

Mantenimiento predictivo con aprendizaje automático en camiones de acarreo y palas hidráulicas sector minero

Por: Robert Martín (Ph.D) y René Álvarez (Ph.D)
AIPredictive una UEN de Apsoluti Business S.L.
<https://aipredictive.net>

1. Resumen

Los camiones de acarreo y las palas hidráulicas son los equipos que sostienen la producción de una mina. Cuando uno de ellos falla sin aviso, se detiene la producción, se afecta a toda la flota y puede haber riesgos para las personas. El mantenimiento predictivo busca evitarlo: utiliza los datos que los propios equipos generan para detectar que un componente se está deteriorando y estimar cuánto tiempo de operación le queda.

Este informe explica, sin recurrir a matemática ni términos tecnológicos innecesarios, cómo funciona esa tecnología, qué resultados se han reportado en un estudio reciente en una mina de cobre, qué alternativas existen y qué límites deben tenerse presentes. En la sección final se propone un itinerario de formación para los equipos de ingeniería que están aprendiendo aprendizaje automático (ML) y mantenimiento predictivo (PdM).

Ideas principales

- El valor no está en el algoritmo, sino en detectar la falla con la anticipación suficiente para actuar. Capacidad para tomar decisiones con la predicción ofrecida por los modelos.
- El estudio de referencia reporta una exactitud de 92,47 % al clasificar el estado de salud del equipo y un error medio de unas 98 horas al estimar la vida útil remanente.
- Los resultados provienen de una sola mina y de 12 unidades: justifican un piloto, no una proyección de ahorros.
- La calidad de los datos y de los registros de falla condiciona el resultado más que la sofisticación del modelo.
- Dominar estos métodos exige competencias combinadas de confiabilidad, datos, modelado y gestión del cambio.
- Desarrollar criterio para seleccionar dentro de la amplia variedad existente de algoritmos el o los más adecuados para el activo en estudio.
- No necesariamente se debe llegar a ser científico de datos para implantar esta clase de tecnologías, se requiere una comprensión profunda de la ingeniería de mantenimiento.

2. Por qué importa el mantenimiento en minería

Los equipos mineros trabajan de forma continua con cargas elevadas, material abrasivo y temperaturas variables. Ese régimen acelera el desgaste de componentes críticos como cajas de transmisión, rodamientos, bombas hidráulicas y mandos finales. Una falla no planificada genera pérdida de producción, costos de reparación mayores, esperas por repuestos y, en el peor caso, situaciones de riesgo para el personal.

Existen tres maneras de gestionar el mantenimiento:

- **Correctivo:** se repara cuando el equipo falla. Es adecuado solo si la consecuencia de la falla es baja.
- **Preventivo por calendario:** se intervienen los componentes cada cierto número de horas, estén o no deteriorados. Reduce fallas, pero desperdicia vida útil y no evita fallas entre intervenciones.
- **Predictivo o basado en condición:** se interviene cuando los datos indican deterioro real. Requiere instrumentación, datos de calidad y capacidad de análisis.

3. Qué es el mantenimiento predictivo

El mantenimiento predictivo responde dos preguntas sobre cada componente crítico:

1. **¿En qué estado de salud se encuentra hoy?** El estudio de referencia usa cuatro estados: normal, degradación leve, degradación severa y falla inminente. A esto se le llama predicción de fallas o diagnóstico.
2. **¿Cuántas horas de operación le quedan?** Es la vida útil remanente, conocida por sus siglas en inglés, RUL. A esto se le llama pronóstico.

Para que la predicción tenga valor, debe cumplirse una condición básica: el aviso debe llegar antes de que falle el equipo y con más anticipación que el tiempo que toma reaccionar (diagnosticar, conseguir el repuesto, programar la parada y ejecutar el trabajo). Si el sistema avisa con dos días de anticipación y el repuesto tarda quince, la predicción no sirve, por precisa que sea.

4. Cómo funciona la tecnología

4.1 Los datos de partida

Cada equipo cuenta con sensores que registran vibraciones, temperaturas, presiones hidráulicas, velocidad de giro y carga transportada, entre otras variables. Cada sensor genera una serie de valores en el tiempo. Además, el sistema de gestión de mantenimiento guarda el historial de fallas y reparaciones. El modelo aprende comparando ambas cosas: cómo se comportaban las señales antes de cada falla conocida.

