

Modelo de Aprendizaje automático para mejorar el mantenimiento de Molinos Semi-autógenos

Machine Learning Model to Improve Maintenance of Semi-autogenous Mills

AUTORES

Teves Adanaque Oscar Isaac  , Fany Yexenia Sobero Rodriguez 

Universidad Nacional Mayor de San Marcos, Lima, Perú

Recibido: 18/12/2024 Revisado: 15/01/2025 Aceptado: 15/05/2025 Publicado: 30/06/2025

RESUMEN

La molienda es un procedimiento crucial en el sector minero, los equipos más importantes en este proceso son los molinos autógenos y semi-autógenos (SAG), que trituran grandes cantidades de material como cobre y oro, gestionando más de 100,000 toneladas al día. El mantenimiento de estos molinos es un reto complejo debido a la necesidad de reemplazar sus revestimientos internos y a las variaciones en los tiempos de intervención, lo que dificulta una planificación adecuada. Cualquier retraso en el mantenimiento puede detener la producción, generando pérdidas de entre 50,000 y 500,000 dólares por hora.

Para abordar esta problemática se realizó el presente estudio utilizando un conjunto de datos históricos de mantenimiento, incluyendo etapas del proceso, tipos de componentes y reportes de mantenimiento preventivos y correctivos, aplicando la metodología Proceso Estándar de la Industria Cruce para la Minería de Datos (CRISP-DM), se pudieron identificar atributos claves y patrones relevantes para predecir tiempos de intervención, a través de algoritmos de aprendizaje automático, específicamente en regresión lineal, regresión polinomial y redes neuronales de regresión, usando Keras. Los resultados mostraron que estos modelos ofrecen alta precisión en la predicción de los tiempos reales de mantenimiento facilitando una mejor comprensión de los atributos que influyen en la duración real de los mantenimientos de los molinos SAG, contribuyendo a la planificación operativa y reduciendo las pérdidas financieras. El uso de un método predictivo fundamentado en el aprendizaje automático contribuye a la mejora de los procesos de mantenimiento, garantizando la continuidad de la producción y previniendo interrupciones costosas.

PALABRAS CLAVE: Molinos SAG, mantenimiento predictivo, aprendizaje automático, minería.

ABSTRACT

Grinding is a crucial procedure in the mining sector, the most important equipment in this process are autogenous and semi-autogenous (SAG) mills, which crush large quantities of material such as copper and gold, handling more than 100,000 tons per day. The maintenance of these mills is a complex challenge due to the need to replace their internal linings and the variations in intervention times, which makes proper planning difficult. Any delay in maintenance can stop production, generating losses of between 50,000 and 500,000 dollars per hour. To address this problem, the present study was carried out using a set of historical maintenance data, including process stages, component types and preventive and corrective maintenance reports, applying the Cross Industry Standard Process for Data Mining (CRISP-DM) methodology, key attributes and relevant patterns were identified to predict intervention times, through machine learning algorithms, specifically in linear regression, polynomial regression and regression neural networks, using Keras. The results showed that these models offer high accuracy in predicting actual maintenance times, facilitating a better understanding of the attributes that influence the actual duration of SAG mill maintenance, contributing to operational planning and reducing financial losses. The use of a predictive method based on machine learning contributes to the improvement of maintenance processes, ensuring production continuity and preventing costly interruptions.

KEYWORD: SAG mills, predictive maintenance, machine learning, mining.

INTRODUCCION

La conservación de los molinos (SAG) en la industria minera es un elemento importante, dado que estos equipos desempeñan un rol esencial en el proceso de trituración de minerales. Un mantenimiento eficaz no solo extiende la durabilidad de los dispositivos, sino que también mejora la productividad y disminuye los gastos de operación, aspectos clave para la rentabilidad de las compañías mineras. No obstante, la gestión de estos mantenimientos plantea retos considerables a causa de la fluctuación en el tiempo de las intervenciones, lo que complica la correcta organización de las tareas de mantenimiento (Rihi et al., 2022).

Diversos estudios han enfatizado la relevancia de incorporar tecnologías de vanguardia para anticipar y optimizar el mantenimiento de maquinaria industrial. Krishnan et al. (2022) subrayan que la implementación de modelos de aprendizaje automático puede prever errores y disminuir el tiempo de parada, mientras que Herrero y Zorrilla (2022) resaltan que la ausencia de anticipación en los periodos de mantenimiento puede generar costos altos debido a interrupciones no planificadas. Por otro lado, Welte et al. (2020) presentan el modelo ASUM (Analytics Solutions Unified Method), que estructura el proceso de implementación de soluciones de aprendizaje automático para el mantenimiento predictivo, desde la idea inicial hasta el seguimiento de la solución.

