CMC CHILE 2026

Sesión
TOOLBOX

1

TOOLBOX SESIÓN 21

CONGRESO DE MANTENIMIENTO & CONFIABILIDAD CHILE 7ª EDICIÓN



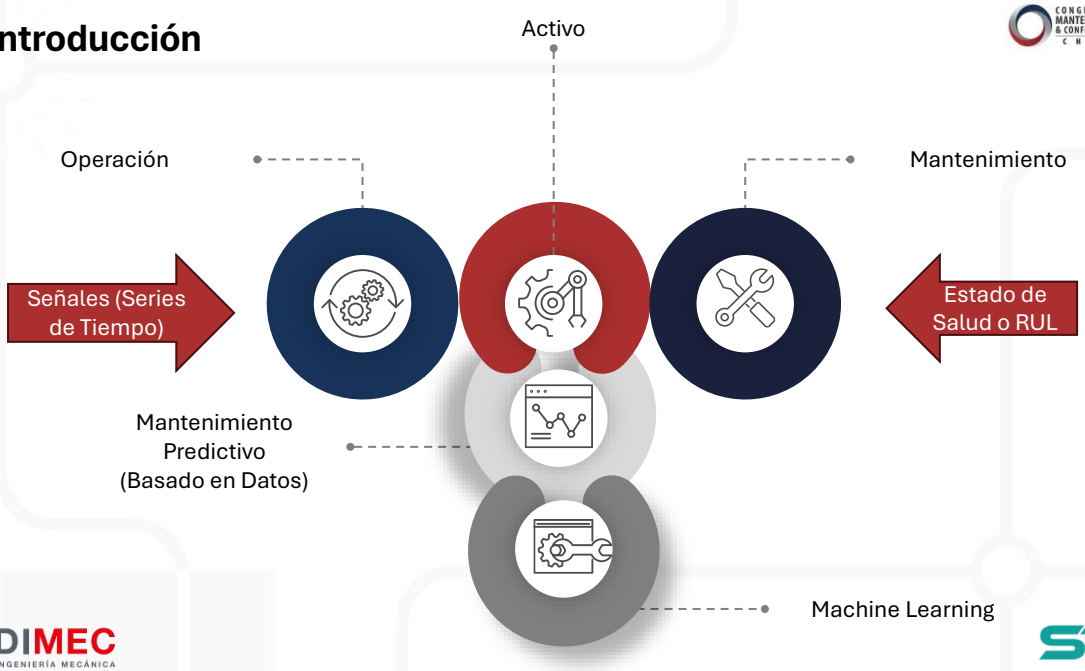
**Taller de Analítica Predictiva en Mantenimiento y Confiabilidad con IA Generativa - Parte 2:**

Enseñar a una red neuronal a predecir cuánto tiempo queda para la falla.

