


UNIVERSIDAD TECNICA FEDERICO SANTA MARIA

DEPARTAMENTO DE INDUSTRIAS

VALPARAISO – CHILE



**“INTELIGENCIA ARTIFICIAL EN LA GESTIÓN DE ACTIVOS:
INNOVACIONES Y DESAFÍOS**

GABRIEL HERNÁN VÁSQUEZ SAN MARTÍN

**TRABAJO FINAL PARA OPTAR AL GRADO DE
MAGÍSTER EN GESTIÓN DE ACTIVOS Y MANTENIMIENTO**

PROFESOR GUÍA

: SR. RAÚL STEGMAIER BRAVO

OCTUBRE 2024



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: Inteligencia artificial en la gestión de activos: innovaciones y desafíos

Nombre del candidato(a): Gabriel Vásquez San Martín

Carrera / Grado: Magíster en Gestión de Activos y Mantenimiento

Campus: Santiago Vitacura ; **Departamento:** Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Raúl Stegmaier Bravo, 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: 25/09/25; Firma: _____

Estudiante o Candidato(a):

Fecha: 24-09-25 ; 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.

Resumen Ejecutivo

La industria minera enfrenta actualmente importantes desafíos relacionados con la eficiencia operativa, la reducción de costos y la disponibilidad técnica de sus equipos críticos. En este contexto, el presente trabajo analiza la aplicación de la inteligencia artificial (IA) como herramienta estratégica para optimizar la gestión de activos en un molino SAG (Semi-Autógeno) perteneciente a la planta concentradora de Minera Candelaria, ubicada en la región de Atacama, Chile.

El estudio toma como base datos técnicos reales del molino SAG de dicha operación, que cuenta con una capacidad de procesamiento de 45.000 toneladas por día, accionamiento Gearless de 12.5 MW y sistema de automatización Siemens SIMATIC. La investigación contempla la evaluación del estado actual del activo, la identificación de tecnologías de IA aplicables, el diseño de un modelo predictivo de mantenimiento, y la proyección del impacto operativo y económico asociado a su implementación.

Los resultados esperados incluyen una reducción del 20 % en los tiempos de inactividad no programados, una disminución del 25 % en los costos anuales de mantenimiento, y un incremento del 6 % en la eficiencia operativa (OEE). Asimismo, se presentan los principales proveedores internacionales de soluciones de IA en gestión de activos y los desafíos técnicos y organizacionales que enfrentan en contextos industriales complejos como el minero. Finalmente, se proponen planes de acción y estrategias de mejora que integran tecnología, capacitación y cambios estructurales, con el objetivo de consolidar una gestión de activos basada en datos, anticipación y confiabilidad.

ÍNDICE

Resumen Ejecutivo	1
ÍNDICE	3
1. Introducción	4
1.1. Descripción de la problemática	6
1.2. Objetivos y alcance	8
Objetivo general	8
Objetivos específicos	8
1.3. Alcance.....	8
2. Metodología	10
3. Desarrollo del tema.....	14
3.1. La inteligencia artificial como herramienta en la gestión de activos	14
3.1.1. Arquitectura tecnológica para mantenimiento predictivo	15
3.1.2. Recolección, preparación y gobernanza de datos.....	21
3.1.3. Plataformas tecnológicas para mantenimiento predictivo.....	23
3.1.4. Modelado predictivo y simulación aplicada al molino SAG.....	31
3.1.5. Construcción de escenarios comparativos y estrategias de mejora	35
3.1.6. Gestión del cambio y barreras organizacionales en la adopción de IA	38
3.2. Arquitectura de integración tecnológica: PCS7 y MindSphere	43
3.3. Modelado predictivo y simulación aplicada al molino SAG	45
Capítulo 4. Conclusiones y recomendaciones	48
Capítulo 5. Plan de acción, presupuesto y hoja de ruta final	52
5.1. Planificación escalonada de la implementación de IA.....	52
5.2. Matriz de costos estimados (CAPEX/OPEX)	53
5.3. Cronograma con responsables e indicadores clave (KPIs).....	56
Bibliografía.....	59
ANEXOS.....	61

1. Introducción

La industria minera global se encuentra en una etapa crítica de transformación tecnológica, impulsada por la necesidad urgente de incrementar la productividad, reducir los costos operativos y elevar la confiabilidad de sus activos físicos. En este escenario, la inteligencia artificial (IA) emerge como una herramienta estratégica para transitar desde enfoques tradicionales de mantenimiento hacia modelos predictivos avanzados, orientados a la toma de decisiones basada en datos (Zheng et al., 2020). Esta transición cobra especial relevancia en el caso de los molinos SAG (Semi-Autógenos), cuya operación eficiente es determinante para el rendimiento global de las plantas concentradoras.

La relevancia de estos activos queda en evidencia al considerar que el proceso de molienda representa entre un 40 % y un 50 % del consumo energético total de una planta de procesamiento, siendo el molino SAG el componente más demandante en términos de energía y criticidad operativa (Ghasemi et al., 2023). En la minería del cobre, particularmente en Chile, este desafío se acentúa debido a la creciente dureza de los minerales extraídos, los mayores costos unitarios y la necesidad de mantener márgenes competitivos en un mercado global volátil.

A nivel nacional, Chile mantiene su posición como el principal productor mundial de cobre, con una participación del 27,1 % de la producción global en 2023, alcanzando 5,3 millones de toneladas métricas finas (Cochilco, 2024). Según datos del Servicio Nacional de Geología y Minería (SERNAGEOMIN, 2023), el parque de activos mineros del país está compuesto por más de 80 plantas de procesamiento, muchas de las cuales operan con molinos SAG de gran escala, expuestos a condiciones de desgaste severo, cargas dinámicas elevadas y exigencias de operación 24/7. La confiabilidad de estos activos resulta, por tanto, clave para la continuidad operacional y la eficiencia económica de las faenas.

En este contexto, Minera Candelaria —ubicada en la región de Atacama y operada por Lundin Mining— cuenta con un molino SAG de 11 metros de diámetro, 5,4 metros de longitud y una capacidad de procesamiento de 45.000 toneladas por

día. Este equipo está equipado con un sistema de accionamiento Gearless (GMD) de 12,5 MW, desarrollado por Siemens, y opera con una disponibilidad mecánica superior al 92 % anual. No obstante, en el periodo 2023–2024 se registraron 12 fallas mayores, con un costo de mantenimiento que superó los USD 1,2 millones, de los cuales el 60 % correspondió a mantenimiento correctivo. Además, el tiempo de inactividad no planificado se estimó en un 8 % del total operativo.

Casos documentados en la industria chilena refuerzan la necesidad de anticipar estas fallas. Por ejemplo, en junio de 2025, la compañía Teck Resources debió detener su molino SAG en la mina Carmen de Andacollo durante aproximadamente un mes debido a una falla no prevista, lo que implicó pérdidas económicas y ajustes logísticos en toda la cadena de procesamiento. Estas situaciones evidencian el impacto crítico que una sola interrupción puede tener sobre la producción, incluso en operaciones altamente tecnificadas.

Diversos estudios científicos han demostrado que la aplicación de IA en la gestión de activos puede reducir hasta un 30 % los costos de mantenimiento y mejorar significativamente la disponibilidad operativa (Abdelrahman et al., 2023; Arroyave-Tobón et al., 2021). Además, el mantenimiento predictivo basado en algoritmos de machine learning permite anticipar el comportamiento de los componentes mecánicos, reduciendo la necesidad de paradas correctivas y optimizando la planificación de recursos (Wang et al., 2020).

Este trabajo de tesina busca contribuir al conocimiento aplicado de la gestión de activos en minería mediante la evaluación del uso de IA en un caso real: el molino SAG de Minera Candelaria. La investigación comprende un diagnóstico técnico del equipo, la revisión de tecnologías IA disponibles, el diseño de un modelo predictivo y la proyección del impacto operativo y económico de su implementación. Con ello, se pretende entregar una propuesta técnica fundamentada que permita mejorar la confiabilidad, eficiencia y sostenibilidad de la operación, alineada con los desafíos del sector minero en la era digital.

1.1. Descripción de la problemática

En la industria minera, los equipos críticos como los molinos SAG concentran una alta proporción del riesgo operativo, debido a su relevancia en la cadena de procesamiento y a su elevada exposición al desgaste mecánico, vibraciones y fluctuaciones en la carga de trabajo. A pesar de la adopción de sistemas de automatización y monitoreo en tiempo real en muchas plantas concentradoras, la gestión del mantenimiento en estos activos continúa presentando desafíos significativos en cuanto a anticipación de fallas, asignación eficiente de recursos y reducción de tiempos de inactividad no programados (Arroyave-Tobón et al., 2021).

El molino SAG de Minera Candelaria, por sus características técnicas — diámetro de 11 m, capacidad de procesamiento de 45.000 tpd y accionamiento Gearless de 12,5 MW— constituye un caso representativo de las complejidades que enfrenta el mantenimiento de activos en operaciones de gran escala. Según datos internos verificados y actualizados al periodo 2023–2024, este equipo registró una frecuencia de 12 fallas mayores en el año, con un costo asociado superior a USD 1,2 millones, de los cuales el 60 % correspondió a mantenimiento correctivo. Adicionalmente, se reportó un 8 % de tiempo de inactividad no planificado, lo cual representa una pérdida estimada de más de 130 horas operativas anuales, afectando la continuidad de producción y el cumplimiento de metas de procesamiento.

La situación descrita se ve agravada por la limitada capacidad predictiva de los sistemas actuales, los cuales, aunque permiten monitoreo de condiciones mediante sensores, carecen de algoritmos capaces de anticipar eventos de degradación o comportamientos anómalos de manera oportuna y fiable. Esto se traduce en una dependencia excesiva del juicio humano, en diagnósticos retrospectivos y en una planificación que, en muchos casos, no responde a criterios basados en datos reales ni tendencias de comportamiento del equipo.

Asimismo, estudios recientes advierten que la mayoría de las operaciones mineras aún gestionan sus programas de mantenimiento bajo esquemas semiautomáticos o preventivos fijos, lo cual no permite aprovechar el potencial de

tecnologías de inteligencia artificial y aprendizaje automático para optimizar la toma de decisiones (Zheng et al., 2020; Abdelrahman et al., 2023). Esto resulta especialmente problemático en contextos como el chileno, donde las plantas deben operar en condiciones extremas de temperatura, con alta humedad salina, carga variable de mineral y una demanda constante de disponibilidad.

En términos estratégicos, esta problemática no solo impacta en la productividad, sino también en la sostenibilidad financiera y en la seguridad operacional. El no contar con una herramienta de diagnóstico predictivo avanzada incrementa el riesgo de fallas catastróficas, pérdidas de producción, accidentes laborales y mayores costos de reemplazo de piezas críticas como trunnions, revestimientos o cojinetes.

Por tanto, el reto consiste en evolucionar desde una gestión correctiva y parcialmente preventiva, hacia un modelo predictivo basado en IA que permita anticipar con mayor precisión las condiciones que preceden a una falla, optimizar el uso de recursos técnicos y humanos, y fortalecer la confiabilidad de activos de alto valor como el molino SAG. Este desafío no es menor, ya que requiere inversión tecnológica, adaptación organizacional y validación técnica, pero su abordaje es clave para mantener la competitividad del sector en el actual contexto de transición tecnológica y exigencia de eficiencia operativa.

1.2. Objetivos y alcance

Objetivo general

Analizar y evaluar la aplicación de inteligencia artificial en la gestión de activos del molino SAG de Minera Candelaria, con el fin de identificar tecnologías, diseñar un modelo de implementación predictiva, y proponer estrategias que optimicen su eficiencia operativa, disponibilidad y mantenimiento.

Objetivos específicos

1. Evaluar el estado actual del molino SAG en términos de desempeño técnico, costos de mantenimiento y frecuencia de fallas.
2. Investigar las tecnologías de inteligencia artificial disponibles en el mercado que pueden aplicarse a la gestión de activos mineros.
3. Desarrollar un modelo de implementación de IA aplicable al molino SAG, considerando integración con sistemas existentes.
4. Simular el impacto operativo y económico de las tecnologías seleccionadas mediante análisis de costo-beneficio.
5. Proponer un plan de acción y mejora continua, orientado a la adopción sostenible y eficiente de IA en el proceso de mantenimiento.

1.3. Alcance

El presente estudio se circunscribe al análisis técnico-aplicado de la implementación de inteligencia artificial (IA) en la gestión de activos de un molino SAG (Semi-Autógeno) perteneciente a la planta concentradora de Minera Candelaria, ubicada en la región de Atacama, Chile. El foco específico está puesto en el molino SAG principal, con un diámetro de 11 metros y un sistema de accionamiento Gearless de 12,5 MW, debido a su criticidad operativa dentro del proceso de molienda y su influencia directa sobre la eficiencia del sistema global de procesamiento.

La investigación se enmarca en un nivel de análisis meso y operativo, abordando variables técnicas como tiempo medio entre fallas (MTBF), tiempo medio de reparación (MTTR), disponibilidad mecánica, eficiencia global del equipo (OEE) y costos de mantenimiento. Se opta por una perspectiva predictiva y estratégica de la gestión de activos físicos, tal como proponen Normas ISO 55000 y estudios recientes sobre mantenimiento inteligente (Crespo Márquez, 2020; Wang et al., 2020).

El alcance se limita a:

- El **activo específico** molino SAG (excluye otros activos como molinos de bolas, bombas, chancadores o celdas de flotación).
- La **etapa de simulación y evaluación técnica** del modelo predictivo, sin alcanzar la fase de implementación real.
- El uso de **datos técnicos y operativos históricos**, junto con insumos cualitativos provenientes de entrevistas a personal técnico de la operación.

No se consideran dentro del alcance aspectos ambientales, financieros externos, contratos de servicio, decisiones de inversión a gran escala ni impactos sobre el sistema de control global de la planta. Asimismo, se excluyen variables relacionadas con la comercialización del mineral, logística minera o mercados internacionales, por exceder el ámbito técnico de la presente tesina.

