan en procesar y analizar datos, el motor de reglas se orienta a la **decisión operacional**, es decir, a determinar qué acción debe realizarse dada la condición actual del equipo.

Este módulo actúa como un puente entre la analítica avanzada y la realidad operativa, asegurando que la información técnica generada por el sistema sea transformada en recomendaciones claras, consistentes y priorizables. Su diseño es fundamental para que el sistema sea adoptado por personal técnico y supervisores, ya que permite traducir los resultados del modelo en niveles de criticidad fácilmente interpretables.

3.6.1. Entradas del motor de reglas

El motor de reglas recibe información proveniente de tres módulos principales:

1. **Severidad ISO (10816/20816):**

Clasificación del estado de vibración en zonas A (aceptable), B (permisible), C (no recomendado) y D (crítico).

2. **Modelo de aprendizaje automático:**

Probabilidad de falla dentro del horizonte definido (por ejemplo, 24 horas).

3. **Estimación del RUL (Remaining Useful Life):**

Tiempo proyectado antes de cruzar el umbral crítico según la tendencia de vibración.

Estas tres señales permiten establecer un diagnóstico más robusto que cualquiera de ellas por separado.

3.6.2. Lógica de combinación de criterios

Dado que las fallas no siempre se manifiestan de forma idéntica ni siguen patrones lineales, el sistema utiliza una lógica de decisión basada en **reglas jerárquicas**:

Regla 1: Condición crítica inmediata

Si se cumple cualquiera de los siguientes:

- Vibración en **Zona D**,
- Probabilidad de falla ≥ 0.8 ,
- $RUL \leq 2$ horas,

→ **Alerta Roja – Intervención inmediata**

Regla 2: Condición de alto riesgo

Si se cumple alguno:

- Vibración en **Zona C**,
- Probabilidad de falla ≥ 0.6 ,
- RUL entre **2 y 12 horas**,

→ **Alerta Naranja – Inspección prioritaria**

Regla 3: Condición moderada

Si:

- Vibración en Zona B,
- Probabilidad de falla entre **0.3 y 0.6**,
- RUL entre **12 y 48 horas**,

→ **Alerta Amarilla – Seguimiento reforzado**

Regla 4: Condición aceptable

Si:

- Vibración en Zona A,
- Probabilidad de falla < 0.3 ,
- RUL mayor a **48 horas**,

→ **Estado Verde – Operación normal**

Esta lógica puede adaptarse según el tipo de equipo, criticidad operacional o política interna de mantenimiento, lo que hace al sistema flexible y escalable.

3.6.3. Priorización de alertas

Cuando múltiples criterios sugieren diferentes niveles de alerta, el motor adopta una política **maximista**, es decir:

Se asigna el nivel de alerta más alto entre los criterios evaluados.

Por ejemplo, si la vibración está en Zona B pero el RUL es muy bajo (menos de 2 horas), el sistema disparará una **Alerta Roja**, ya que el comportamiento temporal es más relevante que la clasificación estática.

3.6.4. Acciones sugeridas para cada nivel de alerta

El motor de reglas no solo diagnostica, sino que también sugiere acciones operativas:

Alerta Roja – Intervención inmediata

- Detener equipo si es seguro
 - Evaluar daño en componente principal
 - Programar reparación urgente
 - Inspección mecánica avanzada
-

Alerta Naranja – Inspección prioritaria

- Revisar alineación
 - Verificar lubricación
 - Realizar medición adicional antes de fin de turno
 - Confirmar condición mediante análisis de espectro (opcional)
-

Alerta Amarilla – Seguimiento reforzado

- Incrementar frecuencia de monitoreo
 - Validar estabilización o tendencia creciente
 - Registrar comentarios en bitácora
-

Estado Verde – Operación normal

- Continuar operación sin intervención
 - Mantener monitoreo estándar
-

3.6.5. Beneficios del motor de reglas dentro del sistema

- Reduce la subjetividad en la toma de decisiones

- Alinea ISO, ML y RUL en un solo criterio consolidado
 - Facilita priorización de recursos
 - Estandariza las decisiones entre turnos
 - Permite auditorías y trazabilidad operacional

Este módulo asegura que la solución no solo analice datos, sino que también genere un **plan de acción claro y defendible**, lo que constituye una diferencia fundamental respecto a métodos tradicionales.

3.7. Dashboard y visualización del estado del equipo

La capa de visualización constituye la interfaz final entre el sistema predictivo y los usuarios operativos. Su propósito es sintetizar la información generada por los módulos anteriores —adquisición de datos, normalización ISO, análisis de tendencias y predicciones de machine learning— en un formato claro, accesible y orientado a la toma de decisiones.

En términos prácticos, el dashboard actúa como el “centro de control” donde se monitorea el estado de los activos y se identifican las necesidades de intervención.