4.2 El modelo del estudio: red convolucional temporal con atención

El estudio utiliza un tipo de red neuronal llamada red convolucional temporal (TCN), combinada con un mecanismo de atención. Sus características, descritas en lenguaje no matemático, son las siguientes.

- **Detección automática de patrones.** El modelo aprende por sí mismo qué formas de la señal son relevantes (un aumento gradual de vibración, un pico repetitivo, una deriva de temperatura). En el análisis tradicional, el ingeniero define de antemano qué indicadores calcular; aquí esa selección se obtiene del entrenamiento con datos históricos.
- **Solo usa información del pasado.** En cada instante, el modelo considera únicamente lo ya ocurrido. Es imprescindible para operar en tiempo real y evita errores de evaluación que inflan los resultados.
- **Análisis a distintas escalas de tiempo.** Las primeras capas del modelo examinan variaciones rápidas y las capas posteriores examinan tendencias más lentas, ampliando progresivamente la ventana de observación sin aumentar en exceso el costo de cálculo.
- **Estabilidad en el entrenamiento.** La arquitectura incorpora atajos internos que permiten entrenar redes profundas de forma estable.
- **Atención.** Un módulo adicional determina qué momentos de la ventana de observación y qué sensores son más informativos para cada decisión, y da menos peso al resto. Además de mejorar el resultado, permite al ingeniero revisar en qué señales se apoyó una alerta.
- **Una sola red para dos tareas.** El mismo modelo clasifica el estado de salud y estima la vida remanente. Ambas tareas se entrenan juntas porque comparten información: un equipo próximo a la falla presenta a la vez un estado degradado y poca vida restante.

4.3 Qué no hace el modelo

- No identifica la causa raíz de la falla. Los pesos de atención indican correlación con la decisión, no causalidad.
- No ve más allá de su ventana de observación. En el estudio, la ventana equivale a menos de un minuto de datos, mientras que el deterioro de un rodamiento avanza durante semanas; las tendencias lentas deben incorporarse por otra vía, como indicadores promediados por hora o turno.
- No sustituye la inspección ni el criterio del analista de condición, al menos en las etapas iniciales.

5. Resultados del estudio de referencia

Los autores del estudio (1) tomado como referencia para este artículo, utilizaron 18 meses de datos de camiones y palas hidráulicas de una mina de cobre a cielo abierto en China: 12 unidades y 847 eventos

de falla. Las pruebas se realizaron sobre equipos completos reservados para evaluación, lo que constituye un buen criterio metodológico.

Indicador	Resultado	Significado práctico
Exactitud del diagnóstico	92,47 %	Aproximadamente 92 de cada 100 clasificaciones de estado son correctas
Exactitud ante una unidad no vista	91,23 %	Estimación más realista de desempeño en un equipo nuevo
Error de vida remanente (RMSE)	98,45 h	Error típico global de la estimación
Error en fase temprana / media / tardía	142 / 88 / 54 h	El modelo es más preciso cuanto más cerca está la falla
Sesgo	-3,2 %	Tiende a anticipar la falla algo antes de lo real, lo cual es prudente
Tiempo de respuesta y tamaño	15 ms, 47 MB	Puede ejecutarse en computadores industriales de faena

Lectura de los resultados

- Ninguna falla inminente fue clasificada como operación normal, un resultado relevante para la seguridad.
- El error más frecuente fue confundir degradación leve con estado normal (cerca de 5 % de esos casos), lo que retrasa una intervención. Los umbrales de alerta deben ajustarse al costo real de cada tipo de error.
- Con 54 horas de incertidumbre en fase tardía (unos tres días de operación, según el régimen de cada faena), el sistema permite reprogramar en la próxima ventana de parada, pero no gestionar repuestos de entrega prolongada.
- Con 20 % de sensores fuera de servicio, el error sube a 112 horas: el desempeño se degrada de forma gradual y no abrupta.

6. Alternativas al algoritmo del estudio

La red convolucional temporal no es la única opción ni siempre la más conveniente. La elección depende de los datos disponibles.