La propuesta metodológica se basa en estudios de caso, revisión de literatura científica y benchmarking de soluciones tecnológicas específicas para minería, siguiendo los lineamientos recomendados por autores como Ghasemi et al. (2023) y Parida et al. (2015), quienes destacan la necesidad de acotar los modelos predictivos a entornos controlables, para garantizar su efectividad, interpretabilidad y escalabilidad.

Tampoco se pretende generalizar los resultados obtenidos a otros contextos productivos o industriales, sino establecer un modelo de aplicación puntual para el caso chileno estudiado, que sirva como insumo para futuras validaciones empíricas

o escalamiento tecnológico (Abdelrahman et al., 2023). El enfoque metodológico adoptado —descriptivo, no experimental y aplicado— permite establecer proyecciones cuantificables del impacto operativo y económico de la IA en la gestión de mantenimiento, pero no reemplaza una validación empírica en condiciones reales de operación.

En resumen, el estudio se limita a la formulación, evaluación y propuesta de un modelo predictivo de mantenimiento basado en inteligencia artificial, diseñado específicamente para el molino SAG de Minera Candelaria, utilizando datos reales, referencias científicas actualizadas y una aproximación práctica orientada a la toma de decisiones estratégicas.

2. Metodología

La presente investigación adopta un **enfoque mixto** (cuantitativo-cualitativo) con un **diseño metodológico no experimental**, de tipo **descriptivo-aplicado**, orientado a comprender, caracterizar y proponer soluciones técnicas para la gestión de activos críticos en un caso específico: el molino SAG de Minera Candelaria, Chile. Esta elección metodológica responde a la necesidad de integrar la **analítica de datos operacionales** con el **diagnóstico organizacional** para evaluar el impacto potencial de la inteligencia artificial (IA) en el mantenimiento predictivo (Crespo Márquez, 2020; Ríos & Serrano, 2022).

Desde la perspectiva **cuantitativa**, el estudio se fundamenta en datos históricos del molino SAG, incluyendo indicadores como **historial de fallas**, **MTBF**, **MTTR**, **OEE**, **consumo energético**, **vibraciones** y **costos de mantenimiento**. Esta información permitirá construir un **modelo exploratorio de predicción de fallas** basado en **machine learning**, que será validado sobre series de datos reales o, cuando falten registros, con datos simulados técnicamente realistas derivados de parámetros públicos de operación.

En la dimensión **cualitativa**, se aplicarán **entrevistas semiestructuradas** y **observación directa** para obtener la perspectiva de operadores, ingenieros de

mantenimiento y responsables de planificación, permitiendo identificar barreras organizacionales, oportunidades de mejora y la viabilidad de adopción de modelos basados en IA (Yin, 2018).

Metodológicamente, la investigación se alinea con el **paradigma pragmático** (Tashakkori & Teddlie, 2010), que combina técnicas cuantitativas y cualitativas priorizando la utilidad práctica del conocimiento. La **triangulación metodológica** fortalece la validez interna al integrar datos históricos, simulaciones técnicas y percepciones expertas (Saunders et al., 2019).

El diseño del estudio es **aplicado-descriptivo**: busca describir la situación actual, modelar posibles mejoras y **proyectar escenarios de optimización** sin implementar cambios industriales en planta, en línea con los principios de la **ISO 55000** sobre gestión de activos (ISO, 2014).

Fase 1. Diagnóstico del estado actual del molino SAG

Objetivo específico: Evaluar el estado actual del molino SAG, identificando indicadores críticos de desempeño, vulnerabilidades operativas y costos asociados.

Diseño metodológico: Se recopilan datos técnicos-operacionales y se revisan informes históricos para caracterizar la condición actual del activo y establecer la línea base.

Técnicas e instrumentos:

- Revisión documental: informes técnicos, reportes de fallas, manuales de operación y KPIs (MTBF, MTTR, disponibilidad, costos).
- Entrevistas semiestructuradas: con ingenieros de mantenimiento y operadores para identificar causas recurrentes de fallas.
- Observación directa: análisis visual in situ o mediante registros digitales de operación.

Resultado esperado: Diagnóstico integral que justifique la necesidad de implementar estrategias basadas en IA para reducir fallas y optimizar la gestión de activos.

Fase 2. Investigación de tecnologías de IA aplicables

Objetivo específico: Identificar tecnologías, plataformas y modelos de IA aplicables a la gestión predictiva del molino SAG.

Diseño metodológico: Se realiza una revisión sistemática de literatura científica y benchmarking tecnológico con proveedores líderes.

Técnicas e instrumentos:

- Revisión bibliográfica: artículos de Scopus, ScienceDirect, Redalyc y Scielo sobre mantenimiento predictivo, gemelos digitales y machine learning.
- Benchmarking tecnológico: análisis de plataformas como **Siemens MindSphere**, **IBM Maximo**, **Uptake** y **ABB Ability™**.
- Consultas con expertos: ponencias en Expomin, ChileMin y casos reales reportados en CODELCO y BHP.

Resultado esperado: Selección de al menos tres soluciones de IA viables técnica y económicamente, con análisis comparativo de ventajas y limitaciones.

Fase 3. Desarrollo y validación exploratoria de un modelo predictivo

Objetivo específico: Diseñar y validar un **modelo exploratorio de predicción de fallas** basado en machine learning, sin llegar a implementación industrial.

Diseño metodológico: Se construye un modelo funcional alimentado con datos históricos y simulados, evaluando su capacidad predictiva sobre 12 eventos de falla registrados en 2023–2024.

Técnicas e instrumentos:

- **Preparación de datos:** series de vibración, temperatura, consumo energético, tiempos de operación y fallas.
- **Entrenamiento del modelo:** uso de algoritmos supervisados (**Árboles de Decisión, Random Forest, XGBoost**) con la librería scikit-learn en **Python**.
- **Validación estadística:** métricas como *accuracy*, *recall*, *precision*, *F1-score* y matriz de confusión.

Resultado esperado: Prototipo de modelo predictivo capaz de anticipar fallas con métricas evaluadas. Si la precisión no es concluyente, los resultados servirán como insumo base para proyectar escenarios futuros y proponer mejoras.

Fase 4. Construcción de escenarios comparativos y estrategias de mejora

Objetivo específico: Evaluar el impacto potencial de integrar IA en la gestión de activos, construyendo escenarios comparativos “con IA” vs. “sin IA”. El propósito no es demostrar resultados concluyentes en planta, sino **simular de manera exploratoria el posible impacto operativo y económico**, bajo supuestos basados en datos históricos, validación del modelo y benchmarking internacional.

Diseño metodológico: Se realizará un análisis de escenarios determinístico, fundamentado en la proyección de indicadores como costos, disponibilidad y frecuencia de fallas. Las simulaciones se sustentan en:

datos históricos del molino SAG en el periodo 2023–2024;

salidas del modelo predictivo entrenado en entorno exploratorio;

referencias comparativas de la literatura y casos industriales (CODELCO, BHP, Rio Tinto).

Técnicas	e	instrumentos:
• Comparación de escenarios: Escenario A (gestión actual) vs. Escenario B (gestión proyectada con IA). • Análisis costo-beneficio: relación entre inversión tecnológica y reducción de fallas estimada. • Hoja de ruta de adopción: propuesta escalonada a 6, 12 y 18 meses, con KPIs, responsables y gestión de riesgos.		

Resultado esperado: Estimación plausible de beneficios potenciales (reducción de fallas, ahorro en costos y mejoras en disponibilidad), condicionada a la efectividad de la gestión del cambio y a la adopción tecnológica. Este resultado constituye una **proyección exploratoria**, útil como referencia para justificar un piloto industrial y orientar decisiones estratégicas, pero no equivale a una validación empírica en condiciones operativas reales.

3. Desarrollo del tema

3.1. La inteligencia artificial como herramienta en la gestión de activos

En la última década, la implementación de **inteligencia artificial (IA)** en la gestión de activos físicos ha transformado los modelos de mantenimiento en industrias críticas como la minería, la energía y la manufactura. Las operaciones modernas enfrentan el desafío de optimizar recursos, reducir fallas y aumentar la disponibilidad de equipos en contextos cada vez más exigentes y competitivos. En Chile, la minería aporta el **8,9 % del PIB nacional** y representa cerca del **55 % de las exportaciones** (Cochilco, 2024), lo que obliga a las compañías a maximizar la eficiencia de sus activos estratégicos para sostener su competitividad.

La aplicación de IA permite evolucionar de un modelo **reactivo o preventivo** a un modelo **predictivo y prescriptivo**, donde las decisiones sobre intervenciones no dependen únicamente de programas de mantenimiento planificados o de la experiencia empírica, sino de **patrones reales de desgaste, condiciones operativas y riesgos asociados** (Abdelrahman et al., 2023). De acuerdo con un estudio de AspenTech (2023), la integración de IA con sensores IoT y plataformas SCADA puede reducir en **20–35 % los costos de mantenimiento** y aumentar la disponibilidad de activos críticos en **10–20 %**.

A continuación, se detalla un marco integral para la implementación de IA en la gestión de activos del **molino SAG de Minera Candelaria**, considerando la arquitectura tecnológica, los procesos de preparación de datos, las plataformas disponibles y los factores organizacionales necesarios para garantizar su adopción exitosa.

3.1.1. *Arquitectura tecnológica para mantenimiento predictivo*

La implementación de IA en la gestión de activos requiere una **arquitectura tecnológica escalable**, que permita integrar datos provenientes de distintas fuentes y analizarlos en tiempo real para tomar decisiones informadas. En el caso del molino SAG, esta arquitectura combina tres niveles:

a) Nivel de sensorización IoT

- Sensores de vibraciones de alta resolución (p.ej., **SKF CMPT 2310**) instalados en trunnions y cojinetes principales.
- Cámaras termográficas infrarrojas para monitorear temperaturas críticas en motores y accionamientos.
- Medidores de torque, consumo energético y presión interna.
- Sensores de desgaste de revestimientos internos mediante ultrasonido.

b) Nivel de control y automatización

- Integración con el sistema **PCS7 de Siemens**, que gestiona en tiempo real variables de velocidad, carga y potencia.
- Recolección de datos en buses industriales basados en protocolos OPC-UA y Modbus, compatibles con los equipos existentes.
- Plataforma SCADA para visualización y control supervisado.

c) Nivel de analítica avanzada

- Plataformas de machine learning y big data que permiten procesar series temporales provenientes de sensores.
- Integración con sistemas ERP como **SAP o Maximo**, que centralizan la gestión de activos, inventarios y costos.

Estudios recientes muestran que una arquitectura correctamente integrada permite capturar y procesar **más de 5.000 variables por minuto** en tiempo real, lo que incrementa la capacidad predictiva de los modelos de mantenimiento (Ghasemi et al., 2023). La implementación de un modelo de mantenimiento predictivo en el molino SAG de Minera Candelaria requiere la integración de la infraestructura de automatización existente con una plataforma avanzada de análisis basada en la nube. Actualmente, la operación utiliza PCS7 de Siemens como sistema central de control distribuido (DCS), encargado de supervisar las variables críticas del molino, como velocidad, torque, consumo energético, temperatura y vibraciones. Sin embargo, PCS7, si bien recopila datos de alta frecuencia en tiempo real, no posee capacidades nativas de análisis predictivo avanzado.

Para potenciar esta infraestructura, se propone la integración con Siemens MindSphere, la plataforma de Internet de las Cosas (IoT) industrial basada en la nube, diseñada específicamente para el análisis avanzado de datos y la optimización de operaciones. Esta integración permite que los datos recolectados por los sensores IoT instalados en el molino SAG se transmitan de forma segura y continua desde PCS7 hacia MindSphere mediante protocolos industriales estandarizados como OPC UA y Profinet.

Una vez en MindSphere, los datos son almacenados, procesados y analizados utilizando algoritmos de machine learning desarrollados para detectar patrones anómalos, anticipar fallas potenciales y optimizar la planificación del mantenimiento. Este flujo bidireccional de información permite que, además de generar alertas predictivas y dashboards en tiempo real, el modelo pueda retroalimentar a PCS7 para activar secuencias automáticas, como reducción de carga, ajustes en la velocidad de giro o priorización de intervenciones correctivas.


El uso de MindSphere no solo reduce los costos de integración gracias a su compatibilidad nativa con la arquitectura PCS7, sino que también proporciona ventajas estratégicas clave:

- **Analítica avanzada en la nube:** Permite procesar grandes volúmenes de datos históricos y en tiempo real para alimentar modelos de predicción de fallas.
- **Escalabilidad tecnológica:** La plataforma puede integrar futuros equipos y sensores sin necesidad de rediseñar la infraestructura existente.
- **Visualización interactiva:** Ofrece dashboards dinámicos y personalizables que muestran métricas operativas críticas, como OEE, MTBF y MTTR.
- **Integración con ecosistema industrial:** MindSphere puede conectarse con plataformas ERP como SAP para optimizar la gestión de repuestos, presupuestos y recursos humanos.

En términos operativos, esta integración permitirá que Minera Candelaria avance hacia un modelo de mantenimiento basado en condición (CBM), donde las decisiones sobre intervenciones no se fundamenten únicamente en cronogramas estáticos, sino en datos reales que reflejen el estado actual y proyectado del molino SAG. Esto incrementará la confiabilidad del activo, reducirá las paradas no planificadas y optimizará los costos totales de mantenimiento.

La Figura 1 ilustra la arquitectura propuesta para la integración entre el sistema de control **Siemens PCS7** y la plataforma **Siemens MindSphere** en el marco de la gestión predictiva del molino SAG de Minera Candelaria. El esquema

muestra el flujo de datos desde la adquisición mediante sensores IoT de alta resolución, pasando por la supervisión en tiempo real a través del sistema PCS7, hasta su procesamiento avanzado en la nube mediante algoritmos de **machine learning**. Además, se visualiza la interacción entre las distintas capas —captura, control, analítica y visualización— que permiten transformar los datos operativos en conocimiento accionable, facilitando decisiones estratégicas basadas en evidencia.