**Raymi Vásquez Moreno**
Académico y Consultor

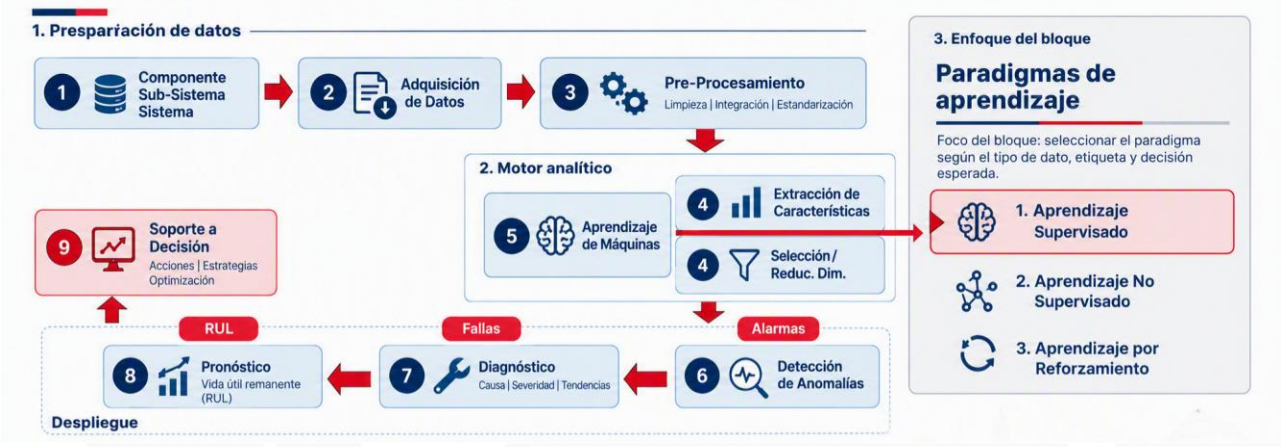
2

## Introducción




3

## Flujo de la información




4

RESULTADOS TOOLBOX

## De datos operacionales a un problema de pronóstico

**1 — 14 campañas**
2 molinos SAG
7 campañas por molino

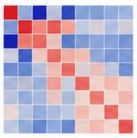


SAG 1 — 7 campañas | SAG 2 — 7 campañas

**2 — 11 variables operacionales**
Más ID, Tiempo (h) y RUL
(14 columnas en total)

| ID | Tiempo (h) | Variables operacionales (11) | RUL |
|---|---|---|---|
| 1 | 0 | ... | 2501 |
| 1 | 1 | ... | 2500 |
| 1 | 2 | ... | 2498 |
| ... | ... | ... | ... |

**3 — Variables seleccionadas**
Basado en análisis de variabilidad y relación con RUL



- Mantener
- Mantener
- Mantener
- Revisar
- Excluir

**4 — Dataset preparado para RUL**
Listo para modelamiento predictivo

| ID | Tiempo (h) | Variables seleccionadas | RUL |
|---|---|---|---|
| 1 | 0 | ... | 2501 |
| 1 | 1 | ... | 2500 |
| 1 | 2 | ... | 2498 |
| ... | ... | ... | ... |

**La IA generativa aceleró el código.**
**La ingeniería validó el análisis.**

Transformamos datos de operación en un insumo técnicamente defendible para modelar la vida útil remanente del revestimiento.

5

## ¿Cuánta vida útil le queda al revestimiento?

Los revestimientos internos del casco y de los cabezales se desgastan principalmente por la interacción continua con el mineral, las bolas de acero y la pulpa durante la molienda, es decir, el desgaste del revestimiento evoluciona durante la campaña de operación del molino SAG.



- Abrasión
- Impacto
- Erosión/ desgaste por pulpa

**Revestimiento nuevo → Operación → Desgaste progresivo → Fin de campaña**

**¿Podemos utilizar el comportamiento histórico del molino para preparar datos que permitan posteriormente estimar la vida útil remanente (RUL) d revestimiento?**

6

# Del desgaste físico a los datos operacionales

## Presentación del Dataset

Los datos corresponden a dos molinos, SAG 1 y SAG 2, con 7 campañas de desgaste por molino. Cada registro contiene ID de campaña, Cycle y 11 variables operacionales. Durante el análisis se construirá RUL como variable objetivo a partir de la evolución de cada campaña.