Dentro de las investigaciones más relevantes realizadas sobre el mantenimiento de molinos SAG utilizando aprendizaje automático se encuentra el estudio realizado por Jayasundara y Zhu (2022), donde se exploró la predicción del desgaste de los revestimientos en molinos de bolas mediante la combinación del método de elementos discretos (DEM) y redes neuronales artificiales. A través de simulaciones DEM, se obtuvieron datos sobre las energías y parámetros de desgaste en un molino de laboratorio. Posteriormente, se entrenó una red neuronal artificial para predecir el desgaste en un molino a escala industrial. Los resultados de este estudio sugieren que el uso conjunto de DEM y redes neuronales artificiales es una herramienta efectiva para anticipar el perfil de desgaste de los molinos de bolas, lo que contribuye a optimizar el rendimiento del equipo y a reducir los costos asociados al mantenimiento.

El objetivo principal de esta investigación fue elaborar un modelo de regresión lineal utilizando algoritmos de aprendizaje automático y redes neuronales usando keras, que simplifique la estimación de los periodos de mantenimiento, empleando información histórica de las intervenciones realizadas en molinos SAG y con ello proporcionar un instrumento útil para la industria minera que facilite una mejor organización de sus recursos y un uso eficiente de la maquinaria, previniendo pérdidas debido a periodos de inactividad no previstos.

METODOLOGIA

La presente investigación empleo un diseño no experimental, caracterizado por la ausencia de manipulación de variables o condiciones experimentales, lo que posibilita la evaluación de los participantes en su ambiente natural (Arias Gonzales, 2021).

Para el desarrollo del trabajo se utilizó la metodología CRISP-DM, mencionada en el estudio realizado por Calero Pérez y Baldeón Calisto (2022), el cual ofrece un enfoque estructurado para proyectos de minería de datos, particularmente beneficiosa en aplicaciones de aprendizaje automático.

Este método consta de seis etapas:

1. Comprensión del negocio: Define los objetivos del proyecto y el problema a resolver, estableciendo criterios de éxito y un plan de trabajo.
2. Comprensión de los datos: Involucra la recopilación y exploración de datos, evaluando su calidad y relevancia para el problema.
3. Preparación de los datos: Incluye la limpieza, transformación y selección de características, asegurando que los datos estén listos para el modelado.
4. Modelado: Se seleccionan y entrenan diferentes algoritmos de aprendizaje automático, ajustando hiperparámetros para optimizar el rendimiento.
5. Evaluación: Se revisan los resultados de los modelos en relación con los objetivos del negocio, asegurando que se cumplan los criterios de éxito.
6. Despliegue: Implica la integración del modelo en el entorno operativo, permitiendo su uso en la toma de decisiones.

La aplicación de CRISP-DM asegura un flujo de trabajo sistemático que facilita la alineación de los objetivos del negocio con los análisis de datos, maximizando la precisión del modelo y su valor práctico en el contexto de mantenimiento predictivo en la minería. Este enfoque permite una implementación confiable y replicable de soluciones de aprendizaje automático.

MATERIALES Y METODOS

La presente investigación recopiló datos estructurados desde bases de datos SQL y PostgreSQL, mientras que la información no estructurada provino de tableros de control, así como de reportes de mantenimientos correctivos y preventivos. Toda esta información fue vinculada mediante llaves primarias y relaciones para mejorar la integridad y cohesión de los datos. Posteriormente, estos fueron exportados a archivos en formato CSV y almacenados en Google Drive, facilitando una integración fluida y accesible desde Google Colab.

En el procesamiento y análisis de datos, se emplearon las bibliotecas Pandas y NumPy para la manipulación y exploración de los conjuntos de datos. Para la visualización de los datos y análisis exploratorio, se utilizaron las bibliotecas Matplotlib y Seaborn, las cuales permitieron la generación de gráficos y representaciones visuales que facilitaron la identificación de patrones y relaciones entre las variables. Para el entrenamiento de los modelos de regresión, se utilizó Scikit-learn, aplicando algoritmos como regresión lineal

(simples y polinomiales), KNN (k-Nearest Neighbors), árboles de decisión, bosques aleatorios y redes neuronales, implementadas mediante TensorFlow y Keras.