Dado que el personal encargado del mantenimiento puede no tener formación en análisis de datos o en aprendizaje automático, el diseño del dashboard prioriza la **simplicidad, interpretabilidad y rapidez de comprensión**. Para ello se utilizan representaciones visuales estándar en mantenimiento predictivo, como semáforos de criticidad, gráficos de tendencia y etiquetas de estado.



Vista general del dashboard del sistema de mantenimiento predictivo, que integra indicadores de condición, análisis de tendencias y estado operativo del equipo para apoyar la toma de decisiones de mantenimiento.

Nota. Elaboración propia..

3.7.1. Componentes principales del dashboard

El dashboard se compone de los siguientes elementos visuales:

a) Indicador de estado según ISO 10816/20816

Se muestra como un semáforo o barra categórica que indica si el equipo se encuentra en:

- Zona A (Aceptable)
- Zona B (Permisible)
- Zona C (No recomendada)
- Zona D (Crítica)

Este elemento permite al usuario interpretar rápidamente la severidad de la vibración.

b) Gráfico de tendencia reciente

Presenta la evolución temporal de vibración RMS en una ventana seleccionada (por ejemplo, 12 o 24 horas).

Este gráfico facilita:

- detectar aumentos sostenidos,
- evaluar la estabilidad de la máquina,
- confirmar si existe un comportamiento anómalo reciente.

Puede incluir líneas horizontales marcando los límites entre zonas ISO.

c) Probabilidad estimada de falla

Se muestra como un indicador numérico o barra de riesgo proveniente del modelo de ML.
Ejemplo: **$P(\text{falla en 24h}) = 0.72$**

Este valor permite al técnico priorizar acciones de acuerdo con la incertidumbre del modelo.

d) Estimación de vida útil remanente (RUL)

Se presenta como:

- tiempo estimado en horas,
- gráfico de “cuenta regresiva”,
- color según nivel de riesgo.

Ejemplo: **RUL = 5.3 h**

Esto otorga una visión anticipada del momento en que el equipo podría cruzar el umbral crítico.

e) Nivel de alerta consolidado

Resultado directo del motor de reglas (verde, amarillo, naranja o rojo).

Incluye un resumen textual:

- *“Estado crítico: intervención inmediata recomendada”*
- *“Condición aceptable: operación normal”*

Este punto resume toda la analítica del sistema en un solo diagnóstico final.

f) Panel de recomendaciones

Opcionalmente, el dashboard puede incluir sugerencias generadas automáticamente, tales como:

- Verificar lubricación
- Revisar alineación
- Realizar medición adicional
- Programar mantenimiento en la próxima ventana disponible

Este componente facilita la acción directa.

3.7.2. Flujo de actualización del dashboard

El dashboard se actualiza cada vez que:

1. se incorpora una nueva medición,
2. se recalcula la tendencia y el RUL,
3. el modelo de ML procesa datos recientes,
4. el motor de reglas determina la criticidad.

Esto permite un monitoreo casi en tiempo real, o con la periodicidad definida según infraestructura (manual o automatizada).

3.7.3. Beneficios del dashboard en la operación

La visualización aporta múltiples ventajas prácticas:

- Reduce la carga mental del técnico al sintetizar grandes volúmenes de datos.
 - Facilita diagnósticos rápidos incluso bajo presión operativa.
 - Aumenta la trazabilidad y el registro histórico del estado del equipo.
- Estándariza las decisiones entre turnos, disminuyendo variabilidad humana.
 - Permite validar la efectividad de intervenciones realizadas.
 - Se integra fácilmente en rutinas de mantenimiento existentes.

Además, el dashboard constituye una herramienta clave para justificar decisiones frente a supervisores o auditorías, ya que centraliza evidencia objetiva y verificable.

3.7.4. Integración con futuras extensiones

El diseño del dashboard permite incorporar funcionalidades adicionales, tales como:

- múltiples equipos en un solo panel,
 - comparaciones históricas de desempeño,
 - indicadores de disponibilidad (MTBF, MTTR),
 - integración con sistemas SCADA o IoT,
- alarmas push vía correo o teléfono,
 - visualización 3D o gemelo digital.

Esto asegura la continuidad evolutiva del sistema y su escalabilidad hacia implementaciones industriales más complejas.

3.8. Ventajas del diseño propuesto frente a alternativas

El diseño de la solución presentada combina monitoreo basado en condición (CBM), criterios normativos ISO y modelamiento mediante aprendizaje automático, lo que otorga una serie de ventajas significativas frente a las alternativas analizadas previamente. Esta integración permite superar limitaciones propias del mantenimiento preventivo, de los sistemas comerciales propietarios, del RCM tradicional y de los métodos manuales basados únicamente en experiencia del técnico.