| | ID | Cycle | SensorMeasure1 | SensorMeasure2 | SensorMeasure3 | SensorMeasure4 | SensorMeasure5 | SensorMeasure6 | SensorMeasure7 |
|---|---|---|---|---|---|---|---|---|---|
| 0 | 1 | 1 | 1355.286133 | 313.998840 | 7.046370 | 80.001221 | 3.834873 | 61.003240 | 85.988953 |
| 1 | 1 | 2 | 1314.193726 | 303.012177 | 6.692522 | 80.001221 | 3.914814 | 63.445523 | 120.999786 |
| 2 | 1 | 3 | 1842.077759 | 500.003052 | 9.510370 | 77.001251 | 6.594503 | 66.720592 | 405.993835 |
| 3 | 1 | 4 | 2349.337646 | 529.996643 | 8.863295 | 79.000214 | 5.702293 | 64.395324 | 454.994354 |
| 4 | 1 | 5 | 1196.063354 | 264.009521 | 7.050979 | 80.999176 | 4.358096 | 63.805751 | 148.002563 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 18670 | 7 | 2560 | 1887.127441 | 342.014832 | 8.480180 | 74.999237 | 6.212714 | 60.730681 | 86.989960 |
| 18671 | 7 | 2561 | 1986.926758 | 424.011963 | 9.231603 | 73.000275 | 7.039661 | 61.121008 | 124.002808 |
| 18672 | 7 | 2562 | 1994.527832 | 385.998108 | 9.941005 | 73.000275 | 7.709493 | 61.077962 | 173.003326 |
| 18673 | 7 | 2563 | 2022.189209 | 453.016754 | 9.592515 | 73.000275 | 7.177448 | 60.482224 | 152.006592 |
| 18674 | 7 | 2564 | 2556.545898 | 585.992004 | 10.375889 | 74.999237 | 7.978002 | 61.436043 | 288.998077 |

18675 rows × 13 columns

| Campaña | Tiempo | ALIMENTACION - TPH | AGUA | VELOCIDAD GIRO | % de SOLIDO | POTENCIA [KW] | PRESION DESCANSOS | PEBBLES GENERADO [TPH] | PEBBLES REC. | FINO % | INTERMEDIO % | GRUESO % |
|---|---|---|---|---|---|---|---|---|---|---|---|---|

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

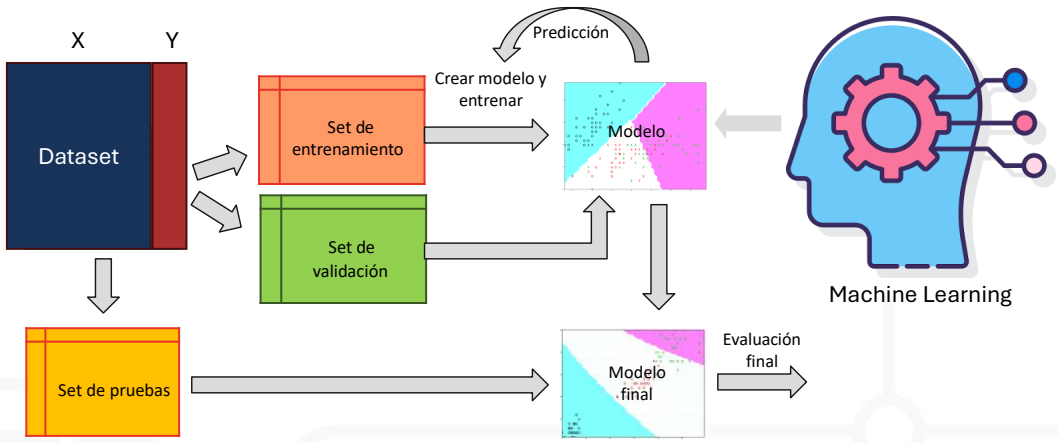
7

# Solución Predictiva

8

**X:** CAMPAÑA; TIEMPO; ALIMENTACION – TPH; AGUA; VELOCIDAD GIRO; % de SOLIDO; POTENCIA [KW]; PRESION DESCANSOS; PEBBLES GENERADO [TPH]; PEBBLES REC; FINO %; INTERMEDIO %; GRUESO %

**Y:** RUL




REF: Apuntes Clases profesor Dr. Enrique López, Universidad de Chile

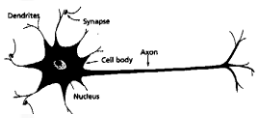




# Redes neuronales

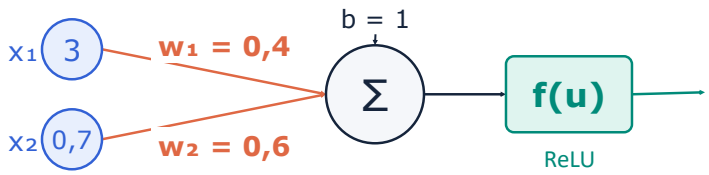
Una neurona oculta transforma las señales de los sensores.