Para evaluar el rendimiento predictivo de los modelos en relación con la duración de mantenimiento de los molinos SAG, se calcularon métricas como:

- RMSE (Root Mean Square Error): esta métrica mide la magnitud promedio de los errores de predicción, penalizando más los errores grandes.
- MAE (Mean Absolute Error): Mide el error promedio absoluto entre las predicciones y los valores reales sin penalizar los errores grandes.
- R^2 (Coeficiente de Determinación): Indica qué porcentaje de la variabilidad de los datos es explicado por el modelo, un valor cercano a 1 mostrando un buen ajuste.

Las pruebas y entrenamientos se realizaron en entornos de trabajo con Python 3, utilizando procesadores CPU y una memoria superior a 12 GB para satisfacer los requerimientos computacionales de procesamiento.

Adicionalmente, se aplicaron métodos estadísticos para evaluar la distribución y características de los datos, utilizando medidas como la media y la desviación estándar para analizar la dispersión y detectar patrones relevantes. Se implementó también una normalización de escala para optimizar la precisión y consistencia en los resultados de los modelos predictivos.

IMPLEMENTACION

La información utilizada en este trabajo provino de diversas fuentes clave que permiten una gestión integral del mantenimiento de los molinos SAG. Los órdenes de trabajo especifican las tareas necesarias, los recursos y los plazos, lo que facilita la organización y el seguimiento detallado de las actividades. Los reportes de mantenimiento, tanto preventivo como correctivo, registran las acciones tomadas para prevenir fallos y resolver problemas, respectivamente; proporcionando datos cruciales para evaluar la efectividad de los programas de mantenimiento y planificar intervenciones futuras. Adicionalmente, cuadros de control y planificación de tareas que gestionan fechas, recursos, incidentes y averías, y genera informes de progreso en cada etapa del mantenimiento. Se obtuvieron 1051 registros que son de los años 2021 a enero 2024.

A continuación, la Tabla 1 describe los atributos del conjunto de datos usados para el análisis en el mantenimiento de molinos semi-autógenos.

Atributo	Descripción
Fecha_inicio_Planificada	Fecha y hora planeada de inicio de mantenimiento del molino.
Fecha_fin_Planificada	Fecha y hora esperada de finalización del mantenimiento.
Fecha_Inicio_real	Fecha y hora reales de inicio de mantenimiento.
Fecha_fin_real	Fecha y hora reales de finalización de mantenimiento.
Duracion_planificada	Tiempo estimado de mantenimiento.

Duracion_real	Tiempo real empleado en el mantenimiento.
Tipo_piezas	Tipo de piezas a utilizar o reemplazar.
Cantidad_piezas_planificadas	Cantidad planeada de piezas a utilizar.
Cantidad_piezas_reales	Cantidad real de piezas utilizadas.
Tiempo_endemoras_planificadas	Tiempo planeado para demoras.
Tiempo_endemoras_reales	Tiempo real de demoras durante el mantenimiento.
Fase_Mantenimiento	Fase del proceso de mantenimiento en curso.
Tiempo_planificado_fase	Tiempo estimado para cada fase del mantenimiento.
Tiempo_real_fase	Tiempo real en cada fase.
Causa_demoras	Descripción de causas de demora.
Historial_fallas	Registro de fallas previas y acciones correctivas.
Tipo_equipo	Tipo de molino SAG.
Condicion_pre	Condición del molino antes de mantenimiento.
Condicion_post	Condición del molino después del mantenimiento.
ID_cliente	Identificación del cliente de quien se recopila la información.

Tabla 1. Conjunto de datos inicial de mantenimiento de molinos SAG.

Se llevo a cabo un filtrado del conjunto de datos inicial con únicamente variables continuas que deben estar vinculadas con la variable meta, "Duración_real". La Tabla 2 muestra el nuevo conjunto de datos al cual se le denomina "Dataset_Filtered".