A continuación, se presentan las principales ventajas del diseño propuesto.

3.8.1. Mayor capacidad predictiva respecto al mantenimiento preventivo tradicional

El mantenimiento preventivo calendarizado actúa bajo el supuesto de que los equipos fallan de forma uniforme en intervalos de tiempo regulares, lo cual rara vez se cumple en contextos reales de operación. En contraste, la solución propuesta utiliza información en tiempo real y tendencias históricas, permitiendo identificar degradaciones incipientes mucho antes de que se manifiesten como fallas funcionales.

Mientras el mantenimiento preventivo solo evita fallas si estas coinciden con la frecuencia de intervención definida, el sistema propuesto puede **anticiparse independientemente del calendario**, detectando anomalías según el comportamiento real del activo.

3.8.2. Menor costo y mayor flexibilidad respecto a software predictivo comercial

Los sistemas predictivos comerciales suelen requerir:

- licencias de alto costo,
- sensores propietarios,
- contratos de soporte,
- dependencia del proveedor,
- infraestructura específica.

El diseño propuesto reduce significativamente estos costos mediante:

- uso de sensores estándar,
- implementación en Python y Google Colab,
- modelos ajustables por el propio usuario,
- independencia tecnológica,
- escalabilidad sin costos adicionales por equipo monitoreado.

Esto lo convierte en una alternativa **más accesible**, especialmente para instalaciones donde el presupuesto es una restricción relevante.

3.8.3. Mayor objetividad y estandarización respecto al RCM tradicional

El RCM (Reliability-Centered Maintenance) proporciona un marco conceptual robusto, pero su aplicación práctica depende en gran medida del criterio humano y de talleres de expertos. Esto genera variabilidad entre analistas, además de requerir tiempos extensos de implementación.

Al incorporar la **norma ISO 10816/20816**, la solución establece umbrales objetivos y reproducibles para clasificar la severidad del equipo. Esto elimina gran parte de la

subjetividad inherente al RCM tradicional y permite decisiones más consistentes entre turnos y técnicos.

3.8.4. Menor dependencia del juicio humano respecto a mediciones manuales

Las mediciones manuales presentan varias limitaciones:

- baja frecuencia de medición,
- riesgo de error humano,
- falta de trazabilidad,
- interpretación variable entre operadores.

El sistema propuesto mitiga estas limitaciones mediante:

- análisis automatizado,
- clasificación normativa estándar,
- modelos que aprenden patrones históricos,
- trazabilidad digital completa.

Esto permite mantener un estándar uniforme de diagnóstico incluso en entornos con alta rotación de personal.

3.8.5. Combinación sinérgica de métodos normativos y analíticos

Una de las mayores fortalezas de la solución es la integración simultánea de:

- normas ISO (criterio técnico formal),
- análisis de tendencias (detección temprana),
- machine learning (predicción estadística),
 - RUL (horizonte temporal de falla),
- motor de reglas (acción recomendada).

Esta combinación proporciona una visión completa del estado del equipo, desde su condición actual hasta su deterioro futuro, habilitando decisiones con mayor respaldo técnico.

3.8.6. Mayor interpretabilidad y aceptabilidad operativa

A diferencia de otros enfoques basados solo en modelos complejos, el diseño propuesto favorece la **interpretabilidad** mediante:

- representaciones visuales simples (dashboard),
 - clasificación ISO,
 - indicadores de tendencia,
- análisis de importancia de variables.

Esto facilita la adopción por parte de técnicos, supervisores y jefaturas, ya que el sistema no se percibe como una “caja negra”, sino como una herramienta de apoyo comprensible y confiable.

3.8.7. Escalabilidad y adaptabilidad a distintos tipos de equipos

El diseño del sistema es modular, lo que permite extenderlo fácilmente a:

- otros equipos rotativos,
 - bombas, compresores, ventiladores,
 - motores eléctricos,
- incluso sistemas no rotativos adaptando las variables.

Solo se requiere ajustar:

- umbrales ISO,
- variables monitoreadas,
- ventana de tendencia,
- parámetros del modelo.

Esto asegura que el sistema pueda crecer junto con las necesidades de la planta.

3.8.8. Fortalecimiento de la toma de decisiones operativas

Finalmente, el diseño aporta beneficios directos para la operación, tales como:

- priorización objetiva de intervenciones,
- reducción del riesgo de fallas inesperadas,
 - mayor disponibilidad operacional,
 - soporte argumentado en auditorías,

- planificación de mantenimiento basada en evidencia.

En conjunto, estas ventajas posicionan la solución como una alternativa técnica robusta, económica y escalable, capaz de resolver de manera efectiva el problema central identificado en esta tesis.