La implementación de un sistema de mantenimiento predictivo para el molino SAG en Minera Candelaria requiere una arquitectura tecnológica robusta que integre de forma eficiente los datos generados en terreno con plataformas analíticas avanzadas. En este contexto, la interacción entre el sistema de control existente **Siemens PCS7** y la plataforma de inteligencia industrial **Siemens MindSphere** constituye el núcleo de la estrategia propuesta. Esta integración permite transformar la información operacional en conocimiento accionable, optimizando la toma de decisiones y aumentando la disponibilidad del equipo crítico.

El proceso comienza en la capa de adquisición de datos, donde el molino SAG cuenta con un sistema de sensorización IoT de alta resolución que recopila

información en tiempo real sobre parámetros clave para la operación. Los acelerómetros instalados en los trunnions y cojinetes principales capturan datos de vibración de alta frecuencia, mientras que las cámaras termográficas infrarrojas permiten monitorear continuamente las temperaturas críticas del motor y los accionamientos. De forma complementaria, los medidores de torque, caudal y consumo energético ofrecen una visión detallada del comportamiento dinámico de la máquina, y los sensores ultrasónicos controlan el desgaste de los revestimientos internos. La confiabilidad del modelo predictivo depende de la calidad y consistencia de estas mediciones, ya que cualquier error en la adquisición puede distorsionar la interpretación de los patrones de falla (Wang et al., 2020).

Toda esta información converge en la capa de control y supervisión, gestionada por el sistema **PCS7**, que centraliza, procesa y almacena los datos provenientes de los sensores. Este sistema permite ejecutar rutinas de control automático, visualizar en tiempo real variables críticas de operación y activar respuestas inmediatas ante condiciones anómalas, como sobrecargas o aumentos inesperados de temperatura. Además, PCS7 actúa como interfaz principal entre los equipos de terreno y las plataformas analíticas, transmitiendo la información hacia **MindSphere** mediante protocolos industriales estandarizados. Este enlace asegura una comunicación bidireccional en la que los datos fluyen desde la planta hacia la nube y, en retorno, las alertas y recomendaciones generadas por el modelo predictivo pueden visualizarse directamente en la interfaz de operación.

En la capa analítica, la plataforma **Siemens MindSphere** procesa los datos recibidos desde PCS7 y aplica modelos avanzados de **machine learning** entrenados con información histórica del molino SAG. Los algoritmos seleccionados, tales como **Random Forest**, **XGBoost** y redes neuronales de tipo feed-forward, permiten identificar patrones complejos y anticipar fallas con horizontes de predicción que pueden alcanzar entre 24 y 96 horas. Este enfoque basado en datos transforma la estrategia de mantenimiento, pasando de un modelo preventivo tradicional a un modelo predictivo, donde las intervenciones se programan según la condición real del activo y no en función de calendarios fijos.

La plataforma, además, permite realizar simulaciones de escenarios para evaluar el impacto técnico y económico de diferentes estrategias de gestión, proyectando la reducción de fallas críticas, la optimización de la disponibilidad y los ahorros potenciales en costos de mantenimiento (Abdelrahman et al., 2023).

El último nivel de la arquitectura lo conforma la capa de visualización y toma de decisiones, donde los resultados generados por el modelo predictivo son presentados en tableros interactivos y reportes dinámicos. Estos paneles permiten acceder a indicadores clave como **MTBF** (tiempo medio entre fallas), **MTTR** (tiempo medio de reparación) y **OEE** (eficiencia global del equipo), además de mapas térmicos, análisis históricos de tendencias y proyecciones de desempeño. La disponibilidad de esta información en tiempo real facilita la planificación de intervenciones y promueve una mayor alineación entre los equipos de mantenimiento, operación y gestión estratégica, asegurando que las decisiones técnicas estén respaldadas por evidencia cuantitativa confiable (ISO, 2014).

La elección de **Siemens MindSphere** como plataforma prioritaria para Minera Candelaria se justifica por su compatibilidad nativa con PCS7, que minimiza la necesidad de integraciones costosas y complejas, reduciendo el tiempo de implementación y los riesgos asociados. Además, su arquitectura modular permite incorporar funcionalidades adicionales, como analítica prescriptiva o integración con gemelos digitales, lo que otorga un carácter escalable y adaptable a la solución planteada (Ghasemi et al., 2023). Por último, MindSphere ofrece soporte especializado para entornos mineros que utilizan sistemas de accionamiento Gearless Mill Drive (GMD), como el presente en la planta, lo que fortalece aún más su pertinencia técnica.

En síntesis, la integración entre PCS7 y Siemens MindSphere constituye un modelo avanzado de gestión de activos que combina sensorización de alta precisión, control en tiempo real y analítica predictiva en una misma arquitectura operativa. Este enfoque permite anticipar fallas, optimizar recursos y aumentar la disponibilidad del molino SAG, alineando la operación con los objetivos estratégicos de reducción de costos y maximización de la productividad. Además, al garantizar

la trazabilidad de datos y la reproducibilidad de resultados, la propuesta contribuye directamente al cumplimiento de los estándares internacionales establecidos por la **ISO 55000** para la gestión eficiente del ciclo de vida de los activos.

3.1.2. Recolección, preparación y gobernanza de datos

La gestión de activos industriales, especialmente en equipos de alta criticidad como los molinos SAG, depende en gran medida de la **calidad, integridad y oportunidad de los datos** recopilados. Antes de entrenar cualquier modelo de inteligencia artificial, es fundamental establecer un proceso estructurado para la recolección, depuración y validación de la información operativa. Esta fase constituye la base sobre la cual se construye todo el modelo predictivo, ya que un sistema de análisis es tan confiable como los datos que lo alimentan (Wang et al., 2020).

En el caso del molino SAG de **Minera Candelaria**, la primera etapa implica la **consolidación de datos provenientes de múltiples fuentes internas**. Entre ellas se incluyen los registros históricos de fallas documentados en el **sistema de gestión de mantenimiento computarizado (CMMS)**, los indicadores clave de desempeño (KPI) como **MTBF** (tiempo medio entre fallas) y **MTTR** (tiempo medio de reparación), además de datos de producción, consumo energético y parámetros operacionales recopilados por el sistema **PCS7 de Siemens**. Esta diversidad de fuentes hace necesario integrar datos heterogéneos, ya que, por ejemplo, los registros de fallas suelen estar estructurados en formatos tabulares, mientras que las lecturas de vibraciones o temperaturas son series temporales con alta frecuencia de muestreo.

Una vez recolectada la información, se lleva a cabo un **proceso de preparación de datos**, que incluye tres pasos clave: depuración, normalización y enriquecimiento. En primer lugar, la depuración consiste en eliminar registros incompletos, inconsistentes o duplicados. Por ejemplo, se identifican lecturas atípicas de temperatura que podrían haberse producido por errores de

sensorización o cortes eléctricos, evitando que distorsionen los patrones reales de comportamiento del equipo. En segundo lugar, la normalización busca **homogeneizar las escalas y unidades de medida** para que los algoritmos puedan interpretar correctamente las variables. Así, variables como “vibración en mm/s” y “torque en kNm” se transforman en escalas comparables, asegurando la coherencia en el análisis. Finalmente, el enriquecimiento permite complementar la base de datos con información adicional, como condiciones ambientales de la planta, variaciones en la dureza del mineral procesado o intervenciones de mantenimiento correctivo, lo que aporta contexto al modelo predictivo (Abdelrahman et al., 2023).

En esta etapa también cobra especial relevancia la **gobernanza de datos**, entendida como el conjunto de políticas, estándares y procedimientos que aseguran que la información sea **accesible, confiable y segura** durante todo el ciclo de vida del proyecto. En entornos industriales, la gestión de la trazabilidad es crítica: cada lectura de sensor, cada registro de intervención y cada evento de falla debe estar correctamente identificado, fechado y vinculado a su fuente original. De esta manera, se garantiza que los resultados obtenidos por el modelo puedan auditarse y reproducirse en cualquier momento, lo que incrementa la confiabilidad y validez de las conclusiones (ISO 55000, 2014).

Por otra parte, la integración de sistemas de **sensores IoT de alta resolución** requiere establecer protocolos de comunicación estandarizados. En el molino SAG, por ejemplo, los datos de vibraciones se capturan mediante acelerómetros triaxiales instalados en los cojinetes principales, mientras que las temperaturas críticas del motor y los accionamientos son monitoreadas en tiempo real mediante cámaras termográficas infrarrojas. Toda esta información se transmite al sistema SCADA, que centraliza las lecturas y las envía hacia plataformas analíticas como **MindSphere** o **SAP Predictive Maintenance**, donde los algoritmos de machine learning procesan y correlacionan millones de registros en cuestión de segundos.

No obstante, la recolección de grandes volúmenes de datos plantea desafíos importantes. Entre los más comunes se encuentran los problemas de **consistencia**

entre diferentes equipos, las lagunas de información durante paradas no planificadas y la latencia en la sincronización de los sensores. Para mitigar estos riesgos, es recomendable aplicar técnicas de **detección de valores atípicos** y algoritmos de imputación que permiten estimar los datos faltantes basándose en tendencias históricas o modelos de predicción probabilística (Ghasemi et al., 2023).

Finalmente, la preparación de los datos no termina con su limpieza, sino que también incluye el diseño de una **arquitectura de almacenamiento robusta y escalable**. En el caso de Minera Candelaria, la información operacional se organiza en un **data lake centralizado** que permite combinar datos históricos de alta resolución con información en tiempo real. Esta arquitectura no solo optimiza la gestión de los datos actuales, sino que también facilita futuras integraciones con nuevas fuentes, como sensores adicionales o sistemas de optimización energética.

En síntesis, la correcta recolección, preparación y gobernanza de los datos constituye el núcleo de cualquier modelo de inteligencia artificial aplicado a la gestión de activos. Si los datos no son fiables, completos y bien estructurados, incluso los algoritmos más sofisticados pueden generar predicciones imprecisas. Por esta razón, se requiere establecer procesos claros, trazables y validados para garantizar la solidez de los resultados y la replicabilidad de los hallazgos en otros contextos industriales similares.

3.1.3. Plataformas tecnológicas para mantenimiento predictivo

En los últimos años, la minería ha experimentado una transición acelerada hacia modelos de gestión de activos basados en datos, impulsada por los avances en inteligencia artificial (IA), sensores IoT y plataformas integradas de análisis predictivo, y es este cambio el que responde a un desafío común en las operaciones mineras modernas: reducir el tiempo de inactividad no planificado, optimizar los recursos y extender la vida útil de equipos críticos como los molinos SAG. En este escenario, las plataformas tecnológicas de mantenimiento predictivo se han consolidado como herramientas fundamentales, permitiendo capturar información

en tiempo real, procesarla mediante algoritmos de machine learning y generar alertas tempranas que mejoran la toma de decisiones estratégicas (Abdelrahman et al., 2023; Wang et al., 2020).

Entre las soluciones disponibles, destacan cinco plataformas líderes con aplicaciones comprobadas en el sector industrial y minero: Siemens MindSphere, IBM Maximo APM, Uptake Fusion, Aspen Mtell y ABB Ability™. Aunque todas tienen enfoques distintos, comparten una característica central: la integración de modelos de IA con ecosistemas industriales que combinan sistemas SCADA, sensores IoT y módulos de análisis avanzado.

En el caso de Siemens MindSphere, su diseño se centra en aprovechar al máximo la infraestructura digital existente en plantas industriales que operan con tecnología Siemens. Esto es particularmente relevante para Minera Candelaria, donde el molino SAG utiliza el sistema de automatización PCS7 y el accionamiento SINAMICS GH180 Gearless Mill Drive (GMD). Esta compatibilidad nativa reduce los costos de integración, simplifica la configuración inicial y garantiza una sincronización precisa de datos en tiempo real. MindSphere combina redes neuronales profundas y arquitecturas híbridas de machine learning para predecir patrones de desgaste, detectar anomalías y generar alertas automáticas integradas en dashboards dinámicos. Además, cuenta con aplicaciones específicas para minería que permiten monitorear vibraciones, temperatura, torque y consumo energético, variables críticas en la operación de molinos SAG (Siemens, 2023).

Por otro lado, IBM Maximo Application Suite (APM) se posiciona como una plataforma orientada a modelos cognitivos y aprendizaje automático para el análisis integral de activos. Su principal fortaleza radica en la interoperabilidad: puede integrarse con SAP, sistemas SCADA y plataformas IoT heterogéneas, ofreciendo mayor flexibilidad en contextos de infraestructura mixta. En minería, Maximo ha demostrado resultados sólidos, como en un proyecto piloto implementado en Chile en 2022, donde se logró una reducción del 18 % en los costos de mantenimiento y un aumento del 12 % en la disponibilidad de equipos críticos. Sin embargo, la implementación de Maximo en Minera Candelaria implicaría mayores tiempos de

integración y la necesidad de adaptar interfaces con PCS7, lo que elevaría los costos iniciales en comparación con MindSphere (Deloitte, 2023).

Uptake Fusion representa otra alternativa innovadora. Su arquitectura combina modelos basados en Random Forest y XGBoost con capacidades de análisis probabilístico avanzado. Esta plataforma está diseñada para integrarse con sistemas ERP y múltiples fuentes IoT, permitiendo correlacionar información operacional con datos de gestión de inventarios y órdenes de trabajo. En Brasil, Uptake ha sido implementada por una operación minera de hierro, logrando una reducción del 21 % en fallas recurrentes en equipos de molienda primaria, gracias a la detección temprana de anomalías en vibraciones y sobrecargas. A pesar de estos resultados positivos, la plataforma presenta limitaciones al trabajar con sistemas de automatización Siemens, lo que podría requerir adaptadores adicionales para su implementación eficiente en Candelaria (Arroyave-Tobón et al., 2021).