Enfoque	Cuándo es apropiado	Limitación principal
Umbral y normas de vibración	Siempre, como capa base de alarmas	No estima vida remanente; falsas alarmas con carga variable
Árboles de decisión sobre indicadores diseñados (gradient boosting, random forest)	Pocos datos o pocas fallas; se requiere trazabilidad	Exige ingeniería de indicadores por especialistas
Análisis de supervivencia (Weibull, Cox)	Muchos reemplazos preventivos y pocas fallas reales	Menor precisión de corto plazo
Modelos estadísticos de degradación (filtro de Kalman, procesos de Wiener)	Degradación gradual con un buen índice de salud	Depende de la calidad del índice
Modelos físicos y gemelos digitales	Componentes críticos bien conocidos	Alto costo de construcción y calibración
Detección de anomalías no supervisada	No existen fallas etiquetadas	Detecta cambios, pero no su naturaleza ni la vida restante
LSTM y otras redes recurrentes	Series de longitud moderada	Entrenamiento lento; dificultad con secuencias muy largas
Transformers	Grandes volúmenes de datos y secuencias largas	Alto costo de cómputo; orientados a pronósticos de largo plazo

Criterio general: partir de soluciones simples y aumentar la complejidad solo si la mejora justifica el costo y la menor transparencia. Una secuencia habitual es umbrales, detección de anomalías, árboles de decisión con indicadores bien diseñados y, finalmente, aprendizaje profundo. Se descartan como solución principal las máquinas de vectores de soporte para la vida remanente, las redes recurrentes simples, los transformers estándar sobre señal cruda de alta frecuencia y los modelos físicos aplicados a toda la flota.

7. Limitaciones que deben conocerse

- Los datos provienen de un solo trabajo y de 12 unidades; la generalización a otras minas, materiales o modelos de equipo no está demostrada.
- No se explica con claridad cómo se obtuvieron trayectorias completas hasta la falla en una flota gestionada para evitarlas.
- Las pruebas de significancia estadística miden la variabilidad del entrenamiento, no la de la población de equipos.
- Las etiquetas de estado provienen de registros de mantenimiento cuya consistencia limita la exactitud, especialmente en estados intermedios.

- No se presenta una evaluación económica: paradas evitadas, costo de falsas alarmas o ahorro en repuestos.
- Los datos crudos de vibración solo están disponibles bajo solicitud, lo que limita la reproducibilidad independiente.
- El texto contiene inconsistencias editoriales, como referencias a secciones inexistentes; se recomienda contrastar sus citas con la literatura primaria.

8. Qué implica para una organización

8.1 Requisitos previos

- Análisis de criticidad de los modos de falla para elegir dónde aplicar la tecnología.
- Sensores calibrados, relojes sincronizados y telemetría confiable.
- Registro riguroso de fallas y reparaciones, con distinción entre falla funcional, reemplazo por condición y reemplazo preventivo.
- Un responsable que vincule el análisis de datos con la planificación de mantenimiento.

8.2 Implementación por fases

N.º	Fase	Resultado esperado
1	Diagnóstico	Modos de falla priorizados y brechas de datos identificadas
2	Preparación de datos	Base de datos etiquetada y auditada
3	Línea base	Alarmas por umbral e indicadores clásicos documentados
4	Piloto en paralelo (3 a 6 meses)	Modelo funcionando sin tomar decisiones; se compara con los hallazgos reales
5	Integración	Alertas convertidas en órdenes de trabajo y reservas de repuestos
6	Escalamiento y gobierno	Monitoreo de deriva, reentrenamiento y revisión periódica

8.3 Indicadores de seguimiento

- Del proceso: disponibilidad física, tiempo medio entre fallas, tiempo medio de reparación, porcentaje de mantenimiento no planificado y costo por tonelada movida.
- Del sistema: proporción de fallas detectadas con anticipación suficiente, falsas alarmas por cada mil horas de operación, error de vida remanente medido en producción y vida remanente de los componentes retirados por alerta.

8.4 Riesgos principales

- Etiquetas inconsistentes: se controlan con catálogos normalizados y auditoría de registros.
- Sobreajuste a pocas máquinas: se controla validando por equipo y en otra operación.
- Falsas alarmas que erosionan la confianza: se controlan con umbrales según costo del error y validación humana inicial.
- Dependencia excesiva del modelo: se controla manteniendo inspecciones críticas y competencias de diagnóstico del personal.
- Cambios de carga, material o estación: se controlan con monitoreo de deriva y reentrenamiento programado.