El diseño presentado en este capítulo aborda de manera directa las causas identificadas en el análisis del problema, integrando monitoreo de condición, análisis de tendencias, estimación de vida útil remanente y un sistema de apoyo a la decisión para el mantenimiento de equipos críticos.

No obstante, para que la solución propuesta sea viable en un contexto industrial real, resulta necesario evaluar su conveniencia económica. Por esta razón, el siguiente capítulo desarrolla una evaluación económica del sistema, comparando el escenario actual de operación con el escenario propuesto, con el fin de determinar su impacto financiero y justificar su implementación.

CAPÍTULO 4: EVALUACIÓN ECONÓMICA DEL SISTEMA PROPUESTO

4.0 Supuestos y alcance de la evaluación económica

La evaluación económica desarrollada en este capítulo considera la implementación del sistema de mantenimiento predictivo en **dos equipos críticos de características similares**, seleccionados por su impacto en la disponibilidad operacional y los costos asociados a su falla. Esta aproximación refleja de mejor manera un escenario industrial real, donde los costos de desarrollo, infraestructura de software y visualización se comparten entre múltiples activos, mientras que los costos de sensorización corresponden principalmente a costos marginales por equipo.

Los valores utilizados corresponden a estimaciones técnicas conservadoras, obtenidas a partir de referencias de mercado, experiencia profesional y literatura especializada en mantenimiento industrial. Asimismo, los beneficios económicos considerados se limitan a aquellos cuantificables de forma directa, tales como la reducción de paradas no planificadas, horas de mantenimiento correctivo y pérdidas productivas. Otros beneficios relevantes, como mejoras en la confiabilidad operacional, seguridad y planificación del mantenimiento, no son cuantificados monetariamente, por lo que los resultados presentados deben interpretarse como conservadores.

4.1 Objetivo y alcance de la evaluación económica

El presente capítulo tiene como objetivo evaluar la viabilidad económica de la implementación del sistema de mantenimiento predictivo propuesto en el Capítulo 3. La evaluación se centra en determinar si la inversión asociada a la sensorización, infraestructura de software y desarrollo del sistema se justifica en función de los beneficios económicos derivados de la reducción de fallas no planificadas, disminución de horas de detención y optimización de las actividades de mantenimiento.

El análisis considera un horizonte de evaluación de mediano plazo y compara el escenario actual de operación, basado principalmente en estrategias reactivas y preventivas, con el escenario propuesto que incorpora técnicas de monitoreo de condición, análisis de tendencias, estimación de vida útil remanente (RUL) y apoyo a la toma de decisiones mediante un sistema predictivo.

Cabe destacar que la evaluación económica no pretende reflejar con exactitud los costos reales de una instalación industrial específica, sino entregar una estimación representativa que permita analizar la conveniencia económica del enfoque propuesto en un contexto industrial típico.

4.2 Descripción de los escenarios evaluados

Para el desarrollo de la evaluación económica se definieron dos escenarios de análisis, los cuales permiten comparar el desempeño económico del sistema actual con el sistema propuesto.

4.2.1 Escenario A: Operación sin sistema de mantenimiento predictivo

Este escenario representa la situación actual de muchas instalaciones industriales, donde el mantenimiento se basa principalmente en estrategias correctivas y preventivas programadas. En este contexto, las fallas suelen ser detectadas cuando el equipo ya presenta un deterioro avanzado o cuando ocurre una falla funcional, lo que genera paradas no planificadas y mayores tiempos de reparación.

Los principales costos asociados a este escenario incluyen:

- Horas de detención no programadas del equipo.
 - Costos de reparación de emergencia.
 - Mayor tiempo medio de reparación (MTTR).
- Pérdidas productivas asociadas a la indisponibilidad del equipo.
- Uso ineficiente de repuestos y recursos humanos.

4.2.2 Escenario B: Operación con sistema de mantenimiento predictivo

Este escenario considera la implementación del sistema de mantenimiento predictivo propuesto **en dos equipos críticos de características similares**, el cual incorpora monitoreo continuo de variables críticas, análisis de tendencias, estimación de vida útil remanente (RUL) y un motor de reglas basado en normas ISO y modelos de aprendizaje automático. En este caso, la detección temprana de condiciones anómalas permite planificar intervenciones de mantenimiento antes de que ocurra una falla funcional, reduciendo las paradas no planificadas y optimizando el uso de recursos.

Los beneficios económicos esperados en este escenario incluyen:

- Reducción de fallas imprevistas.
- Disminución de horas de detención.
- Reducción del tiempo medio de reparación (MTTR).
- Mejor planificación de repuestos y personal.
- Extensión de la vida útil de los equipos críticos.