En el caso de Aspen Mtell, desarrollada por AspenTech, el enfoque se centra en la construcción de modelos prescriptivos. A diferencia de los sistemas puramente predictivos, Mtell no solo anticipa las fallas, sino que también recomienda acciones específicas para prevenirlas. Esta característica ha sido clave en casos como el de BHP en Australia, donde la aplicación de Aspen Mtell sobre sistemas de molienda permitió aumentar en un 14 % el tiempo medio entre fallas (MTBF) y reducir en un 17 % los costos asociados al mantenimiento no planificado. No obstante, su implementación requiere una inversión inicial considerable, dado que se basa en licencias modulares y procesos de integración complejos, lo que puede limitar su adopción en operaciones donde ya existe un ecosistema Siemens consolidado (Ghasemi et al., 2023).

Finalmente, ABB Ability™ ha sido ampliamente utilizado en operaciones de CODELCO en Chile, particularmente en la División Andina. Esta plataforma combina árboles de decisión y analítica multisensorial para gestionar activos de alta criticidad en plantas de chancado y molienda. Los resultados reportados incluyen una disminución del 15 % en las fallas críticas y un aumento del 10 % en la eficiencia

energética global de la operación. ABB Ability™ ofrece una arquitectura escalable y flexible, pero presenta un mayor nivel de complejidad en términos de compatibilidad con sistemas preexistentes que dependen de PCS7 y SINAMICS, como es el caso de Minera Candelaria (SERNAGEOMIN, 2023).

El análisis comparativo entre estas plataformas permite concluir que Siemens MindSphere es la opción más viable para el proyecto. No solo garantiza compatibilidad inmediata con la infraestructura actual, sino que también minimiza los riesgos técnicos y económicos asociados a la implementación. Además, su capacidad de integrarse con sensores IoT, sistemas SCADA y módulos de analítica avanzada lo convierte en un entorno ideal para desarrollar modelos predictivos aplicados al molino SAG. Esta decisión estratégica responde a criterios de costo, escalabilidad y tiempo de adopción, alineándose con las mejores prácticas recomendadas por la ISO 55000 en cuanto a gestión basada en datos y optimización del ciclo de vida de los activos industriales (ISO, 2014).

En este sentido, la elección de MindSphere no se limita a una cuestión de eficiencia técnica, sino que sienta las bases para futuras integraciones con soluciones avanzadas, como gemelos digitales, dashboards de mantenimiento prescriptivo y sistemas de inteligencia operativa que podrían extenderse al resto de la planta concentradora. Así, la implementación de esta plataforma constituye un pilar fundamental para el diseño del modelo predictivo que se desarrolla en el siguiente apartado, donde se detallan los algoritmos, los datos históricos y las simulaciones aplicadas al caso de estudio.

En el contexto de la minería moderna, la implementación de modelos de inteligencia artificial (IA) para mantenimiento predictivo exige no solo contar con datos de alta calidad, sino también con plataformas tecnológicas capaces de integrarlos en tiempo real con los sistemas de control industrial. Actualmente, diversas soluciones comerciales compiten en el mercado, ofreciendo arquitecturas flexibles y modelos de aprendizaje automático que permiten anticipar fallas, optimizar la disponibilidad de equipos y reducir costos operativos (Abdelrahman et al., 2023; Wang et al., 2020).

En la evaluación comparativa realizada para Minera Candelaria, se analizaron cinco de las plataformas más utilizadas en minería y gestión de activos industriales:

Plataforma	Proveedor	Modelo de IA empleado	Integración	Caso de uso en minería
Siemens MindSphere	Siemens	Redes neuronales + IoT	Integración nativa con PCS7 y GMD	Monitoreo de molinos SAG en Perú
IBM Maximo APM	IBM	Modelos cognitivos + ML	Compatible con SAP, SCADA y ERP	Predictivo en minería de oro (Chile)
Uptake Fusion	Uptake	Random Forest y XGBoost	Orientado a entornos IoT y multiequipo	Predictivo en Brasil
Aspen Mtell	AspenTech	Modelos prescriptivos	Integración modular IoT	Implementación en BHP Australia
ABB Ability™	ABB	Árboles de decisión	Escalable para plantas multisensoriales	CODELCO División Andina

Tras evaluar la compatibilidad técnica, la flexibilidad de integración y el soporte operativo, Siemens MindSphere surge como la plataforma más adecuada para Minera Candelaria. Este resultado responde a tres factores clave:

- **Compatibilidad con la infraestructura actual**
La planta concentradora ya utiliza PCS7 y el sistema SINAMICS GH180 de Siemens para el accionamiento Gearless Mill Drive (GMD) del molino SAG, lo que facilita una integración nativa sin necesidad de inversiones adicionales significativas en interfaces o adaptadores de comunicación.
- **Ecosistema IoT-industrial consolidado**
MindSphere está diseñado para operar en entornos de alta criticidad, gestionando sensores IoT, series temporales y datos de vibración, temperatura, torque y consumo energético. Esto permite consolidar múltiples fuentes de datos en una única plataforma analítica.
- **Casos exitosos en la región**
Implementaciones previas de Siemens en Perú y Brasil han demostrado

reducciones de hasta un 22 % en costos de mantenimiento y un 12 % en fallas críticas al integrar modelos de redes neuronales con sistemas GMD similares al de Minera Candelaria (Siemens, 2023).

No obstante, IBM Maximo APM y Uptake Fusion también representan opciones robustas que podrían evaluarse para una segunda fase de digitalización, especialmente en proyectos de integración con SAP o sistemas ERP, considerando la escalabilidad y la alineación con las metas de transformación digital corporativa.

En conclusión, la priorización de Siemens MindSphere como plataforma estratégica se justifica no solo por su compatibilidad técnica con la infraestructura existente, sino también por su madurez tecnológica, su historial de casos de éxito en minería y su capacidad de integración con modelos avanzados de machine learning diseñados para mantenimiento predictivo. Esto permite reducir significativamente los costos de implementación, acelerar los plazos de adopción y potenciar la confiabilidad operacional de Minera Candelaria.

3.1.3.1. Integración operativa y dashboards predictivos

La implementación de inteligencia artificial en entornos industriales, y en particular en la gestión de activos de alta criticidad como el molino SAG de Minera Candelaria, requiere que los modelos predictivos desarrollados no operen de forma aislada, sino que se integren de manera nativa con los sistemas existentes de control, monitoreo y planificación. La plataforma **Siemens MindSphere**, seleccionada como solución prioritaria para este proyecto, permite unificar datos provenientes de múltiples fuentes —sensores IoT, sistemas SCADA, PCS7, SINAMICS GH180 y SAP PM— en un único entorno digital, lo que facilita la supervisión continua y la generación de alertas tempranas basadas en algoritmos de machine learning (Siemens, 2024).

En la operación de Minera Candelaria, esta integración posibilita que los datos recolectados por los sensores del molino —vibraciones, temperaturas, torque, consumo energético y desgaste de revestimientos— sean transmitidos en tiempo real hacia MindSphere. La plataforma no solo centraliza la información, sino que

también habilita **procesos de analítica avanzada** donde los algoritmos entrenados, como **Random Forest, XGBoost y redes neuronales feed-forward**, procesan series temporales históricas y generan predicciones sobre posibles fallas con varias horas o incluso días de anticipación (Abdelrahman et al., 2023; Wang et al., 2020).

a) Flujo de integración digital

La arquitectura digital propuesta para la integración operativa contempla cuatro capas principales:

- **Capa de sensorización IoT:** Incluye acelerómetros triaxiales para medir vibraciones en cojinetes y trunnions, cámaras termográficas para monitorear temperaturas críticas, sensores de torque y presión, además de medidores de consumo energético. Estos dispositivos generan datos de alta resolución, capturando eventos cada 10 a 50 milisegundos.
- **Capa de control y adquisición (SCADA / PCS7):** Los datos sensoriales se consolidan mediante el sistema **PCS7 de Siemens**, ya implementado en Minera Candelaria, y son transmitidos al entorno SCADA para garantizar su disponibilidad inmediata y trazabilidad.
- **Capa de analítica en MindSphere:** Aquí, los datos estructurados y no estructurados se procesan con los modelos predictivos previamente entrenados. Los algoritmos generan **alertas de riesgo clasificadas por criticidad**, priorizando anomalías térmicas, vibracionales o energéticas.
- **Capa de visualización y dashboards operativos:** Los resultados se presentan en paneles interactivos accesibles desde la sala de control, el área de mantenimiento y la gerencia técnica. Esto permite monitorear en tiempo real métricas clave como MTBF, MTTR, OEE, probabilidad de falla y costos proyectados de mantenimiento.

b) Dashboards predictivos y KPIs operativos

El uso de dashboards predictivos es esencial para la toma de decisiones en tiempo real. A través de MindSphere, el personal de operaciones puede acceder a

indicadores clave de desempeño (KPIs) que integran predicciones y métricas históricas, entre los que destacan:

Indicador	Definición	Situación actual (2023)	Meta proyectada (IA)
MTBF (Mean Time Between Failures)	Tiempo medio entre fallas mayores	720 horas	950 horas (+32 %)
MTTR (Mean Time To Repair)	Tiempo medio de reparación	11,4 horas	8,2 horas (-28 %)
OEE (Overall Equipment Effectiveness)	Eficiencia global del equipo	78 %	85 %
Costos de mantenimiento correctivo	Gasto asociado a fallas críticas	USD 1,2 M	USD 980 k (-18 %)
Disponibilidad operacional	Tiempo útil de operación	92 %	96 %

Estos KPIs permiten evaluar, de forma cuantitativa, el impacto esperado de la implementación del modelo predictivo. Además, el sistema permite configurar alertas dinámicas: por ejemplo, si la vibración de un trunnion supera el umbral de 12 mm/s o si la temperatura de los cojinetes principales excede los 90 °C, el dashboard emite una notificación automática y genera una orden de inspección en el **SAP PM**.

c) Impacto en la operación minera

La integración propuesta no solo mejora la confiabilidad técnica del molino SAG, sino que también transforma los procesos internos de mantenimiento. Gracias a la conexión directa entre MindSphere, SCADA y SAP PM, se logra:

- Priorizar **intervenciones basadas en condición** en lugar de mantenimientos programados rígidos.
- Reducir significativamente los costos asociados a reparaciones correctivas.
- Anticipar fallas críticas con **hasta 72 horas de antelación** en componentes clave, como trunnions y cojinetes principales.
- Mejorar la coordinación entre las áreas de operación, mantenimiento, planificación y control de gestión.

Este nivel de integración convierte los datos en **información accionable**, permitiendo que las decisiones estratégicas se fundamenten en evidencia y no únicamente en la experiencia empírica. Así, el proyecto se alinea con los principios de la **Industria 4.0**, donde la analítica avanzada y la automatización inteligente se combinan para optimizar la gestión de activos de alta criticidad (Wang et al., 2020; Ghasemi et al., 2023).

3.1.4. Modelado predictivo y simulación aplicada al molino SAG

Este apartado corresponde al desarrollo de la **Fase 3 de la metodología propuesta** (ver Capítulo 2), cuyo objetivo específico es diseñar y validar un modelo exploratorio de predicción de fallas aplicable al molino SAG de Minera Candelaria. En este contexto, se integran técnicas de analítica de datos, algoritmos de machine learning y escenarios simulados, utilizando tanto registros históricos reales como datos procesados técnicamente a partir de condiciones operacionales del equipo. Esta fase no contempla una implementación industrial definitiva, sino la construcción de un prototipo funcional cuya validación permita proyectar mejoras tangibles en la gestión de activos.

La implementación de inteligencia artificial (IA) en la gestión de activos industriales requiere la integración de tres elementos clave: **datos históricos y en tiempo real, algoritmos de aprendizaje automático y entornos de simulación capaces de evaluar escenarios futuros**. En el caso de **Minera Candelaria**, el molino SAG constituye un activo crítico cuya operación continua es esencial para la productividad de la planta concentradora. Durante 2023, este equipo registró **12 fallas mayores**, generando **pérdidas superiores a USD 1,2 millones** en costos de mantenimiento correctivo y representando **un 8 % de inactividad no planificada**. Este contexto justifica la necesidad de adoptar un modelo predictivo robusto que permita anticipar comportamientos anómalos y optimizar la planificación de intervenciones preventivas.

3.1.4.1. Preparación y estructuración de los datos

El modelo se nutre principalmente de **series temporales** provenientes de sistemas de monitoreo en línea e históricos del molino. Los datos provienen de distintas fuentes integradas en la infraestructura existente:

- El sistema **PCS7** de Siemens, que registra parámetros operativos en tiempo real.
- Los sensores IoT instalados en trunnions, cojinetes, motores y revestimientos.
- Los reportes históricos de fallas y mantenimientos en el **CMMS** de Minera Candelaria.

Entre las variables más relevantes se incluyen:

- **Vibraciones** en cojinetes principales (Hz, mm/s).
- **Temperatura** en el sistema de accionamiento Gearless Mill Drive (°C).
- **Consumo energético** del motor Siemens (kWh).
- **Torque y presión interna** durante los ciclos de carga.
- **Eventos de sobrecarga y paradas no planificadas.**
- **Desgaste acumulado de revestimientos internos.**

Antes de entrenar los modelos, los datos pasan por un proceso de preparación y gobernanza que incluye:

- **Depuración de datos:** Eliminación de registros duplicados, corrección de inconsistencias y detección de valores atípicos.
- **Normalización:** Homogeneización de unidades para garantizar que las variables puedan compararse.
- **Imputación inteligente:** Uso de algoritmos estadísticos para estimar valores faltantes basados en patrones históricos.
- **Estructuración final:** Creación de un dataset balanceado, segmentado en periodos estacionales para mejorar la capacidad predictiva.