9. Glosario

Término	Definición
Aprendizaje automático (ML)	Conjunto de técnicas en las que un programa aprende patrones a partir de datos históricos, en lugar de seguir reglas escritas de antemano.
Mantenimiento predictivo (PdM)	Estrategia que interviene según la condición real del equipo, estimada a partir de datos.
Vida útil remanente (RUL)	Tiempo de operación estimado antes de que el componente alcance la falla.
Serie temporal	Secuencia de mediciones ordenadas en el tiempo.
Intervalo P-F	Tiempo entre el momento en que la falla potencial es detectable y el momento en que se convierte en falla funcional.
Censura de datos	Situación en la que un componente se reemplaza antes de fallar y, por tanto, no se conoce su vida real.
Deriva del modelo	Pérdida gradual de exactitud cuando las condiciones reales se alejan de las de entrenamiento.
Línea base	Método simple contra el cual se compara un modelo más complejo.
CMMS	Sistema informático de gestión de mantenimiento, donde se registran órdenes de trabajo, fallas y repuestos.

10. Formación del equipo: competencias que deben desarrollar los ingenieros

Un equipo que aprende ML y PdM a la vez enfrenta un riesgo frecuente: que los ingenieros de mantenimiento aprendan a ejecutar modelos sin comprender el proceso de falla, o que los especialistas en datos construyan modelos sin comprender el equipo. El dominio se logra combinando ambas

miradas. Esta sección propone las competencias necesarias, una ruta de aprendizaje y criterios para verificar el avance.

10.1 Mapa de competencias

Área	Qué debe dominar el ingeniero	Evidencia de dominio
Ingeniería de confiabilidad	Modos y mecanismos de falla, FMECA, análisis de criticidad, RCM, curva P-F, distribuciones de vida (Weibull), análisis de causa raíz	Priorizar modos de falla y justificar cuáles admiten monitoreo por condición
Monitoreo de condición	Análisis de vibraciones, termografía, análisis de aceite, presiones hidráulicas; normas ISO 14224, ISO 13374, ISO 13381-1 e ISO 55000	Interpretar un espectro y un análisis de aceite y contrastarlos con una alerta del modelo
Instrumentación y adquisición de datos	Tipos de sensores, muestreo, filtrado, sincronización, calibración, telemetría y almacenamiento	Auditar una cadena de medición e identificar fuentes de error
Datos y programación	Python, manejo de series temporales, limpieza, valores faltantes, control de versiones, SQL	Construir un flujo reproducible de preparación de datos
Estadística y probabilidad	Distribuciones, incertidumbre, intervalos de confianza, contrastes de hipótesis, análisis de supervivencia y datos censurados	Explicar por qué una mejora es o no estadísticamente creíble
Fundamentos de aprendizaje automático	Aprendizaje supervisado y no supervisado, sobreajuste, validación cruzada, métricas de clasificación y regresión, árboles de decisión y boosting	Entrenar y comparar modelos clásicos sobre indicadores diseñados
Aprendizaje profundo para series temporales	Redes convolucionales y recurrentes, TCN, atención, entrenamiento multitarea, ajuste de parámetros	Reproducir un modelo publicado y evaluar si supera a la línea base
Validación rigurosa	Partición por equipo o trayectoria, prevención de fuga de información, validación en otra faena, monitoreo de deriva	Diseñar un protocolo de validación que resista una auditoría
Integración operativa	CMMS, órdenes de trabajo, planificación, gestión de repuestos, reglas de urgencia, ciclo de retroalimentación	Convertir una alerta en una acción programada con repuesto reservado
Evaluación económica	Costo de falla, costo de falsa alarma, tasa de captura, caso de negocio por modo de falla	Presentar un caso de negocio con supuestos explícitos
Comunicación y gestión del cambio	Explicar resultados a operaciones y gerencia, gestión de expectativas, capacitación de técnicos	Exponer límites y riesgos del modelo a un público no técnico
Ética, seguridad y gobierno de datos	Ciberseguridad industrial, propiedad de los datos, trazabilidad de decisiones, responsabilidad ante falsos negativos	Definir quién decide y quién responde cuando el modelo y la inspección discrepan

