

Predicción del tiempo de vida útil restante de una bomba Warman 650

Aplicación de la técnica XGBoost de Machine Learning en una empresa minera a gran escala

87,841

registros analizados

9

variables de proceso

62

días de operación

El área de molienda concentra el riesgo operacional

El área de molienda es determinante para la continuidad de toda la unidad minera: allí se reduce el tamaño del mineral y se transporta la pulpa hacia los hidrociclones.

Las bombas Warman 650 son responsables de trasladar el lodo desde los molinos SAG hacia los hidrociclones. Su falla detiene el flujo de mineral y compromete la producción diaria.

140,000 t

de mineral procesado por día dependen de este circuito

2

Molinos SAG

Reducen el tamaño del mineral con bolas de acero

6

Bombas Warman 650

Transportan la pulpa hacia los hidrociclones


7

Hidrociclones (promedio)

Separan las partículas finas del lodo resultante

Más de la mitad de las intervenciones son correctivas

48 intervenciones por cambio de componentes mayores (2023)



■ Alcanzaron 1,000 h de vida útil ■ Fallas prematuras (correctivas)

52 %

de las intervenciones no alcanzó la vida útil
estimada de 1,000 horas

≤ 10 h

de parada por cada intervención en la bomba
Warman 650

9.7 t/h

de producción perdida por cada hora de
intervención

La baja anticipación de fallas en componentes mayores genera paradas inesperadas, mayor costo de mantenimiento correctivo y pérdida directa de producción.

Formulación del problema

PROBLEMA GENERAL

¿De qué manera se puede predecir de forma eficiente el tiempo de vida útil restante de una bomba Warman 650 en una empresa minera a gran escala?

P1

Precisión

¿Cómo predecir con precisión la vida útil restante considerando las condiciones operativas reales de la mina?

P2

Datos

¿Qué métodos permiten recopilar e integrar de forma efectiva los datos históricos de rendimiento y vida útil?

P3

Tiempo real

¿Cómo implementar predicción en tiempo real que alerte a los operadores antes de que ocurra la falla?

Objetivos de la investigación

OBJETIVO GENERAL

Determinar la influencia de la técnica XGBoost del Machine Learning en la predicción del tiempo de vida útil de una bomba Warman 650 en una empresa minera a gran escala.

XGBoost · Extreme Gradient Boosting

OE1

Evaluar la precisión del método XGBoost frente a otros métodos de predicción existentes.

OE2

Analizar el impacto de la calidad y cantidad de datos en la precisión de la predicción.

OE3

Desarrollar un sistema de predicción en tiempo real que alerte a los operadores ante posibles fallas.

Objetivos específicos

Hipótesis de trabajo

HIPÓTESIS GENERAL ALTERNATIVA

La técnica XGBoost del Machine Learning influye en la predicción del tiempo de vida útil de una bomba Warman 650 en una empresa minera a gran escala.

HE1

Superioridad frente a métodos tradicionales

XGBoost superará significativamente la precisión de modelos tradicionales, como la regresión lineal, al estimar la vida útil restante.

HE2

Dependencia de la calidad del dato

La precisión aumentará de forma significativa con datos históricos más completos y de mayor calidad sobre rendimiento y condiciones de operación.

HE3

Detección de patrones ocultos

El método identificará patrones no detectables por métodos tradicionales, significativamente correlacionados con la vida útil restante.

Pilares conceptuales del modelo

Predicción de RUL

Estimar el tiempo restante antes de la falla para anticipar intervenciones.

Aprendizaje profundo

RNN, LSTM, CNN, redes de atención y autoencoders para patrones no lineales.

Fusión de sensores

Vibración, temperatura, presión y corriente aportan señales complementarias.

Transferencia de aprendizaje

Aprovecha conocimiento de un dominio con datos abundantes hacia otro escaso.

Machine Learning clásico

SVM, Random Forest, Gradient Boosting, XGBoost y MLP sobre datos tabulares.

Selección de características

PCA, importancia de variables y regularización reducen la dimensionalidad.

Mantenimiento predictivo

Programa la intervención según el estado real y la degradación proyectada.