Atributo	Descripción
Duracion_planificada	Tiempo estimado para completar el mantenimiento.
Duracion_real	Tiempo real empleado en el mantenimiento.
Tipo_piezas	Tipo de piezas utilizadas o reemplazadas.
Cantidad_piezas_planificadas	Cantidad de piezas planificadas para el mantenimiento.
Cantidad_piezas_reales	Cantidad real de piezas utilizadas.
Tiempo_endemoras_reales	Tiempo real de demoras ocurridas durante el mantenimiento.
Fase_Mantenimiento	Fase específica del proceso de mantenimiento en curso.
Tiempo_planificado_fase	Tiempo estimado para completar una fase específica.
Tiempo_real_fase	Tiempo real empleado en completar una fase específica.
Causa_demoras	Descripción de las causas específicas de cualquier demora.

Tabla 2. Conjunto de datos de mantenimiento de molinos SAG filtrado.

La Fig. 1 muestra la matriz de correlación para determinar la relación entre los atributos y la variable objetivo del nuevo conjunto de datos “Dataset_filtered”.




Fig. 1. Matriz de correlación de conjunto de datos (Dataset_filtered).

Antes de entrenar el modelo, se realizó un análisis exploratorio de los datos, el cual reveló que las desviaciones estándar no eran uniformes. Por ello, fue necesario estandarizar la data para mejorar el procesamiento de la información. Se utilizaron las funciones `StandardScaler`, `train_test_split`, `cross_val_score` y `SelectKBest` de la biblioteca `Scikit-learn`.

Se dividió el conjunto de datos en entrenamiento y prueba, con una proporción de 80% y 20%, respectivamente. Además, se utilizó una semilla de 123 para garantizar la reproducibilidad de los resultados y evitar variaciones en las particiones de los datos.

RESULTADOS

Para llevar a cabo el análisis del conjunto de datos de mantenimiento de molinos semi-autógenos mediante algoritmos de aprendizaje automático, se utilizaron modelos de regresión con el objetivo de evaluar métricas como RSME, MAE, R^2 , dentro de los resultados obtenidos, los modelos de regresión lineal, regresión polinómica con grado 1, y redes neuronales usando Keras destacan por su bajo RMSE, alrededor de 0.34, lo que indica un ajuste adecuado y un rendimiento preciso en las predicciones. Estos modelos también presentan los valores más bajos de MAE, aproximadamente 0.08, lo que refleja que los errores absolutos promedio son mínimos. Además, exhiben R^2 superiores a 0.92, lo que significa que explican más del 90% de la variabilidad de los datos, demostrando su alta efectividad en el análisis predictivo de mantenimiento para los molinos semi-autógenos.

Por otro lado, los modelos de KNN, árboles de decisión y bosques aleatorios con 10, 50, 100 árboles mostraron un rendimiento inferior. El modelo KNN, probado con K valores de [1, 5, 10, 15], presentaron el peor desempeño en términos de RMSE (1.08) y MAE (0.77), lo que sugiere que no se ajusta adecuadamente a los datos. Aunque los árboles de decisión y los bosques aleatorios mostraron un rendimiento superior al de KNN, sus valores de R^2 , que oscilan entre 0.85 y 0.91, siguen siendo inferiores a los de los modelos lineales y las redes neuronales, lo que indica que no logran capturar completamente la variabilidad de los datos. En resumen, los modelos lineales y las redes neuronales son los más adecuados para este conjunto de datos, mientras que los demás modelos muestran un desempeño más limitado.

Las predicciones realizadas utilizando redes neuronales con Keras, comparando los tiempos predichos frente a los tiempos reales, se presentan en la Fig. 2, donde se muestran cinco valores del conjunto de test tras el entrenamiento y la evaluación de las métricas de regresión. Los resultados reflejan estimaciones obtenidas para cada fase o giro del mantenimiento de molinos semi-autógenos en horas, destacando un coeficiente de determinación (R^2) del 92.3 %, lo que evidencia una relación confiable entre variables.




Fig. 2. Predicciones del conjunto de test, neuronas artificiales con keras.

Asimismo, dado que la regresión lineal mostró métricas con alta efectividad, se analizaron los coeficientes de correlación en el conjunto de datos. Los resultados indicaron que las variables Duración_planificada (0.976) y tiempo_endemoras_reales (0.993) tuvieron los efectos más significativos sobre la Duración_real, evidenciando una relación positiva notable. Otras variables, como Cantidad_piezas_planificadas y Fase_Mantenimiento, presentaron impactos menos relevantes. El intercepto (-0.083) estuvo cercano a cero, lo que indica que tiene una importancia práctica mínima en el modelo.