**Inspiración biológica**




Dendritas: entradas
Sinapsis: pesos
Axón: salida

**Entradas x** | **Pesos w** | **Suma + sesgo** | **Activación** | **Salida a**




$$u = 0{,}4 \times 3 + 0{,}6 \times 0{,}7 + 1 = 2{,}62$$

$x_1$: temperatura estandarizada. $x_2$: presión estandarizada.

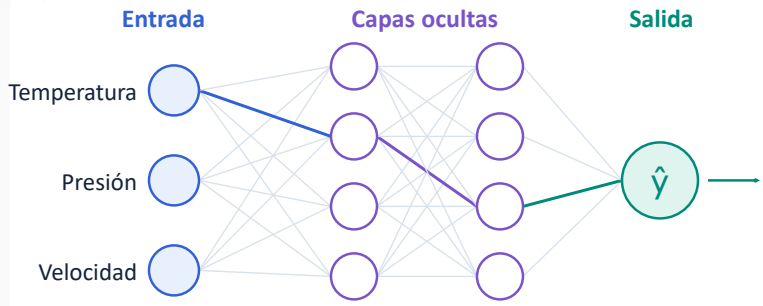
**Funciones de activación**

La no linealidad permite aprender patrones complejos.

| Identidad | Escalón | Sigmoide | tanh | ReLU |
|---|---|---|---|---|
| Salida lineal (RUL) | Devuelve 0 o 1 | Entre 0 y 1 | Entre −1 y 1 | En las capas ocultas |

# Predicción de vida útil remanente (RUL)

La red estima cuántos ciclos de operación le quedan al motor.




**RUL estimada**

Ciclo actual: 120

**35 ciclos**

restantes

| Observados | RUL |
|---|---|
| 120 | 35 |

Fin estimado: ciclo 155
120 + 35 = 155
Ejemplo ilustrativo

**MLP: perceptrón multicapa**

Varias capas ocultas: red profunda (DNN)

**Salida lineal: f(u) = u**

Un valor numérico en ciclos

11

# La red aprende a predecir RUL

Aprende con registros de motores cuyo fin de vida conocemos.

**1 Predice**

En el ciclo 120, estima 35 ciclos de RUL.

**2 Compara**

Objetivo: 30 ciclos.
Error: +5 ciclos.
Error²: 25 ciclos².

**3 Calcula gradientes**

Backpropagation calcula los gradientes del MSE.

**4 Actualiza**

El optimizador ajusta los pesos y los sesgos.

MSE: promedio de los errores cuadrados

**Objetivo de un ejemplo histórico**

**Fin observado: 150** **RUL = 30 ciclos**

En el ciclo 120: 150 − 120 = 30 ciclos.

**Ajuste de un peso**

$w_{nuevo} = w_{actual} - \eta \times gradiente$

La tasa η controla el tamaño del ajuste.

**Una época = recorrer todo el conjunto de entrenamiento.**

12

## Entorno de Trabajo

Drive, Colab y Gemini sostienen la práctica completa

La carpeta de Drive funciona como raíz del proyecto; Colab ejecuta; Gemini genera código pedagógico y comentado.




13

## Paso a paso: del dato a la predicción

16 prompts para reproducir las 12 celdas de código, en el mismo Colab.

**A. Datos**

- 1–2 Conectar Drive y cargar SAG1.
- 3–4 Definir X e y y dividir 80/20.
- 5 Estandarizar con entrenamiento.

**B. Modelo**

- 6–7 Configurar y entrenar el MLP.
- 8 Predecir y calcular las métricas.
- 9 Graficar RUL real frente a predicha.

**C. Aplicación**

- 10–11 Cargar y preparar SAG2.
- 12–13 Evaluar y graficar los resultados.
- 14–16 RUL inicial por campaña.

Copia un prompt en Gemini, ejecuta su código en Colab y revisa la evidencia.