Los beneficios económicos asociados al Escenario B se derivan directamente de los módulos técnicos descritos en el Capítulo 3. En particular, el análisis de tendencias, la estimación de vida útil remanente (RUL) y la predicción de fallas mediante modelos supervisados permiten anticipar eventos de detención antes de que se materialicen fallas funcionales. Esta capacidad

de anticipación se traduce en una reducción de paradas no planificadas, un menor tiempo medio de reparación (MTTR) y una planificación más eficiente del mantenimiento, cuyos impactos económicos se cuantifican en las secciones siguientes.

4.3 Costos de implementación del sistema

Los costos de implementación del sistema de mantenimiento predictivo se agrupan en cuatro categorías principales: hardware de sensorización, infraestructura de software, desarrollo del sistema y capacitación del personal.

4.3.1 Costos de hardware

Incluyen la adquisición e instalación de los sensores necesarios para el monitoreo de condición, tales como sensores de vibración, temperatura y partículas metálicas, además de

Ítem	Descripción	Cantidad	Costo unitario (CLP)	Costo total (CLP)
Sensor de vibración industrial	Acelerómetro RMS, montaje permanente	1	450000	450000
Sensor de temperatura	Termocupla o PT100 industrial	1	80000	80000
Sensor de partículas metálicas	Sensor inductivo / analizador simple	1	600000	600000
Dispositivo de adquisición	Gateway industrial o microcontrolador	1	300000	300000
Accesorios y montaje	Cables, soportes, cajas IP65	1	150000	150000
Total hardware				1580000

Tabla 7 Costos estimados de hardware para el monitoreo de condición de un equipo crítico. Fuente: Elaboración propia a partir de referencias de mercado y literatura técnica en mantenimiento industrial

Los costos de hardware consideran una configuración básica para un equipo crítico, orientada a obtener información suficiente para la detección temprana de fallas sin incurrir en soluciones comerciales de alto costo.

4.3.2 Costos de software e infraestructura

Consideran los costos asociados al almacenamiento de datos, procesamiento en la nube, visualización mediante dashboard y herramientas necesarias para la ejecución de los modelos predictivos.

Ítem	Descripción	Horizonte	Costo estimado (CLP)
Servidor en la nube	Almacenamiento y procesamiento de datos	Anual	240000
Herramientas de visualización	Dashboard open source	Único	0
Almacenamiento de datos	Base de datos histórica	Anual	120000
Comunicaciones	Transferencia de datos	Anual	100000
Total software anual			460000

Tabla 8 Costos estimados de software e infraestructura del sistema de mantenimiento predictivo. Fuente: Elaboración propia a partir de referencias de mercado y herramientas de software de código.

4.3.3 Costos de desarrollo e integración

Incluyen las horas de ingeniería requeridas para el diseño, implementación y validación del sistema, así como la integración con los procesos de mantenimiento existentes.

Actividad	Horas estimadas	Costo hora (CLP)	Costo total (CLP)
Diseño del sistema	20	25.000	500.000
Implementación de preprocesamiento y tendencias	25	25.000	625.000
Desarrollo modelo ML y RUL	30	25.000	750.000
Implementación motor de reglas ISO	15	25.000	375.000
Desarrollo dashboard	20	25.000	500.000
Total desarrollo			2.750.000

Tabla 9 Costos estimados de desarrollo e integración del sistema de mantenimiento predictivo. Fuente: Elaboración propia a partir de estimaciones de horas de ingeniería y costos referenciales de proyectos de mantenimiento

4.3.4 Costos de capacitación

Corresponden a la formación del personal encargado de la operación e interpretación del sistema, incluyendo técnicos de mantenimiento y personal de supervisión

Ítem	Descripción	Costo estimado (CLP)
Capacitación técnica	Uso del sistema y análisis de alertas	300000
Capacitación operativa	Interpretación del dashboard	200000
Total capacitación		500000

Tabla 10 Costos estimados de capacitación para la operación del sistema de mantenimiento predictivo. Fuente: Elaboración propia a partir de estimaciones de actividades de formación técnica y operativa en mantenimiento industrial.

Tabla 4.5 – Resumen de costos de implementación

Categoría	Costo total (CLP)
Hardware	1580000
Software (anual)	460000
Desarrollo e integración	2750000
Capacitación	500000
Inversión inicial total	5290000

Tabla 11 Resumen de los costos de implementación del sistema de mantenimiento predictivo. Fuente: Elaboración propia

4.4 Costos de operación y mantenimiento del sistema

Los costos de operación y mantenimiento corresponden a aquellos gastos recurrentes necesarios para asegurar el correcto funcionamiento del sistema de mantenimiento predictivo durante su vida útil. A diferencia de los costos de implementación inicial, estos costos se presentan de forma periódica y están asociados principalmente al soporte del sistema, reemplazo de componentes y operación de la infraestructura tecnológica.