Aplicaciones industriales

Petróleo y gas, manufactura, aviación, energía y transporte.

Dimensiones para evaluar el modelo

1

Precisión

Estimaciones de RUL lo más cercanas posible al valor real.

2

Robustez

Buen desempeño ante datos ruidosos, atípicos y condiciones variables.

3

Eficiencia

Predicciones rápidas con consumo razonable de cómputo y memoria.

4

Interpretabilidad

Explicar qué factores conducen a cada estimación de vida útil.

5

Escalabilidad

Manejar grandes volúmenes de datos y múltiples fuentes de sensores.

6

Rendimiento

Capacidad global del modelo integrando todas las métricas anteriores.

7

Desgaste

Deterioro gradual por uso, carga y condiciones ambientales.

8

Condiciones de operación

Carga, temperatura y presión bajo las que funciona el equipo.

Variable independiente: técnica XGBoost · Variable dependiente: tiempo de vida útil restante (RUL)

PARTE – II

Entendimiento de los datos

Dataset de operación de la bomba PU-001 — carga, limpieza, control de calidad y análisis exploratorio previo al modelado con XGBoost.

El dataset PU-001 en cifras

87,841**registros**

una medición por minuto

62 días**de operación**

01-feb al 03-abr de 2026

9**variables numéricas**

de 13 columnas originales

0**nulos y duplicados**

tras la limpieza inicial

Preparación aplicada

1

Eliminación de columnas vacías

Se descartaron 3 columnas sin nombre ni datos (Unnamed 10-12): 13 → 10 columnas.

2

Estandarización del tiempo

129 registros de tiempo no se parsearon; se reconstruyó la serie a frecuencia de 1 minuto con 100 % de coincidencia frente a los timestamps válidos.

3

Indexación temporal


La variable tiempo pasó a ser el índice ordenado del DataFrame, habilitando el análisis de series de tiempo.

Variables de proceso monitoreadas

Variable	Unidad	Media	Mediana	Mínimo	Máximo
Velocidad	%	88.51	95.10	0.00	98.40
Flujo	m ³ /h	7,258.85	7,749.24	0.00	9,084.25
Presión	kPa	113.27	124.13	-9.10	146.56
Ciclones	#	6.97	7.00	3.00	9.00
Densidad	%	60.80	63.93	-1,130.93	212,856.47
Temp. motor	°C	94.15	101.00	0.00	118.00
Potencia	kW	1,492.03	1,642.00	0.00	1,894.00
Vibración motor	mm/s	0.172	0.178	-0.023	0.500
Vibración porta rodamientos	mm/s	0.046	0.045	0.001	—

Los valores mínimos en cero de velocidad, flujo, potencia y temperatura corresponden a paradas del equipo. Los máximos de densidad y los valores negativos evidencian errores de instrumentación que deberán tratarse antes del modelado.

Control de calidad: qué hay que corregir



● Sin nulos ni duplicados

Las 9 variables tienen 87,841 registros completos y no existen filas duplicadas.

● Ceros = paradas, no errores


Los ceros simultáneos en velocidad, flujo y potencia representan detenciones reales del equipo y deben etiquetarse como tal.

● Valores físicamente imposibles

Densidad con máximo de 212,856 % y mínimo de -1,130 %; presión y vibración con lecturas negativas: errores de sensor a depurar.

Estas correcciones son el insumo directo del objetivo específico OE2: el impacto de la calidad del dato sobre la precisión del modelo.

Matriz de correlación de las variables



Bloque hidráulico fuertemente acoplado

Velocidad–flujo 0.961, flujo–potencia 0.957 y presión–flujo 0.956: las variables de proceso se mueven prácticamente en conjunto.

La vibración del motor sí responde al proceso

Correlación de 0.786 con potencia y 0.742 con flujo: es candidata natural como indicador de condición.




Vibración del porta rodamientos casi independiente

Correlaciones entre 0.12 y 0.20 con el resto: aporta información propia, no redundante, sobre el estado del componente.

Densidad sin señal aparente

Correlaciones cercanas a 0.02, distorsionadas por los valores atípicos detectados en el control de calidad.