Una base de datos de alta calidad es esencial, ya que los algoritmos de machine learning dependen directamente de la integridad, consistencia y representatividad de la información procesada (Abdelrahman et al., 2023).

3.1.4.2. Selección y entrenamiento de algoritmos

La arquitectura propuesta combina **modelos supervisados y no supervisados** para capturar patrones de desgaste, identificar comportamientos anómalos y generar predicciones sobre posibles fallas. Los principales algoritmos considerados son:

- **Random Forest (RF)**: Ideal para clasificar estados del equipo y estimar la probabilidad de fallas futuras mediante el análisis de múltiples variables en paralelo.
- **XGBoost**: Un algoritmo basado en árboles de decisión potenciados, altamente eficiente en la detección de patrones complejos y en la reducción del sesgo en datos desbalanceados.
- **Redes Neuronales Artificiales (ANN)**: Utilizadas para correlacionar señales multivariadas, como vibraciones, torque y temperaturas críticas, generando predicciones precisas con anticipación.
- **Isolation Forest (modelo no supervisado)**: Empleado para detectar anomalías en tiempo real, útil cuando se registran eventos infrecuentes como sobrecargas repentinas.

El entrenamiento de los modelos se realizará mediante la división de los datos históricos en **conjuntos de entrenamiento (70 %)** y **validación (30 %)**, evaluando su desempeño con métricas estándar como:

- **Precisión (Accuracy)**: Proporción de predicciones correctas.
- **Recall (Sensibilidad)**: Capacidad para identificar fallas reales.
- **F1-Score**: Métrica balanceada entre precisión y recall.
- **Matriz de confusión**: Para evaluar aciertos y falsos positivos en la detección de anomalías.

Estudios recientes en minería demuestran que la combinación de Random Forest + redes neuronales puede reducir hasta un 20 % el tiempo de inactividad no planificada en equipos de molienda SAG, además de mejorar el OEE (Overall Equipment Effectiveness) en un 15 % en promedio (Ghasemi et al., 2023; Barua et al., 2021).

3.1.4.3. Simulación de escenarios y validación del modelo

Una vez entrenado, el modelo predictivo será sometido a simulaciones controladas que permitan evaluar su efectividad en escenarios reales. Se propondrán **tres escenarios operativos** para Minera Candelaria:

- **Escenario A – Sin implementación de IA:** El molino continúa operando bajo esquemas actuales de mantenimiento preventivo.
- **Escenario B – Implementación parcial:** Se incorporan alertas predictivas limitadas a vibraciones y temperaturas críticas.
- **Escenario C – Implementación completa:** La IA gestiona automáticamente eventos de mantenimiento, integrando sensores IoT, PCS7 y dashboards predictivos.

Cada escenario será evaluado en términos de:

- **Reducción proyectada de fallas (%)**.
- **Ahorros potenciales en costos de mantenimiento (USD)**.
- **Impacto en disponibilidad operativa (% OEE)**.
- **Retorno sobre la inversión (ROI)**.

Por ejemplo, proyecciones preliminares basadas en datos históricos de Candelaria sugieren que la implementación completa del modelo podría reducir en **hasta un 25 %** las fallas críticas, generar **ahorros anuales estimados de USD 300.000** y aumentar la **disponibilidad operativa del molino en un 12 %**.

El modelo predictivo será implementado sobre la infraestructura digital de Siemens MindSphere, seleccionada por su compatibilidad nativa con PCS7 y SINAMICS GH180. Esto permite:

- Transmisión de datos en tiempo real desde los sensores hacia dashboards interactivos.
- Integración de alertas automáticas en el sistema de control distribuido (DCS).
- Generación de reportes periódicos para la supervisión de KPIs clave como MTBF, MTTR y OEE.

El uso de MindSphere reduce significativamente los tiempos de adopción y los riesgos técnicos asociados a la implementación, lo que permite que la validación de los modelos sea más eficiente y escalable (Siemens, 2023; Deloitte, 2023).

Los resultados obtenidos en esta fase no constituyen una implementación definitiva del modelo, pero sí ofrecen una **prueba de concepto validada** que evidencia la factibilidad técnica de integrar inteligencia artificial en la gestión predictiva del molino SAG. Esta validación exploratoria, respaldada por simulaciones y métricas de desempeño, permite sustentar con base empírica los escenarios comparativos que se desarrollarán en la siguiente fase. En este sentido, el modelo construido no solo contribuye al cumplimiento del objetivo metodológico propuesto, sino que se transforma en un **insumo clave para estimar impactos operacionales, económicos y estratégicos** en el marco de una futura adopción tecnológica a escala industrial.

3.1.5. Construcción de escenarios comparativos y estrategias de mejora

El cierre del ciclo metodológico en esta investigación exige proyectar los posibles impactos de la implementación de inteligencia artificial (IA) en la gestión de activos críticos, contrastando el modelo predictivo validado con la situación actual del molino SAG de Minera Candelaria. Esta fase no busca replicar una simulación probabilística en tiempo real, sino elaborar un **análisis determinístico de escenarios**, empleando los resultados obtenidos en la Fase 3 como base técnica

para formular **estrategias viables de mejora**, tanto operativas como organizacionales.

3.1.5.1. Escenario Base (sin IA): caracterización del modelo actual

La gestión actual del molino SAG se basa en un enfoque preventivo tradicional, apoyado en monitoreo condicional y paradas programadas. Aunque esta estrategia ha permitido mantener la continuidad operacional en estándares aceptables, presenta importantes limitaciones. Entre ellas destacan: una alta variabilidad en la frecuencia de fallas (12 eventos críticos en 2023), tiempos promedios de reparación superiores a 18 horas, y una disponibilidad operacional que bordea el 89 %, por debajo del benchmark internacional para plantas concentradoras modernas, que se sitúa entre 93 % y 95 % (Galar et al., 2019; Cochilco, 2024).

En términos financieros, el costo directo de estas fallas —considerando repuestos, horas-hombre y pérdidas de producción— supera los USD 1,2 millones anuales, lo que representa cerca del 1,5 % del presupuesto operativo de mantenimiento de planta.

3.1.5.2. Escenario de implementación parcial (IA nivel básico)

Bajo este modelo, se propone una integración inicial del sistema predictivo desarrollado, limitada a alertas tempranas sobre vibraciones y temperaturas anómalas, sin automatización completa de decisiones. El sistema operaría en modo consultivo, generando dashboards e informes diarios para los equipos de mantenimiento, quienes decidirían si ejecutar una intervención.

Proyecciones basadas en la validación del modelo sugieren que este enfoque permitiría anticipar al menos el 60 % de las fallas mecánicas detectadas en 2023, reduciendo la frecuencia de fallos en un 15 % y disminuyendo los costos de mantenimiento correctivo en un 12 %. Si bien el ROI es moderado, este escenario actúa como **etapa de madurez intermedia**, crucial para la adopción cultural de la IA en el entorno industrial (Deloitte, 2023).

3.1.5.3. Escenario de implementación total (IA integrada)

Este escenario contempla la **implementación completa del modelo predictivo**, integrando el sistema con la arquitectura PCS7, los sensores IoT del molino y la plataforma Siemens MindSphere. La IA no solo emitiría alertas, sino que **generaría recomendaciones automáticas**, priorización de tareas y ajuste de parámetros operacionales en tiempo real.

La simulación de este escenario permite proyectar los siguientes beneficios operacionales y económicos:

- **Reducción estimada de fallas críticas:** 25 %.
- **Incremento en disponibilidad operativa (OEE):** de 89 % a 95 %.
- **Ahorro en mantenimiento correctivo:** USD 300.000–350.000 anuales.
- **Reducción en el tiempo medio de reparación (MTTR):** de 18 a 12 horas.
- **Mejora en la tasa de anticipación de eventos:** superior al 80 %.
- **Retorno de inversión (ROI):** estimado en 14 meses, considerando inversión en sensores adicionales, licencias y capacitación.

Estos resultados se sustentan en casos documentados por CODELCO, BHP y Rio Tinto, donde la integración de modelos de machine learning con plataformas SCADA e IoT permitió optimizar la gestión de mantenimiento, reducir accidentes y mejorar el uso de recursos críticos (Zheng et al., 2020; Barua et al., 2021).

3.1.5.4. Propuesta de hoja de ruta de implementación

A partir del análisis anterior, se formula un plan escalonado de adopción tecnológica, que permite mitigar riesgos, facilitar la aceptación organizacional y maximizar beneficios:

Etapa	Horizonte	Acciones clave	Indicadores de éxito
Fase 1	0–6 meses	Validación piloto del modelo con datos históricos y actuales; integración parcial con PCS7	Acierto predictivo ≥ 70 %, reducción de eventos imprevistos

Fase 2	6–12 meses	Escalamiento a monitoreo en tiempo real, entrenamiento de personal, gobernanza de datos	Aumento en KPIs de mantenimiento, reducción de MTTR
Fase 3	12–18 meses	Integración completa con MindSphere, automatización de alertas y reportes	Mejora de OEE $\geq 5\%$, ROI alcanzado, replicabilidad en otros activos

3.1.5.5. ***Implicaciones estratégicas***

Más allá de los beneficios técnicos y económicos, esta fase permite comprender el **valor estratégico de la IA** en entornos industriales. No se trata únicamente de prevenir fallas, sino de **transformar el modelo de gestión de activos**, habilitando una operación basada en datos, proactiva y resiliente. Asimismo, los escenarios comparativos permiten a la alta dirección **tomar decisiones informadas**, con proyecciones realistas y respaldadas por evidencia concreta.

Finalmente, el ejercicio comparativo genera insumos valiosos para justificar presupuestos de inversión, establecer nuevos acuerdos con proveedores tecnológicos, diseñar programas de formación interna y, eventualmente, **replicar el modelo en otros equipos críticos** de la planta, como los molinos secundarios, sistemas de bombeo o estaciones de chancado.

3.1.6. ***Gestión del cambio y barreras organizacionales en la adopción de IA***

La implementación de inteligencia artificial (IA) en entornos industriales de alta criticidad, como la gestión de activos del molino SAG en **Minera Candelaria**, no solo depende de la selección adecuada de plataformas tecnológicas o del desarrollo de modelos predictivos efectivos. El verdadero reto radica en la transformación organizacional, ya que el éxito de estos proyectos exige integrar personas, procesos y tecnología bajo un mismo propósito estratégico. En este

sentido, distintos estudios de referencia en gestión de activos señalan que aproximadamente el 70 % de las iniciativas de adopción tecnológica fracasan parcial o totalmente debido a problemas de gestión del cambio, y no por limitaciones técnicas (Deloitte, 2023; PwC, 2022).

La transición hacia un modelo de mantenimiento predictivo demanda un enfoque integral que abarque tres dimensiones fundamentales: la capacitación técnica del personal, la alineación de objetivos estratégicos y la adaptación cultural. No basta con instalar sensores IoT, entrenar modelos de machine learning o implementar plataformas como **Siemens MindSphere**; es imprescindible que los equipos humanos comprendan, adopten y confíen en el nuevo sistema. Esta aceptación no surge automáticamente: requiere generar confianza en los datos, demostrar el valor de las predicciones y explicar de forma clara cómo los resultados beneficiarán tanto a la operación como a los trabajadores.

Los reportes recientes de Deloitte (2023) y Fundación Chile (2023), que analizaron procesos de transformación digital en minería en América Latina, muestran que las compañías que invierten en programas de capacitación estructurados logran aumentar en promedio un 25 % la efectividad de la implementación de IA y reducen hasta en un 30 % la resistencia al cambio. Esto evidencia que la tecnología, por sí sola, no es suficiente: la clave está en el desarrollo de competencias digitales en los equipos de operación, mantenimiento y gestión.

Un aspecto crítico identificado por PwC (2022) es que, en industrias de alta complejidad como la minería, la introducción de IA altera flujos de trabajo consolidados durante años. Por ejemplo, en Minera Candelaria, los mantenedores han tomado decisiones históricamente basadas en la experiencia y la intuición, priorizando la intervención correctiva o preventiva según eventos pasados. Con la incorporación de modelos predictivos, los criterios cambian: las decisiones ahora se basan en datos y probabilidades de falla estimadas. Este cambio exige **un rediseño organizacional** que fomente la colaboración entre áreas tradicionalmente aisladas,

como **operaciones, mantenimiento, TI y gestión financiera**, estableciendo un lenguaje común orientado a la confiabilidad operacional.

La gestión del cambio también involucra comunicación efectiva y liderazgo participativo. Estudios de McKinsey & Company (2023) en el sector industrial indican que los proyectos de IA que involucren activamente a los líderes de primera línea —supervisores, jefes de turno y coordinadores de mantenimiento— tienen 1,8 veces más probabilidades de alcanzar sus objetivos que aquellos donde las decisiones se centralizan en la alta dirección. En este sentido, la construcción de una narrativa interna clara sobre “por qué” y “para qué” se adopta la IA es esencial para eliminar temores asociados a la automatización y garantizar el compromiso de todo el personal.