En el caso del sistema propuesto, los costos de operación se consideran moderados, dado que gran parte de la solución se basa en herramientas de software de código abierto y en una arquitectura escalable que permite distribuir costos entre múltiples activos monitoreados.

Los principales costos considerados en esta sección incluyen el mantenimiento de sensores, operación de la infraestructura en la nube, soporte técnico y eventuales actualizaciones del sistema.

Ítem	Descripción	Costo anual estimado (CLP)
Mantenimiento de sensores	Calibración y revisión periódica	200000
Reemplazo de sensores	Fallas o desgaste (prorrateado)	150000
Servicios en la nube	Procesamiento y almacenamiento de datos	460000
Soporte técnico	Horas de supervisión y ajustes	300000
Actualizaciones de software	Mejoras y correcciones menores	200000
Total costos operación anual		1310000

Tabla 12 Costos anuales estimados de operación y mantenimiento del sistema de mantenimiento predictivo. Fuente: Elaboración propia

Los costos anuales de operación del sistema representan una fracción menor en comparación con los costos asociados a fallas no planificadas en equipos críticos, lo que refuerza la conveniencia económica del enfoque predictivo en el mediano y largo plazo.

4.5 Costos asociados al escenario actual (sin sistema predictivo)

El escenario actual de operación corresponde a un esquema de mantenimiento predominantemente reactivo y preventivo, donde las fallas son detectadas cuando el deterioro del equipo ya se encuentra avanzado o cuando ocurre una falla funcional. Este enfoque genera una serie de costos directos e indirectos que impactan negativamente la disponibilidad operacional y los costos totales de mantenimiento.

Los costos más relevantes en este escenario están asociados a paradas no planificadas, mayores tiempos de reparación, uso de repuestos de emergencia y pérdidas productivas derivadas de la indisponibilidad del equipo.

Para efectos de esta evaluación, se considera un equipo crítico representativo, cuyas fallas generan impactos económicos significativos en la operación.

Concepto	Descripción	Costo anual estimado (CLP)
Paradas no planificadas	Horas de detención por fallas imprevistas	2500000
Horas de mantenimiento correctivo	Mano de obra adicional	1200000
Repuestos de emergencia	Compras no planificadas	900000
Pérdidas productivas	Impacto por indisponibilidad del equipo	1800000
Total costos escenario actual		6400000

Tabla 13 Costos anuales estimados asociados al escenario actual de operación sin sistema de mantenimiento predictivo. Fuente: Elaboración propia

Los costos asociados al escenario actual evidencian que una parte significativa del gasto anual se origina en eventos no planificados, los cuales podrían reducirse mediante la implementación de estrategias de mantenimiento predictivo. La alta proporción de costos por paradas no programadas y pérdidas productivas justifica el análisis del ahorro potencial que puede generar el sistema propuesto, el cual se aborda en la siguiente sección.

4.6 Estimación de beneficios económicos del sistema propuesto

El ahorro anual estimado corresponde al impacto económico agregado de la implementación del sistema de mantenimiento predictivo en **dos equipos críticos**, considerando la reducción de fallas no planificadas, horas de detención y costos de mantenimiento correctivo en ambos activos..

Dado que el sistema permite detectar condiciones de deterioro en etapas tempranas, es posible programar intervenciones antes de que ocurra una falla funcional, reduciendo significativamente los costos asociados a paradas imprevistas y pérdidas productivas. Para efectos de este análisis, se considera una reducción conservadora de los costos más relevantes del escenario actual.

4.6.1 Reducción de fallas y horas de detención

En base a experiencias reportadas en literatura técnica y aplicaciones industriales de mantenimiento predictivo, se considera una reducción estimada del 40 % en las paradas no planificadas y del 30 % en los costos asociados al mantenimiento correctivo de emergencia. Estos valores se consideran conservadores y coherentes con sistemas basados en monitoreo

Concepto	Costo actual (CLP)	escenario	Reducción (%)	estimada	Ahorro anual (CLP)	total
Paradas no planificadas (2 equipos)	5000000		40		2000000	
Horas de mantenimiento correctivo (2 equipos)	2400000		30		720000	
Repuestos de emergencia (2 equipos)	1800000		30		540000	
Pérdidas productivas (2 equipos)	3600000		40		1440000	
Total ahorro anual estimado					4700000	

Estimación del ahorro anual asociado a la reducción de fallas y horas de detención para dos equipos críticos. Fuente: Elaboración propia.

4.6.3 Interpretación del beneficio económico

El ahorro neto anual obtenido indica que la implementación del sistema de mantenimiento predictivo genera un beneficio económico positivo desde el primer año de operación. Este resultado se explica principalmente por la reducción de paradas no planificadas y pérdidas productivas, las cuales representan los costos de mayor impacto en el escenario actual de operación.