A continuación, se presenta una comparación entre los valores predichos por el modelo y los valores reales obtenidos mediante los algoritmos de regresión lineal, lo que permite evaluar el desempeño y la precisión del modelo en la predicción de los tiempos de mantenimiento de molino semi-autógenos.




Fig. 3. Gráfico de modelo de regresión línea, entrenamiento vs test.

El gráfico de modelo de regresión lineal mostrado en la Fig. 3 presenta una eficiencia elevada en los datos de test y entrenamiento, con puntos de información distribuidos de manera uniforme alrededor de la línea de regresión. Esto indica que el modelo entiende adecuadamente la correlación lineal entre las variables. Es apropiado para calcular el mantenimiento de los molinos SAG y muestra un rendimiento óptimo en la información de entrenamiento, con coeficientes significativos y fácilmente interpretables.




Fig. 4. Gráfico de valores residuales vs predictivos

El gráfico de residuos frente a valores predichos mostrado en la Fig. 4 muestra la distribución de los residuos del modelo de regresión lineal, que son las diferencias entre los valores reales y los predichos. El modelo muestra que se ajusta bien a la mayoría de los datos, con algunos valores atípicos que no están

bien predichos. Estos valores corresponden a fases que se han ejecutado en algunos servicios, pero de las cuales aún no se dispone de suficiente información de ejecución en otros trabajos.

DISCUSIÓN

Los hallazgos de la investigación señalan que los métodos de aprendizaje automático, en particular Gradient Boosting, Random Forest y Regresión Lineal, presentan un desempeño sobresaliente en la predicción de fallos en máquinas rotatorias, con un índice de precisión del 99.93%. Esta efectividad pone de manifiesto la utilidad de estos algoritmos en el sector industrial, ayudando a disminuir los gastos de mantenimiento y a prevenir interrupciones innecesarias en la producción como lo manifestaron Roque et al. (2022).

Una investigación realizada con un modelo de simulación de mantenimiento industrial mostró que la metodología empleada redujo los gastos en un 44%, disminuyó el tiempo de parada no programada y mejoró la eficiencia del mantenimiento (Aaron S. Yearley, 2022). De manera complementaria el aprendizaje automático mejora el mantenimiento industrial al optimizar la programación de actividades y reducir tiempos muertos. Wu y Zheng (2023) propusieron modelos de aprendizaje automático que pueden desarrollarse en dos etapas durante los experimentos, lo que facilita la descomposición de problemas complejos y la optimización independiente de cada etapa. Además, estos modelos pueden incorporar métodos de mejora iterativa, refinando progresivamente las soluciones para lograr un desempeño más eficiente y preciso en el mantenimiento predictivo.

De acuerdo con diversas investigaciones, la integración de técnicas de aprendizaje automático en el mantenimiento predictivo ha demostrado ser efectiva en el sector industrial y altamente aplicable en equipos del sector minero. Este estudio se centra en la predicción del tiempo requerido para el mantenimiento de molinos semi-autógenos, presentando estas técnicas como una solución prometedora para aumentar la precisión en dichas estimaciones. Al considerar múltiples atributos relevantes, estas proyecciones contribuyen a una gestión más eficiente de los procesos en el sector minero.

En este trabajo, se utilizaron variables continuas para entrenar los modelos, obteniendo métricas de desempeño como un RMSE de 0.31 y un MAE de 0.08, lo que refleja un buen ajuste del modelo, predicciones consistentes y errores mínimos. Sin embargo, la información recopilada también puede analizarse desde una perspectiva diferente, transformando la variable objetivo en un problema de clasificación y aplicando un enfoque por etapas para descomponer los problemas y optimizar las soluciones. Además de predecir fallos, los modelos predictivos contribuyen a optimizar la planificación del mantenimiento, reduciendo los tiempos de inactividad y los costos asociados a las paradas operativas.

CONCLUSIONES

La implementación de métodos de aprendizaje automático en el mantenimiento de molinos semi-autógenos revela relaciones clave entre la planificación por fases, los tipos de piezas de recambio, los tiempos de demora y las causas de las demoras. El uso de algoritmos de regresión lineal contribuye a mejorar la precisión de las proyecciones de los tiempos de mantenimiento y mejorar la planificación y ejecución de estos trabajos.