Por último, es importante considerar que la adopción exitosa de IA requiere gobernanza transversal del proyecto. Esto significa definir roles claros para cada área involucrada, establecer métricas de adopción (por ejemplo, el porcentaje de alertas predictivas atendidas o la reducción efectiva de tiempos de inactividad) y garantizar que la estrategia digital esté alineada con los objetivos corporativos. Este enfoque reduce riesgos, evita implementaciones fragmentadas y maximiza el retorno sobre la inversión. El éxito del mantenimiento predictivo en el molino SAG no dependerá únicamente de la sofisticación de los algoritmos o de la compatibilidad de la plataforma tecnológica elegida. Su verdadera viabilidad estará determinada por la **capacidad de la organización para gestionar el cambio**, integrar a sus equipos y desarrollar competencias que permitan aprovechar el potencial de la inteligencia artificial como una herramienta que potencia —y no reemplaza— la experiencia humana.

a) Desafíos organizacionales y barreras culturales

La literatura sobre transformación digital en minería identifica tres grandes desafíos que Minera Candelaria enfrentará en este proyecto (Ríos & Serrano, 2022; Yin, 2018):

- **Resistencia al cambio y temor a la sustitución laboral:** Un número significativo de operadores y técnicos perciben la IA como una amenaza a la continuidad de sus puestos de trabajo. Estudios recientes muestran que el **45 % de los trabajadores de plantas industriales en Chile** expresa preocupación por la automatización y la sustitución de tareas manuales (Fundación Chile, 2023). En consecuencia, es clave **enfocar la narrativa del proyecto en la colaboración entre humanos y algoritmos**, subrayando que la IA no reemplaza la experiencia técnica, sino que la potencia.
- **Brechas de competencias digitales:** En minería, aproximadamente el **57 % de los trabajadores operativos** declara no estar familiarizado con tecnologías de monitoreo IoT o plataformas analíticas avanzadas (Cochilco, 2023). Este déficit se traduce en la necesidad de programas de formación progresivos, enfocados en interpretar indicadores generados por el modelo predictivo, configurar alertas y tomar decisiones basadas en datos.
- **Fragmentación interdepartamental:** Para integrar un sistema predictivo, es imprescindible alinear a las áreas de **operaciones, mantenimiento, TI, gestión financiera y seguridad industrial**. En muchas organizaciones mineras, estas áreas trabajan en silos, lo que dificulta la interoperabilidad de datos, la coordinación de intervenciones y la priorización de inversiones.

b) Estrategias para mitigar las barreras

Para enfrentar estos desafíos, se propone una **estrategia estructurada de gestión del cambio** que contemple tres líneas de acción principales:

Capacitación técnica y reconversión de competencias

- Implementar un **programa de formación continua** para operadores, mantenedores e ingenieros.
- Contenidos clave: fundamentos de machine learning, interpretación de alertas predictivas, integración de MindSphere con PCS7 y SAP.

- Según un estudio de Deloitte (2023), **las mineras que invierten en capacitación aumentan en promedio un 25 % la efectividad de implementación de IA** y reducen hasta en un 30 % la resistencia interna.

Creación de una estructura de gobernanza tecnológica

- Definir un **Comité de Transformación Digital** encargado de supervisar la implementación.
- Integrar representantes de **operaciones, mantenimiento, TI, finanzas y seguridad industrial** para alinear prioridades y definir indicadores comunes.
- Establecer **KPIs de adopción tecnológica**, como el porcentaje de alertas predictivas atendidas, reducción en fallas críticas y ahorro real en costos.

Gestión de la comunicación y transparencia del proyecto

- Elaborar una narrativa organizacional clara: la IA **no reemplaza**, sino que **optimiza**.
- Difundir casos de éxito, como los de **Vale (Brasil)** o **CODELCO**, que lograron reducciones de hasta **23 % y 15 %** en costos y fallas críticas, respectivamente, gracias a modelos predictivos (Abdelrahman et al., 2023; SERNAGEOMIN, 2023).
- Asegurar que todos los niveles de la organización comprendan el **propósito estratégico** y los **beneficios tangibles** del sistema.

c) Integración con Siemens MindSphere y modelo predictivo

La selección de **Siemens MindSphere** como plataforma prioritaria permite reducir la complejidad técnica, ya que la planta ya utiliza el sistema **PCS7** y el accionamiento **SINAMICS GH180** para el molino SAG. Esto permite **minimizar costos de integración** y acelerar el despliegue. Sin embargo, para que la plataforma logre un uso efectivo, es fundamental:

- Entrenar a los equipos para gestionar dashboards interactivos, interpretar tendencias y validar alertas.

- Establecer un **protocolo de intervención basado en datos** que redefina prioridades de mantenimiento.
- Crear un **plan de monitoreo continuo**, integrando KPIs como MTBF, MTTR, OEE y costos unitarios de mantenimiento.

d) Beneficios esperados de una gestión del cambio efectiva

Una correcta implementación de estrategias de gestión del cambio podría permitir que el modelo predictivo alcance su máximo potencial. Con base en datos históricos de la operación y benchmarking sectorial, se proyectan los siguientes beneficios plausibles en Minera Candelaria:

- Reducción estimada del 20 % en fallas críticas durante el primer año.
- Disminución aproximada del 15 % en costos de mantenimiento correctivo.
- Aumento proyectado de la disponibilidad operacional del molino SAG en torno al 7 %.
- Un nivel de adopción tecnológica esperado superior al 80 % de usuarios activos en MindSphere durante los primeros seis meses.

3.2. Arquitectura de integración tecnológica: PCS7 y MindSphere

La implementación de un sistema de mantenimiento predictivo basado en inteligencia artificial en entornos industriales no puede comprenderse como una simple incorporación de algoritmos. Requiere, ante todo, de una arquitectura tecnológica robusta que garantice la captura, transmisión, análisis y visualización de datos en tiempo real. En el caso del molino SAG de Minera Candelaria, esta arquitectura se articula sobre dos pilares fundamentales: el sistema de control distribuido **PCS7** y la plataforma de análisis en la nube **Siemens MindSphere**.

PCS7, desarrollado por Siemens, constituye el sistema centralizado de supervisión y control de procesos en la planta concentradora. Este sistema opera sobre una infraestructura redundante que gestiona variables críticas como velocidad de rotación, par motor, temperaturas, presiones internas y condiciones de carga. Gracias a su arquitectura modular, PCS7 no solo controla la operación del molino SAG, sino que también actúa como punto de integración para sensores externos de

vibración, ultrasonido y cámaras termográficas que recogen datos adicionales desde componentes clave como trunnions, cojinetes y revestimientos internos.

Ahora bien, el verdadero potencial de estos datos emerge cuando se integran a una plataforma capaz de analizarlos de manera inteligente. Aquí entra en escena MindSphere, también de Siemens, una solución cloud orientada a aplicaciones industriales que permite almacenar, procesar y visualizar datos provenientes de múltiples fuentes. La conexión entre PCS7 y MindSphere se establece a través de protocolos industriales como OPC UA, lo que asegura una comunicación estandarizada, segura y bidireccional. Esta conectividad permite que los datos operativos sean transferidos en tiempo casi real a la nube, donde son interpretados por modelos de machine learning diseñados para detectar patrones de deterioro, predecir fallas y emitir alertas anticipadas.

En este esquema, la arquitectura de integración puede describirse en tres niveles funcionales. El primero corresponde a la **capa de adquisición**, donde sensores IoT recogen datos con alta frecuencia (por ejemplo, acelerómetros triaxiales, sensores térmicos, medidores de torque). Estos datos ingresan al **nivel de control** gestionado por PCS7, que además de recolectar información, ejecuta acciones de protección inmediata si se detectan condiciones críticas. El tercer nivel, el **analítico**, lo ocupa MindSphere, que no solo procesa los datos sino que los enriquece con algoritmos de inteligencia artificial, produciendo información de valor para la toma de decisiones técnicas y estratégicas.

Un componente adicional, aunque no menos importante, es la **capa de visualización y usuario final**. En esta etapa, los resultados del análisis son presentados mediante dashboards interactivos, accesibles desde dispositivos móviles o estaciones de trabajo, con indicadores clave como “riesgo de falla en los próximos N ciclos”, “tiempo estimado de intervención” o “recomendación de reemplazo anticipado”. Esta interfaz cumple un rol esencial en la adopción de la tecnología, ya que traduce la complejidad algorítmica en insumos comprensibles para ingenieros, operadores y responsables de mantenimiento.

Desde una perspectiva organizacional, esta arquitectura también ofrece ventajas en términos de escalabilidad. Al utilizar una solución nativa de Siemens, compatible con la infraestructura existente en Minera Candelaria (como el accionamiento GMD SINAMICS GH180 y el sistema de control PCS7), se minimizan los esfuerzos de integración, se reducen los tiempos de despliegue y se asegura la interoperabilidad entre los distintos módulos. Además, al ser una plataforma en la nube, MindSphere permite gestionar múltiples activos distribuidos geográficamente, lo que abre la posibilidad de extender la estrategia predictiva a otros equipos críticos de la operación minera.

Por otra parte, la arquitectura contempla mecanismos de retroalimentación. Las predicciones realizadas por los modelos de IA no solo se traducen en acciones técnicas, sino que también se retroalimentan al sistema para mejorar su precisión en futuras iteraciones. Esta característica de **aprendizaje continuo** convierte a la arquitectura en un ecosistema dinámico, capaz de evolucionar conforme se acumula experiencia operativa y se ajustan los parámetros de funcionamiento del molino SAG.

En suma, la arquitectura tecnológica diseñada para este proyecto no se limita a conectar sensores con una plataforma digital. Es un sistema ciberfísico integrado que articula hardware, software, inteligencia artificial y conocimiento técnico. Su objetivo no es únicamente anticipar fallas, sino transformar la gestión de activos en un proceso proactivo, fundamentado en datos, escalable y alineado con los principios de la Industria 4.0 (Wang et al., 2020; Ghasemi et al., 2023). Esta integración entre PCS7 y MindSphere sienta las bases para una minería más eficiente, segura y competitiva, en la que el conocimiento automatizado se convierta en una herramienta estratégica para la toma de decisiones.

3.3. Modelado predictivo y simulación aplicada al molino SAG

El diseño y puesta en marcha de un modelo predictivo para el molino SAG de Minera Candelaria constituye una de las fases más críticas del proyecto, no solo por el desafío técnico que implica el entrenamiento de algoritmos de inteligencia artificial, sino también por su impacto directo en la reducción de fallas críticas y

optimización de recursos. A diferencia de enfoques tradicionales de mantenimiento que se apoyan en intervenciones periódicas o reactivas, el modelo propuesto se basa en el análisis de datos operacionales históricos y en tiempo real para anticipar eventos de falla con suficiente antelación y confiabilidad.

La construcción del modelo se articula en varias etapas interdependientes. En primer lugar, se realiza una **definición de las variables objetivo**. En el contexto del molino SAG, estas pueden tomar la forma de “probabilidad de detención no planificada en las próximas 72 horas”, “riesgo acumulado por sobrecalentamiento” o “deterioro crítico en trunnions por vibración excesiva”. La elección de estas salidas no es trivial, pues deben representar de manera cuantificable y accionable los principales mecanismos de fallo observados en registros históricos.

A partir de esta definición, se pasa a la **selección de características predictoras**. Estas variables de entrada —también llamadas “features”— incluyen: datos de vibración registrados por acelerómetros triaxiales en los cojinetes; temperaturas críticas obtenidas por cámaras termográficas; consumo energético en distintos regímenes de carga; registros de paradas no planificadas; historial de intervenciones de mantenimiento; y condiciones operativas como variabilidad en la dureza del mineral procesado. Esta riqueza de datos permite capturar relaciones no lineales entre las condiciones operativas y la ocurrencia de fallas, lo cual es clave para el éxito del modelo.

Una vez definido el conjunto de datos, se entra en la fase de **entrenamiento algorítmico**. Para este proyecto se propone la utilización de modelos de aprendizaje supervisado, específicamente Random Forest, XGBoost y redes neuronales feed-forward. La elección de estos algoritmos responde tanto a su capacidad comprobada en entornos industriales como a su flexibilidad para manejar datos con ruido, outliers o relaciones no lineales (Abdelrahman et al., 2023; Barua et al., 2021). Cada algoritmo será entrenado con el conjunto de datos históricos de fallas del molino SAG durante 2023–2024, utilizando una validación cruzada de tipo *k-fold* para evitar sobreajuste y asegurar generalización.

Durante el entrenamiento, se aplica un proceso iterativo de ajuste de hiperparámetros —como profundidad de árboles, número de estimadores o tasa de aprendizaje— utilizando técnicas de optimización como búsqueda aleatoria (*random search*) o *grid search*. Paralelamente, se monitorean métricas de rendimiento como *precision*, *recall*, F1-score y área bajo la curva ROC, lo que permite evaluar no solo la precisión del modelo, sino también su sensibilidad a falsos positivos y negativos.

Una vez entrenado, el modelo se implementa inicialmente en un **entorno de prueba o simulación controlada**, lo que permite observar su comportamiento ante diferentes escenarios sin afectar la operación real. En esta etapa se diseñan casos hipotéticos de operación anómala, por ejemplo, una sobrecarga repentina, aumento sostenido de temperatura en el motor, o una vibración creciente en el trunnion izquierdo. Estos escenarios permiten evaluar la capacidad del modelo para emitir alertas con tiempo suficiente y para discriminar entre una anomalía pasajera y una falla incipiente real.

En paralelo, se desarrolla una **simulación de escenarios comparativos** que permite cuantificar el impacto del modelo en indicadores clave como disponibilidad operativa, costos de mantenimiento y frecuencia de fallas. Esta simulación compara dos escenarios: uno base, que representa la estrategia actual de mantenimiento reactivo y preventivo; y otro prospectivo, donde el modelo predictivo está plenamente operativo. Para ambos escenarios se proyectan indicadores sobre un horizonte temporal de 12 meses, considerando las tasas históricas de fallas, los tiempos promedio de intervención, y los costos asociados a cada tipo de parada.

Los resultados preliminares de esta simulación estiman que, en condiciones operativas normales, el modelo puede reducir entre un 18 % y 25 % el número de fallas críticas, disminuir en un 15 % los costos correctivos directos, y aumentar en aproximadamente 5 puntos porcentuales la disponibilidad del equipo. Estos beneficios no solo se traducen en ahorros económicos tangibles, sino también en mejoras en seguridad, eficiencia energética y utilización de la capacidad instalada.

Cabe destacar que el modelo no se concibe como una herramienta estática. Una vez en operación, se implementa un mecanismo de **aprendizaje continuo**,

donde cada nueva falla, intervención o cambio en el régimen de operación retroalimenta al algoritmo. Este proceso, conocido como *online learning* o *retraining*, garantiza que el modelo se mantenga vigente y preciso incluso ante condiciones cambiantes o no previstas en el conjunto de entrenamiento inicial (Ghasemi et al., 2023).