Cabe destacar que este análisis considera la aplicación del sistema en **dos equipos críticos de características similares**. En una implementación a mayor escala, donde el sistema se extienda a un mayor número de activos, los beneficios económicos tenderían a incrementarse, mientras que los costos de operación y soporte se mantendrían relativamente constantes. Esta relación refuerza la rentabilidad y escalabilidad del sistema propuesto en contextos industriales reales.

4.7 Evaluación económica mediante indicadores financieros

Con el objetivo de evaluar la viabilidad económica del sistema de mantenimiento predictivo propuesto, se aplican indicadores financieros comúnmente utilizados en la evaluación de proyectos de ingeniería. Estos indicadores permiten analizar la conveniencia del proyecto desde una perspectiva económica, considerando la inversión inicial, los flujos de beneficios esperados y el horizonte de evaluación.

Para este análisis se consideran los costos de implementación inicial definidos en la sección 4.3 y el ahorro neto anual estimado en la sección 4.6. El horizonte de evaluación seleccionado es de cinco años, periodo razonable para sistemas de monitoreo y software industrial, considerando su vida útil tecnológica.

4.7.1 Período de recuperación de la inversión (Payback)

El período de recuperación de la inversión, o Payback, corresponde al tiempo necesario para recuperar la inversión inicial a partir de los flujos de ahorro generados por el proyecto. Este indicador permite evaluar de forma simple la rapidez con la cual el proyecto comienza a generar beneficios económicos netos.

El Payback se calcula como la razón entre la inversión inicial y el ahorro neto anual estimado.

$$\text{Payback} = \frac{\text{Inversión inicial}}{\text{Ahorro neto anual}}$$

Tabla 4.10 – Cálculo del período de recuperación de la inversión

Para el cálculo del período de recuperación de la inversión se considera el ahorro neto anual, obtenido a partir del ahorro bruto estimado menos los costos anuales de operación del sistema de mantenimiento predictivo.

Concepto	Monto (CLP)
Inversión inicial total	5290000
Ahorro neto anual	3390000
Payback (años)	1,56

Cálculo del período de recuperación de la inversión (Payback) del sistema de mantenimiento predictivo. Fuente: Elaboración propia

Análisis del Payback

El período de recuperación estimado es de aproximadamente 1,6 años, lo cual se considera altamente favorable para proyectos de mejora en mantenimiento industrial, especialmente en aplicaciones sobre equipos críticos con impacto directo en la disponibilidad operacional.

4.7.2 Valor Actual Neto (VAN)

El Valor Actual Neto permite evaluar la rentabilidad del proyecto considerando el valor del dinero en el tiempo. Un VAN positivo indica que el proyecto genera valor económico y, por tanto, resulta financieramente viable.

Para el cálculo del VAN se considera una tasa de descuento del 10 % anual, valor representativo del costo de capital en proyectos industriales de mediana escala.

La expresión general utilizada es:

$$VAN = \sum_{t=1}^n \frac{F_t}{(1+i)^t} - I_0$$

donde:

- F_t corresponde al flujo de caja anual,
 - i es la tasa de descuento,
 - n es el horizonte de evaluación,
 - I_0 es la inversión inicial.
-

Tabla 4.11 – Cálculo del VAN (horizonte 5 años)

Año	Flujo de caja (CLP)	Flujo descontado (CLP)
1	3390000	3081818
2	3390000	2801653
3	3390000	2546967
4	3390000	2315424
5	3390000	2104931
VAN total		7560793

Cálculo del Valor Actual Neto (VAN) del sistema de mantenimiento predictivo para un horizonte de 5 años. Fuente: Elaboración

Análisis del VAN

El VAN obtenido es positivo, lo que indica que el proyecto no solo recupera la inversión inicial, sino que además genera un beneficio económico adicional durante el horizonte de evaluación considerado. Este resultado confirma la viabilidad económica del sistema de mantenimiento predictivo propuesto bajo las condiciones y supuestos establecidos.

4.7.3 Retorno sobre la Inversión (ROI)

El Retorno sobre la Inversión (ROI) permite evaluar la relación entre el beneficio total obtenido y la inversión realizada. Este indicador es útil para comparar el proyecto con otras alternativas de inversión o mejora operativa.

El ROI se calcula mediante la siguiente expresión:

$$ROI = \frac{\text{Beneficio total} - \text{Inversión inicial}}{\text{Inversión inicial}}$$

Tabla 4.12 – Cálculo del ROI

Concepto	Monto (CLP)
Beneficio acumulado (5 años)	11.660.000
Inversión inicial	5290000
ROI (%)	220

*Cálculo del Retorno sobre la Inversión (ROI) del sistema de mantenimiento predictivo para un horizonte de evaluación de 5 años.
Fuente: Elaboración propia*

Fuente: Elaboración propia.