Comportamiento temporal de las señales clave



Lectura de las series

- Régimen estable interrumpido por caídas abruptas a cero, que corresponden a las paradas del equipo.
- La vibración del motor sigue el patrón de carga: sube y baja junto con la potencia y el flujo.
- La vibración del porta rodamientos muestra una tendencia propia y descendente en el periodo, independiente del régimen de carga.
- Esa deriva es precisamente la señal de degradación que el modelo de RUL debe aprender a extrapolar.

Hallazgos preliminares

1

Base de datos suficiente para modelar

87,841 observaciones a resolución de un minuto y sin datos faltantes constituyen una base sólida para entrenar y validar el modelo.

2

Se requiere depuración antes del modelado

Los valores negativos y los máximos imposibles en densidad, presión y vibración distorsionan estadísticos y correlaciones.

3

Alta multicolinealidad entre variables de proceso

Velocidad, flujo, presión y potencia superan correlaciones de 0.94 entre sí; será necesaria una selección de características cuidadosa.

4

La vibración es la variable de condición más prometedora

Coincide con la literatura revisada: es el indicador más usado para estimar el RUL en maquinaria rotativa.

5

La variable objetivo es el punto crítico

El dataset registra condición operativa, no eventos de falla: construir el RUL como cuenta regresiva sobre un solo historial resultó ser la decisión que condicionó todo el modelado posterior.

PARTE – III | ENTRENAMIENTO DEL MODELO

Entrenamiento y evaluación

Construcción de la variable RUL, entrenamiento de Random Forest y XGBoost sobre 87 841 registros, y diagnóstico de los resultados obtenidos.

De los sensores a la variable objetivo

1,464 h**horizonte total**

del RUL construido

87,841**observaciones**

con RUL asignado

8**variables predictoras**

de proceso y condición

80 / 20**partición temporal**

70,272 train · 17,569 test

Cómo se construyó el RUL

1**Reconstrucción del eje temporal**

La marca de tiempo original no era uniforme: la serie se regeneró desde el primer instante válido con muestreo constante de 1 minuto.

2**Supuesto de fin de vida**

Se asumió que el último registro (03-abr-2026, 06:59) corresponde a la falla; el RUL de cada fila es la distancia en horas hasta esa fecha.

3**Partición cronológica, sin mezclar**

El 80 % más antiguo entrena (RUL de 1 464 h a 292.8 h) y el 20 % final evalúa (RUL de 292.8 h a 0 h).

Configuración de los cuatro modelos

1

Random Forest

200 árboles, profundidad máxima 15, mínimo 10 muestras por división y 5 por hoja.

2

Familia: ensamble de árboles

Predice promediando valores de hojas. No puede emitir predicciones fuera del rango de RUL visto en entrenamiento.

3

XGBoost

500 estimadores, tasa de aprendizaje 0.05, profundidad 6, submuestreo de filas y columnas 0.8.

4

Familia: ensamble de árboles

Misma restricción que Random Forest, con regularización explícita y aprendizaje secuencial.

5

Regresión Ridge

Regularización L2 con alfa 1.0 sobre variables estandarizadas.

6

Familia: modelo lineal

Sí extrapola, pero solo puede representar relaciones lineales entre las variables y el objetivo.

7

Red neuronal (MLP)

Capas ocultas de 64 y 32 neuronas, activación ReLU, optimizador Adam, detención temprana.

8

Familia: red neuronal

Sí extrapola y además representa relaciones no lineales. Es la combinación que faltaba probar.

Los cuatro modelos usan las mismas ocho variables, la misma partición temporal 80/20 y semilla fija 42

RESULTADOS DEL ENTRENAMIENTO

La familia del modelo cambia el resultado

208.54 h**MAE de la red neuronal**

el mejor de los cuatro

71.3 %**menos error que XGBoost**

de 725.42 h a 208.54 h

-6.61**R² de la red neuronal**

XGBoost quedó en -84.21

922.68 h**MAE de Ridge**

el peor de los cuatro

Lectura de los resultados

1**La familia pesa más que los hiperparámetros**

Pasar de Random Forest a XGBoost redujo el error 9.6 %. Pasar de XGBoost a una red neuronal lo redujo 71.3 %.