Por último, la integración técnica se completa mediante la conexión del modelo con la plataforma MindSphere, que permite desplegar los resultados en forma de dashboards interactivos, informes automatizados y alertas visuales en estaciones de monitoreo. Estas interfaces aseguran que el conocimiento generado por la inteligencia artificial llegue en tiempo real a los encargados de mantenimiento, planificación y operación, fortaleciendo así el proceso de toma de decisiones basado en evidencia.

En definitiva, el modelado predictivo aplicado al molino SAG representa mucho más que un ejercicio computacional. Se trata de una transformación profunda en la forma en que se gestiona un activo crítico, pasando de una lógica reactiva a una estrategia inteligente, anticipatoria y alineada con los principios de confiabilidad operacional y sostenibilidad industrial.

Capítulo 4. Conclusiones y recomendaciones

La presente investigación sugiere que la inteligencia artificial (IA) aplicada al mantenimiento predictivo puede representar un cambio transformador en la gestión de activos críticos en minería, particularmente en equipos de alta criticidad como el molino SAG de Minera Candelaria. A través de un enfoque mixto, sustentado tanto en análisis de datos operacionales como en insumos cualitativos provenientes de entrevistas técnicas, se ha logrado caracterizar en profundidad el estado actual del activo, las causas de sus fallas recurrentes y el potencial de mejora que ofrece la analítica avanzada. En relación con los beneficios proyectados en la sección 3.1.6.d, es importante precisar que estos valores corresponden a estimaciones construidas

sobre escenarios exploratorios y referencias sectoriales, condicionados a una gestión del cambio efectiva. En las conclusiones, dichos resultados se integran con el benchmarking de experiencias internacionales (CODELCO, BHP, Rio Tinto) y con evidencia de la literatura académica reciente, lo que permite consolidar un marco plausible de beneficios potenciales. Así, no se afirma que estos impactos se hayan demostrado empíricamente, sino que representan resultados esperados bajo condiciones de implementación adecuadas. En consecuencia, los beneficios presentados en este trabajo deben entenderse como **proyecciones plausibles** sustentadas en un modelo exploratorio y en referencias de la industria, más que como resultados concluyentes obtenidos en condiciones operativas reales

Conviene precisar, además, que los beneficios proyectados en la sección 3.1.6.d corresponden a escenarios condicionados a una gestión del cambio efectiva, por lo que representan estimaciones iniciales de carácter exploratorio. En contraste, los beneficios presentados en las conclusiones integran dichas proyecciones con un análisis comparativo más amplio, sustentado en benchmarking internacional y literatura académica reciente. De esta manera, ambos niveles de análisis no son excluyentes, sino complementarios: los primeros aportan una visión localizada y dependiente de la realidad organizacional de Minera Candelaria, mientras que los segundos ofrecen un marco plausible de impactos potenciales al incorporar evidencia empírica de experiencias previas en la industria minera global

En términos cuantitativos, la construcción de un modelo predictivo entrenado sobre datos reales y técnicamente simulados permitió proyectar una reducción de hasta 25 % en fallas críticas, una mejora del 12 % en la disponibilidad operativa y un ahorro estimado en USD 300.000 anuales. Estos resultados son consistentes con hallazgos previos en la literatura, donde se ha evidenciado la efectividad de algoritmos como Random Forest, redes neuronales o XGBoost para anticipar anomalías en activos industriales (Barua et al., 2021; Abdelrahman et al., 2023).

Desde la dimensión cualitativa, el análisis de barreras organizacionales reveló que la adopción de IA requiere no solo inversión tecnológica, sino también liderazgo, capacitación técnica y una cultura organizacional abierta al cambio. La

resistencia al uso de sistemas automáticos de predicción, observada entre operadores y técnicos, confirma lo señalado por Deloitte (2023): más del 70 % de los fracasos en proyectos de transformación digital están vinculados a una deficiente gestión del cambio, más que a limitaciones técnicas.

Asimismo, el benchmarking con casos reales de empresas como Vale, BHP, CODELCO y Rio Tinto, ha evidenciado que los mejores resultados se obtienen cuando la IA se integra a sistemas SCADA, plataformas IoT y procesos de toma de decisiones en tiempo real. En este sentido, la elección de Siemens MindSphere como plataforma base, dada su compatibilidad con PCS7 y SINAMICS GH180, fue estratégica, ya que reduce fricciones de implementación y garantiza interoperabilidad con la infraestructura actual de la planta.

A modo de consolidación técnica, se recomienda formalizar una etapa piloto controlada, en la cual el modelo predictivo desarrollado se implemente de forma paralela al sistema de mantenimiento actualmente en uso. Esta estrategia permitiría validar progresivamente el rendimiento del algoritmo sin comprometer la operación continua del molino, facilitando ajustes iterativos en un entorno supervisado y de bajo riesgo. En paralelo, se sugiere ampliar la cobertura de sensorización mediante la incorporación de monitoreo continuo de variables adicionales como torque, presión de carga y condiciones ambientales internas y externas al equipo. De acuerdo con Ghasemi et al. (2023), la inclusión de estos parámetros podría incrementar la precisión del modelo en al menos un 10 %, al aportar señales complementarias para la detección anticipada de fallas.

Por otra parte, resulta fundamental actualizar los protocolos de recolección de datos, asegurando que toda la información generada por sensores, reportes manuales y sistemas SCADA cumpla con criterios rigurosos de trazabilidad, consistencia y estandarización. Una base de datos robusta y confiable es un prerequisite para garantizar la efectividad de los algoritmos de inteligencia artificial, ya que incluso los modelos más sofisticados pueden verse afectados por registros incompletos, mal etiquetados o inconsistentes. Finalmente, se propone avanzar hacia una siguiente etapa en la evolución del sistema, integrando modelos

prescriptivos que no solo identifiquen patrones de falla inminente, sino que además recomienden acciones concretas y optimizadas de mantenimiento, en función de la gravedad de la anomalía, los costos asociados y la disponibilidad de recursos técnicos. Este enfoque, ya implementado en plataformas avanzadas como Aspen Mtell (Arroyave-Tobón et al., 2021), permitiría pasar de una lógica de reacción predictiva a una gestión automatizada e inteligente del ciclo de vida del activo.

Para consolidar una implementación exitosa y sostenible de inteligencia artificial en la gestión de activos industriales, es crucial acompañar la transformación tecnológica con un conjunto de acciones estratégicas que fortalezcan las capacidades humanas y organizacionales. En primer lugar, se recomienda iniciar un programa de capacitación técnica especializado, orientado al personal operativo y de mantenimiento, con énfasis en el uso, comprensión y beneficios de la inteligencia artificial aplicada a procesos industriales. Esta formación no solo reducirá la resistencia cultural al cambio, sino que también empoderará a los equipos de terreno para interpretar correctamente las alertas predictivas y actuar en consecuencia, fortaleciendo la adopción del sistema en condiciones reales de operación.

Asimismo, se propone establecer una gobernanza transversal del proyecto, que integre representantes de mantenimiento, tecnologías de la información, operaciones y finanzas. Esta instancia debe asumir el liderazgo del seguimiento técnico y estratégico de la iniciativa, garantizando su alineación con los objetivos globales de la compañía y facilitando la toma de decisiones interdepartamentales. En complemento, es fundamental incluir indicadores clave de rendimiento (KPIs) específicos de transformación digital dentro del sistema de gestión. Entre ellos se pueden destacar: el porcentaje de alertas predictivas correctamente atendidas, la precisión global del modelo predictivo, y el ahorro operativo anual atribuible a su implementación. Estos indicadores permitirán cuantificar el impacto real del proyecto y sustentar decisiones futuras de inversión o escalabilidad.

Por otro lado, el proyecto debe vincularse explícitamente con las metas ESG de la organización, en particular con aquellas relacionadas con sostenibilidad

operacional. La disminución de fallas críticas y paradas no planificadas contribuye directamente a la eficiencia energética del proceso, reduciendo el consumo innecesario de recursos y las emisiones asociadas a mantenimientos de emergencia o ciclos productivos interrumpidos (ISO, 2014). Finalmente, se aconseja planificar desde el inicio la escalabilidad del modelo desarrollado. Una vez validado en el molino SAG, el sistema podría adaptarse a otros activos críticos como chancadores primarios, bombas de pulpa o sistemas de transporte, extendiendo su impacto a lo largo de toda la cadena de valor minera y consolidando un ecosistema predictivo robusto y replicable a nivel organizacional.

El presente trabajo abre múltiples líneas de investigación aplicadas. Entre ellas, destaca la posibilidad de desarrollar gemelos digitales del molino SAG para realizar simulaciones en entornos virtuales, permitiendo probar nuevas estrategias de operación antes de implementarlas en planta. También sería valioso explorar técnicas de deep learning como redes LSTM o transformers aplicadas a series temporales complejas, con el objetivo de anticipar fallas con mayor precisión y antelación. Por último, se recomienda profundizar el análisis económico del proyecto, incorporando variables como costos indirectos por detención de planta, impacto en cumplimiento de contratos de venta y rentabilidad global de la unidad de producción.

Capítulo 5. Plan de acción, presupuesto y hoja de ruta final

5.1. Planificación escalonada de la implementación de IA

La implementación efectiva de un sistema de inteligencia artificial (IA) en un entorno industrial complejo, como es el caso del molino SAG de Minera Candelaria, requiere una estrategia de adopción gradual que mitigue riesgos, asegure la adaptación de los equipos humanos y permita validar el desempeño tecnológico en fases controladas. En este sentido, se propone una hoja de ruta en tres etapas principales: piloto controlado, escalamiento progresivo y operación integrada.

En la **fase piloto**, el modelo predictivo desarrollado será implementado en paralelo al sistema actual de mantenimiento preventivo, permitiendo una validación en condiciones reales sin comprometer la operación continua. Esta etapa busca evaluar la precisión de las predicciones, la sensibilidad a condiciones variables y la capacidad de generar alertas útiles para el equipo de mantenimiento. La duración estimada de esta fase es de 4 a 6 meses.

En la **fase de escalamiento**, se extenderá la cobertura del modelo a otros subsistemas del molino, incorporando nuevas variables como condiciones ambientales, torque operativo y presión interna. Asimismo, se evaluará la integración plena con la plataforma Siemens MindSphere y su sincronización con el sistema de control distribuido PCS7. Esta etapa contempla la capacitación del personal, la automatización parcial de la toma de decisiones y la incorporación de dashboards predictivos.

La **fase de operación integrada** consolidará el modelo predictivo como herramienta central de planificación del mantenimiento. A partir de esta fase, se habilitarán funciones prescriptivas, en las que el sistema no solo identifique patrones de falla, sino que además recomiende acciones correctivas, agendas de intervención y optimización de recursos técnicos. Esta última etapa se considera alcanzable en un horizonte de 18 a 24 meses, siempre y cuando las fases anteriores muestren resultados satisfactorios.

Esta planificación escalonada se alinea con experiencias previas de implementación en CODELCO, BHP y Rio Tinto, donde la adopción progresiva permitió minimizar la resistencia organizacional y facilitar la transferencia tecnológica con mayor efectividad (Barua et al., 2021; Deloitte, 2023).

5.2. Matriz de costos estimados (CAPEX/OPEX)

Para dimensionar la viabilidad económica del proyecto, se ha construido una estimación preliminar de los costos asociados, diferenciando inversión inicial (CAPEX) y costos operativos recurrentes (OPEX).

CAPEX estimado:

Concepto	Descripción	Costo estimado (USD)
Sensores adicionales	Torque, presión, ultrasonido	85.000
Infraestructura TI	Servidores edge y almacenamiento	40.000
Plataforma IA	Licencia MindSphere (anual)	55.000
Desarrollo inicial del modelo	Consultoría, integración y validación	70.000
Total CAPEX		250.000

La inversión inicial estimada para desplegar un sistema de mantenimiento predictivo basado en inteligencia artificial en el molino SAG asciende a **USD 250.000**, una cifra que, si bien puede parecer significativa en términos absolutos, se justifica ampliamente al considerar el impacto operacional del equipo. Dentro de esta inversión se contempla la adquisición de sensores adicionales de última generación —particularmente para variables como torque, presión y condiciones estructurales internas— los cuales representan aproximadamente el 34 % del total. Esta sensorización avanzada permitirá ampliar la cobertura del modelo y mejorar sustancialmente la granularidad de los datos disponibles para entrenamiento.

Otro componente relevante del CAPEX corresponde a la infraestructura tecnológica necesaria para almacenar, procesar y transmitir grandes volúmenes de datos operacionales. La instalación de servidores locales (edge computing), redes industriales seguras y sistemas de respaldo constituye una inversión estratégica que otorga autonomía al sistema, reduce la latencia en la toma de decisiones y mitiga riesgos asociados a la dependencia de la nube. En paralelo, la adquisición de licencias para la plataforma Siemens MindSphere supone una ventaja comparativa, al integrarse de forma nativa con el sistema PCS7 existente en planta, evitando gastos adicionales de integración y personalización.

Adicionalmente, se considera una inversión en consultoría técnica especializada para el desarrollo inicial del modelo predictivo, que incluye el diseño de la arquitectura de datos, la selección de algoritmos óptimos y la validación exploratoria con registros históricos. Este componente representa una garantía

metodológica que permite acortar tiempos de implementación y minimizar riesgos técnicos en la etapa piloto. En conjunto, el CAPEX proyectado busca sentar las bases de un sistema escalable, auditable y alineado con las buenas prácticas internacionales en gestión de activos digitales (ISO, 2014).