Los modelos de regresión lineal empleados han demostrado un desempeño positivo, con indicadores como Root Mean Square Error (RMSE) y el coeficiente de determinación (R^2) señalando un adecuado ajuste y una correlación entre las variables estudiadas. Esto subraya la relevancia de incluir técnicas cuantitativas en la gestión del mantenimiento, lo que facilita la mejora de los recursos y la reducción de los periodos de parada.

El modelo presentado analizó y detectó patrones en el comportamiento de las características del conjunto de datos de valores continuos. Tras el proceso de entrenamiento, el estudio proporcionó los valores de los residuos y evaluó su distribución en relación con los valores previstos, entregando predicciones con valores de confiabilidad bastantes altos, lo que indica que el modelo de regresión se ajusta correctamente a los datos. Este ajuste demuestra la ausencia de sesgos significativos y de valores atípicos que puedan afectar la fiabilidad de las proyecciones. Estos resultados sugieren que la metodología empleada no solo es robusta, sino también aplicable en el entorno real de los procesos en el sector minero, sirviendo como una herramienta valiosa para la toma de decisiones en la planificación de actividades.

En conclusión, esta investigación demuestra que la implementación de métodos de aprendizaje automático para el mantenimiento de molinos semi-autógenos representa un avance importante hacia la actualización y eficacia del sector minero. Los descubrimientos no solo aportan a la comprensión de cómo estas tecnologías pueden ser aplicadas en contextos industriales, sino que también presentan nuevos caminos de investigación en el área del mantenimiento predictivo, trazando una ruta hacia la sostenibilidad y competitividad en este sector.

REFERENCIAS

- Arias Gonzales, J. L. (2021). *Diseño y metodología de la investigacion* (Junio 2021).
- Calero Perez, M., & Baldeon Calisto, M. (2022). Application of machine learning algorithms for the prediction of payment by agreement in a debt collection company with the CRISP-DM methodology. *Proceedings of the International Conference on Industrial Engineering and Operations Management*, 474-485. <https://doi.org/10.46254/SA03.20220112>
- Herrero, R. D., & Zorrilla, M. (2022). An I4.0 data intensive platform suitable for the deployment of machine learning models: A predictive maintenance service case study. *Procedia Computer Science*, 200, 1014-1023. <https://doi.org/10.1016/j.procs.2022.01.300>
- ISO - 25000. (s. f.). *Usabilidad*. Recuperado 15 de noviembre de 2023, de <https://iso25000.com/index.php/normas-iso-25000/iso-25010/23-usabilidad>
- Jayasundara, C. T., & Zhu, H. P. (2022). Predicting liner wear of ball mills using discrete element method and artificial neural network. *Chemical Engineering Research and Design*, 182, 438-447. <https://doi.org/10.1016/j.cherd.2022.04.013>
- Krishnan, T., Khan, A., & Alqurni, J. (2022). Aggregate Production Planning and Scheduling in the Industry 4.0 Environment. *Procedia Computer Science*, 204, 784-793. <https://doi.org/10.1016/j.procs.2022.08.095>
- Rihi, A., Baïna, S., Mhada, F., Elbachari, E., Tagemouati, H., Guerboub, M., & Benzakour, I. (2022). Predictive maintenance in mining industry: Grinding mill case study. *Procedia Computer Science*, 207, 2483-2492. <https://doi.org/10.1016/j.procs.2022.09.306>
- Roque, A. S., Krebs, V. W., Figueiro, I. C., & Jazdi, N. (2022). An analysis of machine learning algorithms in rotating machines maintenance. *IFAC-PapersOnLine*, 55(2), 252-257. <https://doi.org/10.1016/j.ifacol.2022.04.202>
- Welte, R., Estler, M., & Lucke, D. (2020). A Method for Implementation of machine learning Solutions for Predictive Maintenance in Small and Medium Sized Enterprises. *Procedia CIRP*, 93, 909-914. <https://doi.org/10.1016/j.procir.2020.04.052>
- Wu, H., & Zheng, H. (s. f.) (2023) . OPEN Single-machine scheduling with periodic maintenance and learning effect. *Scientific Reports*.
- Yeardley, A. S., Ejeh, J. O., Allen, L., Brown, S. F., & Cordiner, J. (2022). Integrating machine learning techniques into optimal maintenance scheduling. *Computers & Chemical Engineering*, 166, 107958. <https://doi.org/10.1016/j.compchemeng.2022.107958>