10.2 Ruta de aprendizaje por etapas

Etapa	Duración orientativa	Contenidos y entregable
1. Base común	1 a 2 meses	Confiabilidad y PdM para todo el equipo; introducción a Python y estadística. Entregable: análisis de criticidad de un subsistema real.
2. Datos y línea base	2 a 3 meses	Adquisición y limpieza de datos, indicadores de vibración, modelos clásicos y supervivencia. Entregable: línea base documentada con métricas.
3. Aprendizaje profundo	2 a 3 meses	Redes para series temporales, TCN y atención, validación rigurosa. Entregable: comparación honesta entre el modelo profundo y la línea base.
4. Piloto en paralelo	3 a 6 meses	Operación del modelo en modo sombra, medición de captura y falsas alarmas. Entregable: informe de desempeño frente a los hallazgos reales.
5. Integración y gobierno	Continuo	Conexión con el CMMS, reglas de decisión, monitoreo de deriva, reentrenamiento. Entregable: procedimiento operativo formal.

10.3 Perfiles y distribución de roles

No todos los integrantes necesitan la misma profundidad. Una distribución razonable es la siguiente:

- **Ingeniero de confiabilidad:** define modos de falla, criticidad, criterios de etiquetado y reglas de decisión. Requiere comprensión conceptual del modelo, no necesariamente su programación.
- **Analista de condición:** valida las alertas con vibraciones, aceite y termografía. Es el puente entre el modelo y el equipo.
- **Ingeniero de datos y modelado:** construye los flujos de datos y los modelos, y mide su desempeño. Requiere formación en estadística y aprendizaje automático, con conocimiento básico del equipo.
- **Planificador de mantenimiento:** transforma las alertas en órdenes de trabajo y gestiona repuestos y ventanas de parada.
- **Responsable del proyecto:** gestiona el caso de negocio, las expectativas y la relación con operaciones.

El objetivo es que cada persona domine su área y comprenda lo suficiente de las demás como para dialogar con precisión.

10.4 Errores frecuentes en la formación

Nuestra experiencia como formadores en PdM/IA/ML/DL en diferentes empresas que exploran la posibilidad de aplicar estas tecnologías, nos llevan a identificar los siguientes errores habituales en las compañías:

- Comenzar por el algoritmo más sofisticado sin haber construido una línea base simple.
- Centrar el 80% de la atención en el algoritmos, dejando poco espacio para desarrollar Feature Engineering necesaria para configurar correctamente los modelos de datos.
- Evaluar con particiones aleatorias que mezclan datos de un mismo equipo entre entrenamiento y prueba, lo cual infla los resultados.
- Ignorar la censura de datos y tratar los reemplazos preventivos como si fueran fallas.
- Reportar solo la exactitud global sin considerar el costo desigual de los errores.
- Interpretar los pesos de atención como causa raíz.
- Formar únicamente a especialistas en datos, sin involucrar a técnicos y planificadores.

10.5 Cómo verificar que el equipo de ingenieros domina el método

Puede explicar, sin recurrir a fórmulas, qué hace el modelo, qué no hace y en qué condiciones falla.

Puede reproducir los resultados de un estudio publicado y contrastarlos con una línea base clásica.

Diseña validaciones por equipo y distingue el desempeño en datos conocidos del desempeño en equipos nuevos.

Cuantifica la anticipación de las alertas frente al tiempo de respuesta real de la operación.

Mantiene indicadores de proceso y de modelo en producción, y detecta la deriva.

Sustenta con datos propios el caso de negocio y las decisiones de escalamiento.

10.6 Conclusión

Dominar el mantenimiento predictivo con aprendizaje automático no equivale a aprender una herramienta de software. Supone integrar el conocimiento físico del equipo (feature engineering), la disciplina en el manejo de datos, el rigor estadístico en la validación y la capacidad de llevar una predicción hasta una decisión de mantenimiento ejecutada a tiempo. Un equipo que incorpore estas competencias de forma progresiva, empezando por soluciones simples y verificables, estará en condiciones de evaluar críticamente estudios como el aquí reseñado y de adaptarlos a su propia operación.

Referencia

Mao, J., Xu, W., Li, D., Zhu, H. y Yang, F. (2026). A TCN-Attention fusion model for fault prediction and remaining useful life estimation of large-scale mining equipment. Scientific Reports, 16, 13746.