OPEX anual estimado:

Concepto	Descripción	Costo estimado (USD)
Soporte técnico	Personal y mantenimiento de plataforma	45.000
Actualización de modelos	Reentrenamiento y ajuste de algoritmos	30.000
Formación continua	Capacitación y recertificaciones	20.000
Licencias de software	Renovación y mantenimiento	25.000
Total OPEX anual		120.000

La inversión se considera razonable en función de los beneficios proyectados: reducción del 25 % en fallas críticas, ahorro anual de USD 300.000 en mantenimiento correctivo, y mejora del OEE en al menos 12 %, lo cual genera retornos medibles a partir del primer año de operación (Ghasemi et al., 2023). Los costos operativos anuales asociados al funcionamiento y sostenibilidad del sistema predictivo ascienden a aproximadamente **USD 120.000**, un valor que debe analizarse bajo la lógica del retorno a mediano plazo. La mayor proporción de este OPEX corresponde a la contratación de soporte técnico especializado, responsable de garantizar la operatividad continua de la plataforma, el mantenimiento preventivo de los sensores y la resolución de posibles incidencias. Esta función resulta crítica, ya que la confiabilidad del sistema depende directamente de la estabilidad de sus componentes físicos y digitales.

Otro rubro importante se relaciona con la actualización periódica de los modelos de machine learning. La variabilidad operacional de la planta, las condiciones del mineral procesado y el envejecimiento natural del equipo exigen que los algoritmos sean reentrenados regularmente para mantener su capacidad

predictiva. Este proceso implica tanto el ajuste de hiperparámetros como la inclusión de nuevos eventos en el dataset histórico, y debe ser gestionado con rigurosidad técnica y trazabilidad documental.

La formación continua del personal también representa un eje clave del OPEX. Lejos de ser un gasto prescindible, la capacitación técnica permite que operadores y mantenedores comprendan la lógica del sistema, confíen en sus recomendaciones y adopten decisiones informadas. Tal como lo indica Deloitte (2023), las organizaciones que invierten en formación digital logran reducir en más de un 30 % la resistencia al cambio, acelerando la adopción de nuevas tecnologías y mejorando su eficacia operativa.

Finalmente, los costos asociados a licencias de software y mantenimiento de plataformas deben entenderse como parte de una estrategia de continuidad tecnológica. En lugar de comprometer la operación por desarrollos in-house sin soporte garantizado, optar por plataformas robustas con servicios de actualización y seguridad incluidos proporciona estabilidad y respaldo institucional. En conjunto, el OPEX estimado no solo es sostenible en función del ahorro proyectado en mantenimiento correctivo, sino que también permite preservar la eficacia del sistema a lo largo del tiempo, favoreciendo su expansión futura hacia otros activos críticos de la planta.

5.3. Cronograma con responsables e indicadores clave (KPIs)

El éxito de un sistema de mantenimiento predictivo basado en inteligencia artificial no puede evaluarse únicamente en términos tecnológicos o de implementación puntual, sino que requiere de un seguimiento estructurado a través de indicadores clave de desempeño (KPIs) que midan con precisión el impacto técnico, económico y organizacional del modelo. En este proyecto, los KPIs constituyen no solo herramientas de control, sino también elementos estratégicos que permiten validar hipótesis, justificar inversiones futuras y sustentar decisiones de escalamiento. Uno de los primeros indicadores a considerar es la **precisión del**

modelo predictivo, que refleja su capacidad para acertar en la detección de fallas reales, minimizando tanto los falsos positivos como los negativos. Alcanzar una precisión superior al 85 % es un umbral realista y deseable en contextos industriales de alta criticidad, según estudios previos (Barua et al., 2021). Esta métrica, junto con el F1-score y la matriz de confusión, permite analizar el equilibrio entre sensibilidad y especificidad del modelo, asegurando su utilidad práctica.

En segundo lugar, se debe evaluar la **reducción de fallas críticas**, es decir, el porcentaje de disminución en la frecuencia de fallas mayores tras la implementación del sistema. Con base en experiencias internacionales en minería (Ghasemi et al., 2023), se proyecta una reducción inicial del 20 %, lo cual representa un impacto directo en la disponibilidad operativa del molino y en la continuidad del proceso productivo. Este KPI se complementa con la medición del **OEE (Overall Equipment Effectiveness)**, indicador que resume la disponibilidad, el rendimiento y la calidad del equipo. Se espera un incremento del OEE entre un 10 % y un 12 % en los primeros 12 meses.

Los indicadores clásicos del mantenimiento, como el **MTBF (Mean Time Between Failures)** y el **MTTR (Mean Time To Repair)**, también son fundamentales para comprender la eficacia del nuevo modelo. Un aumento del MTBF indicará una mayor estabilidad operativa, mientras que una reducción del MTTR sugerirá una respuesta más eficiente y planificada frente a eventos críticos anticipados por la IA. Estos indicadores son esenciales para validar que el mantenimiento ha pasado de un enfoque reactivo o meramente preventivo a uno realmente predictivo. Otro KPI estratégico es el **porcentaje de alertas predictivas atendidas en tiempo real**, el cual mide el grado de apropiación del sistema por parte del personal técnico. Este indicador no solo permite evaluar la eficacia operativa del sistema de alertas, sino que también refleja el nivel de confianza que han desarrollado los equipos humanos frente a la inteligencia artificial. Para considerarse exitoso, este porcentaje debe superar el 90 % al final del primer ciclo anual.

Desde una perspectiva financiera, se incorpora el KPI de **ahorros operacionales anuales**, expresado en dólares estadounidenses, derivado de la

reducción de mantenimientos correctivos, disminución del uso de repuestos críticos y mejora en la programación de las intervenciones. Este indicador es especialmente relevante para la toma de decisiones estratégicas, ya que aporta una visión tangible del retorno sobre la inversión (ROI) del sistema implementado.

Complementariamente, se propone medir el **índice de adopción tecnológica**, que puede calcularse a través del número de usuarios activos del sistema (dashboard, reportes, plataformas integradas) o mediante encuestas internas aplicadas al personal operativo y de mantenimiento. Este KPI permite identificar barreras organizacionales y adaptar los procesos de capacitación y sensibilización según el nivel de madurez digital de la planta. Finalmente, se considera fundamental alinear el sistema con los compromisos de sostenibilidad de la empresa, incorporando un **KPI vinculado a metas ESG**, en particular al componente de eficiencia energética y reducción de emisiones. La disminución de fallas y paradas no planificadas contribuye a optimizar el consumo energético del molino, reducir emisiones asociadas a intervenciones de urgencia y generar condiciones más seguras para el personal. Esta alineación estratégica fortalece la legitimidad del proyecto frente a los stakeholders internos y externos.

Fase	Actividades principales	Duración	Responsables	KPIs
Fase 1: Piloto controlado	Integración inicial, pruebas de modelo, dashboards	6 meses	Ingeniería Mantenimiento + TI	Precisión >80%, Tasa de alertas útiles >70%
Fase 2: Escalamiento	Sensorización extendida, capacitación, integración MindSphere	8 meses	TI + RRHH + Ingeniería	% personal capacitado >90%, Tiempo medio de respuesta <48h
Fase 3: Operación integrada	Automatización de alertas, KPIs prescriptivos, monitoreo continuo	10 meses	Gerencia de Operaciones + Finanzas	Ahorro anual ≥USD 250.000, ROI ≥25%

La gobernanza del proyecto estará liderada por un Comité Transversal de Transformación Digital, cuya misión será garantizar la alineación estratégica, la correcta asignación de recursos y el cumplimiento de los hitos establecidos. Esta instancia deberá reunirse trimestralmente para realizar seguimiento y ajustes operativos. En conjunto, estos KPIs permiten construir un marco robusto de seguimiento y evaluación que no solo mide el desempeño del sistema en términos técnicos, sino que articula su contribución al valor organizacional, a la sostenibilidad operativa y a la transformación digital de la industria minera. Se propone un cronograma detallado de implementación, distribuido en tres fases, con responsables por área y KPIs asociados a cada hito. Este cronograma contempla un horizonte total de 24 meses.

Bibliografía

- Abdelrahman, H., Elazab, A., & Soliman, H. (2023). Predictive maintenance using machine learning: A systematic review. *Engineering Applications of Artificial Intelligence*, 117, 105672. <https://doi.org/10.1016/j.engappai.2022.105672>
- Arroyave-Tobón, J. A., Vélez, J. A., & Gaitán-Angulo, M. V. (2021). Machine learning for predictive maintenance in mining: Review and implementation trends. *Revista Facultad de Ingeniería Universidad de Antioquia*, (100), 53–65. <https://doi.org/10.17533/udea.redin.20210536>
- Barua, S., Ahmed, M. U., & Mourshed, M. (2021). A review of machine learning applications for maintenance prediction. *Measurement*, 178, 109397. <https://doi.org/10.1016/j.measurement.2021.109397>
- Cochilco. (2024). *Estadísticas del mercado del cobre 2023*. Comisión Chilena del Cobre. <https://www.cochilco.cl>
- Crespo Márquez, A. (2020). *The maintenance management framework: Models and methods for complex systems maintenance*. Springer. <https://doi.org/10.1007/978-3-030-39914-1>
- Deloitte. (2023). *Mining industry outlook: Technology and transformation*. Deloitte Insights. <https://www2.deloitte.com>
- Fundación Chile. (2023). *Reporte de transformación digital en minería 2023*. Fundación Chile. <https://www.fch.cl>

- Galar, D., Kumar, U., Stenström, C., & Parida, A. (2019). Maintenance analytics: The key to unlocking the power of machine learning in predictive asset management. *Journal of Quality in Maintenance Engineering*, 25(3), 322–338. <https://doi.org/10.1108/JQME-05-2018-0034>
- Ghasemi, S., Powell, M. S., & Morrison, R. (2023). Digital twins and advanced simulation of SAG mill performance. *Minerals Engineering*, 200, 107204. <https://doi.org/10.1016/j.mineng.2023.107204>
- ISO. (2014). *ISO 55000:2014 Asset management – Overview, principles and terminology*. International Organization for Standardization.
- Parida, A., Kumar, U., Galar, D., & Stenström, C. (2015). Performance measurement and management for maintenance: A literature review. *Journal of Quality in Maintenance Engineering*, 21(1), 2–33. <https://doi.org/10.1108/JQME-07-2013-0043>
- PwC. (2022). *Mine 2022: A critical transition*. PricewaterhouseCoopers. <https://www.pwc.com>
- Ríos, P., & Serrano, R. (2022). Metodologías mixtas en investigación aplicada: una revisión crítica. *Revista de Investigación Educativa*, 40(1), 1–20. <https://doi.org/10.6018/rie.473711>
- Saunders, M., Lewis, P., & Thornhill, A. (2019). *Research methods for business students* (8th ed.). Pearson Education.
- SERNAGEOMIN. (2023). *Anuario de la minería de Chile 2022*. Servicio Nacional de Geología y Minería. <https://www.sernageomin.cl>
- Siemens, 2023. *MindSphere – Industrial IoT as a service*. Disponible en: <https://new.siemens.com/global/en/products/software/mindsphere.html>
- Tashakkori, A., & Teddlie, C. (2010). *Mixed methodology: Combining qualitative and quantitative approaches*. Sage Publications.
- Wang, J., Ma, Y., Zhang, L., Gao, R. X., & Wu, D. (2020). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, 54, 361–378. <https://doi.org/10.1016/j.jmsy.2020.02.004>
- Yin, R. K. (2018). *Case study research and applications: Design and methods* (6th ed.). Sage Publications.
- Zheng, Y., Kong, X., Wang, Y., & Wang, S. (2020). A survey of maintenance strategy using AI and big data in industry. *Computers in Industry*, 123, 103300. <https://doi.org/10.1016/j.compind.2020.103300>

ANEXOS

Anexo1. Pseudocódigo del modelo predictivo de fallas del molino SAG

INICIO

// 1. Carga y preprocesamiento de datos históricos

Importar datos de vibración, temperatura, torque, consumo energético y fallas desde PCS7, sensores IoT y CMMS

Eliminar registros nulos o duplicados

Normalizar escalas de variables (Min-Max Scaling)

Imputar valores faltantes mediante media ponderada o regresión

Crear etiquetas de falla (binario: 1 = falla crítica, 0 = normal)

// 2. División de datos

Dividir dataset en entrenamiento (70%) y validación (30%)

Aplicar segmentación por condiciones operativas (baja, media, alta carga)

// 3. Entrenamiento de modelos

Inicializar modelos:

Random Forest (RF)

XGBoost

Red Neuronal Multicapa (ANN)

Para cada modelo:

Ajustar hiperparámetros con validación cruzada

Entrenar con datos históricos etiquetados

Evaluar métricas: Accuracy, Recall, Precision, F1-Score

// 4. Selección del mejor modelo

Comparar desempeño entre modelos

Seleccionar modelo con mejor equilibrio precisión/recall (preferiblemente F1-Score > 0.80)

// 5. Implementación en entorno de prueba

Conectar el modelo entrenado a datos en tiempo real desde PCS7 y sensores IoT

Ejecutar predicciones cada 5 minutos

Si predicción = 1 (riesgo de falla crítica):

Generar alerta predictiva

Registrar alerta en el dashboard Siemens MindSphere

Notificar al equipo de mantenimiento vía sistema DCS

// 6. Validación operativa

Comparar alertas con eventos reales ocurridos

Actualizar modelo con nuevos datos cada 30 días (aprendizaje incremental)

// 7. Reporte de indicadores

Calcular KPIs mensuales:

Fallas evitadas

Reducción de tiempo de inactividad

Ahorros estimados

Precisión del sistema

FIN

Notas técnicas:

- Este pseudocódigo simula un ciclo continuo de aprendizaje supervisado, adaptado a entornos industriales reales, en los que los datos son generados permanentemente.
- El modelo puede ser ejecutado en entornos Python (con scikit-learn, XGBoost y TensorFlow), desplegado a través de una API conectada al sistema Siemens MindSphere.
- Se sugiere incorporar un mecanismo de *drift detection* en versiones posteriores, para identificar cambios en los patrones operacionales que afecten la precisión predictiva.