2**Extrapolar es necesario, pero no suficiente**

Ridge también extrapola y fue el peor de todos: sus predicciones llegaron a 2 225 h, siete veces el máximo real.

3**El techo lo pone el etiquetado, no el algoritmo**

Ningún modelo superó a la regla trivial. La red neuronal se acerca, pero sigue 42 % por encima de ella.

Los árboles no alcanzan el rango real



Los rangos de entrenamiento y prueba son disjuntos

Entrenamiento cubre RUL de 1 464 h a 292.8 h; prueba, de 292.8 h a 0 h. El modelo nunca vio los valores que debe predecir.

La predicción queda atrapada entre 300 h y 1 450 h

Un ensamble promedia valores de hojas, así que su salida no puede salir del rango del objetivo visto en entrenamiento.

La tendencia va en sentido contrario


Mientras más cerca está la falla, más vida pronostica el modelo: usa las variables de proceso como reloj indirecto.

Hipótesis a verificar

Si la causa es la familia de modelos, un algoritmo capaz de extrapolar debería reducir el error de forma sustancial.

VERIFICACIÓN

La red neuronal confirma el diagnóstico



Reduce el error en más del 70 %

El MAE baja de 725.42 h a 208.54 h y el RMSE de 780.29 h a 233.20 h, con la misma partición y las mismas ocho variables.

Es el único que entra al rango real

Sus predicciones descienden hasta 127 h, mientras que los árboles nunca bajaron de 293 h. La hipótesis queda verificada.

Pero no reproduce el descenso hacia cero

La predicción se mantiene plana alrededor de 350 h en lugar de acompañar la caída del RUL real. Queda una causa sin resolver.

Esa causa es el etiquetado

El RUL se definió como cuenta regresiva sobre un único historial, así que depende del calendario y no del estado del equipo.

Ningún modelo supera a una regla trivial

Modelo	MAE (h)	RMSE (h)	R ²
Línea base: media de entrenamiento	732.01	736.87	-74.99
Línea base: repetir el último RUL	146.42	169.06	-3.00
Random Forest	802.56	851.09	-100.38
XGBoost	725.42	780.29	-84.21
Ridge	922.68	933.60	-120.99
Red neuronal (MLP)	208.54	233.20	-6.61

La red neuronal es el mejor de los cuatro modelos y reduce el error de XGBoost en 71.3 %, pero sigue 42 % por encima de una regla que responde siempre 292.8 h y no consulta ningún sensor.

Cinco acciones para un modelo válido

1

Más historiales de falla

Incorporar varias bombas y varios ciclos de intervención, y particionar entre trayectorias, no en el tiempo.

2

Redefinir el RUL por tramos

Etiquetado lineal por tramos: saturar el RUL durante la fase sana y hacerlo decrecer solo cuando la degradación es observable.

3

Variables de ventana móvil

Valor eficaz, curtosis, pendiente y dispersión de la vibración en ventanas de 1 a 24 h, para capturar tendencia y no nivel instantáneo.

4

Depuración pendiente

Eliminar los valores físicamente imposibles de densidad y presión, y etiquetar de forma explícita los períodos de parada.

5

Escalar la familia que sí funcionó

Avanzar del perceptrón multicapa hacia arquitecturas recurrentes o convolucionales sobre ventanas de señal, con validación cruzada por bloques.

Alternativa de menor exigencia de datos: reformular el problema como clasificación de "falla en las próximas N horas", que no requiere extrapolación y se ajusta al objetivo específico OE3.

CONCLUSIÓN

La familia del modelo importa, el etiquetado más

De los cuatro modelos entrenados, la red neuronal redujo el error de XGBoost en 71.3 %, lo que confirma que la incapacidad de extrapolar de los ensambles de árboles era una causa real del problema. Aun así, ninguno superó a una regla trivial, porque el RUL se construyó como cuenta regresiva sobre un único historial de falla. Lo que queda operativo hoy es la clasificación por umbrales de vibración, con 1.00 % de registros críticos y 3.86 % en alerta, junto con una ruta de corrección precisa.

Gracias