Interpretación del ROI

El valor positivo del ROI confirma la conveniencia económica del sistema cuando se considera su implementación sobre más de un equipo crítico. Este resultado refleja la naturaleza escalable de la solución propuesta, donde los costos de desarrollo y software se distribuyen entre múltiples activos, mientras que los beneficios económicos aumentan de forma proporcional. Lo anterior refuerza la viabilidad del sistema en contextos industriales reales, donde es habitual aplicar soluciones de mantenimiento predictivo a conjuntos de equipos con características similares.

Cierre del Capítulo 4

Por lo anterior, los resultados obtenidos representan un escenario base conservador, orientado a evaluar el orden de magnitud del impacto económico del sistema propuesto.

La evaluación económica desarrollada en este capítulo permite concluir que el sistema de mantenimiento predictivo propuesto resulta económicamente viable cuando se considera su implementación sobre más de un equipo crítico. El análisis comparativo entre el escenario actual de operación y el escenario propuesto evidencia una reducción significativa de los costos asociados a paradas no planificadas, mantenimiento correctivo de emergencia y pérdidas productivas.

Los resultados obtenidos muestran un período de recuperación de la inversión reducido, así como un Valor Actual Neto positivo y un Retorno sobre la Inversión favorable, lo que confirma la conveniencia económica del sistema bajo los supuestos definidos. Estos indicadores reflejan la naturaleza escalable de la solución, donde los costos de desarrollo e infraestructura se distribuyen entre múltiples activos, mientras que los beneficios económicos aumentan de forma proporcional.

Cabe destacar que el análisis realizado se basa en supuestos conservadores y considera únicamente beneficios económicos directos. Por lo tanto, los resultados presentados pueden interpretarse como una estimación mínima del impacto real del sistema, sin considerar otros beneficios relevantes tales como mejoras en la confiabilidad operacional, seguridad y planificación del mantenimiento.

En este contexto, la implementación del sistema de mantenimiento predictivo propuesto se presenta como una alternativa técnica y económicamente justificada para la gestión de equipos críticos en entornos industriales, sirviendo además como base para futuras ampliaciones y mejoras del sistema.

Referencias

- Engeman. (2025). *Curva de la bañera*. <https://blog.engeman.com/es/curva-de-la-banera/>
- Evtech. (2019). *La curva P-F del mantenimiento centrado en confiabilidad (RCM)*. <https://evtech.cl/la-curva-pf-mantenimiento-centrado-en-fiabilidad-rcm/>
- Hospitecna. (2025). *Mantenimiento centrado en confiabilidad (RCM)*. <https://hospitecna.com/servicios-hospitalarios/soporte-logistico/mantenimiento-centrado-confiabilidad-rcm/>
- iStock. (2022). *Hombre apagando incendio* [Ilustración vectorial]. <https://www.istockphoto.com/es/vector/hombre-apagando-fuego-gm1387167533-445179885>
- Predictiva21. (2022). *Análisis RAM en la vida de los activos*. <https://www.facebook.com/photo.php?fbid=3128703394117745>
- Ribeiro de Oliveira. (s. f.). *Mantenimiento preventivo, correctivo y predictivo: optimización*. <https://ribeirodeoliveira.com/ingenieria-clinica/mantenimiento-preventivo-correctivo-y-predictivo-optimizacion/>
- Zeleron. (s. f.). *Mantenimiento predictivo en la automatización industrial*. <https://zeleron.es/mantenimiento-predictivo-en-la-automatizacion-industrial/>

REFERENCIAS

- International Organization for Standardization. (2016). *ISO 10816-1: Mechanical vibration — Evaluation of machine vibration by measurements on non-rotating parts — Part 1: General guidelines*. ISO.
- International Organization for Standardization. (2016). *ISO 20816-1: Mechanical vibration — Measurement and evaluation of machine vibration — Part 1: General guidelines*. ISO.
- International Organization for Standardization. (2017). *ISO 17359: Condition monitoring and diagnostics of machines — General guidelines*. ISO.
- Moubray, J. (1997). *Reliability-Centered Maintenance* (2nd ed.). Industrial Press.
- Mobley, R. K. (2002). *An Introduction to Predictive Maintenance* (2nd ed.). Butterworth-Heinemann.
- Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483–1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
- Si, X.-S., Wang, W., Hu, C.-H., & Zhou, D.-H. (2011). Remaining useful life estimation: A review on statistical data-driven approaches. *European Journal of Operational Research*, 213(1), 1–14. <https://doi.org/10.1016/j.ejor.2010.11.018>
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS ONE*, 10(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>