14

PROMPT MAESTRO

## Gemini como tutor del ejercicio

**PROMPT PARA GEMINI**

Actúa como docente experto en Python, Colab, redes neuronales de regresión y mantenimiento predictivo.

Trabajaremos la RUL del revestimiento: entrenar con SAG1.csv y evaluar con SAG2.csv. Ambos CSV ya contienen RUL.

Entrega el código del paso solicitado, comentarios útiles y una explicación de máximo 5 líneas. Reutiliza los objetos y conserva los parámetros.

Si falta un archivo o una columna, explica qué revisar. No inventes resultados ni adelantes pasos.

**REGLAS DEL EJERCICIO**

- ☑ Una conversación en Gemini.
- ☑ Un mismo notebook en Colab.
- ☑ Código de un paso a la vez.
- ☑ Verificar antes de avanzar.

**ENVIAR UNA SOLA VEZ**

15

A. DATOS · PROMPT 1

## Conectar Google Drive

**PROMPT PARA GEMINI**

Genera una celda para conectar Google Drive con este notebook de Google Colab.

Importa drive desde google.colab y monta Drive en /content/drive con force_remount=True. Completaré la autorización en la interfaz de Colab.

Deja la conexión lista para leer los archivos CSV en los siguientes pasos.

**EVIDENCIA ESPERADA**

- ☑ Drive montado.
- ☑ Ruta /content/drive disponible.
- ☑ Autorización completada.

**CONEXIÓN CON DRIVE**

16

A. DATOS · PROMPT 2

## Cargar y revisar SAG1.csv

**PROMPT PARA GEMINI**

Importa pandas como pd y numpy como np.

Define file_path con esta ruta exacta:
/content/drive/MyDrive/SURF_IA/SAG/SAG1.csv

Lee el CSV en un DataFrame llamado df. Muestra un mensaje de carga exitosa con sus dimensiones y presenta las primeras 5 filas.

Usa try/except para informar el error si no se puede leer el archivo e indicar que debe verificarse la ruta. Conserva los datos tal como vienen en el CSV. Si la carga falla, detén el paso y evita usar un df de una ejecución anterior.

**EVIDENCIA ESPERADA**

- ☑ df creado.
- ☑ Dimensiones visibles.
- ☑ Primeras 5 filas.
- ☑ RUL disponible.

**RUTA DEL NOTEBOOK**

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

17

A. DATOS · PROMPT 3

## Separar entradas y objetivo

**PROMPT PARA GEMINI**

Trabaja con df. Usa todas las columnas excepto la última como características X y la última columna como objetivo y.

Muestra los nombres de las columnas de X y el nombre de y. Comprueba que la última columna se llama RUL y que las entradas son numéricas, sin valores faltantes. Si no se cumple, informa el problema antes de continuar.

Conserva el orden, las filas y las variables, incluidos ID y Cycle. Todavía no dividas ni escales los datos.

**EVIDENCIA ESPERADA**

- ☑ X definido.
- ☑ y definido.
- ☑ Nombres de predictores.
- ☑ Objetivo RUL verificado.

**RUL ES EL OBJETIVO**

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

18

A. DATOS · PROMPT 4

## Dividir entrenamiento y prueba

PROMPT PARA GEMINI

Importa train_test_split desde sklearn.model_selection.

Usa X e y para crear una partición aleatoria por filas: 80 % de entrenamiento y 20 % de prueba, con test_size=0.2 y random_state=42. Conserva los demás parámetros predeterminados.

Guarda X_train, X_test, y_train e y_test. Muestra sus dimensiones y mantén alineadas las entradas con su RUL. Todavía no entrenes.

EVIDENCIA ESPERADA

- ☑ 80 % entrenamiento.
- ☑ 20 % prueba.
- ☑ Semilla 42.
- ☑ Entradas y RUL alineadas.

PARTICIÓN POR FILAS

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

19

A. DATOS · PROMPT 5

## Estandarizar con entrenamiento

PROMPT PARA GEMINI

Importa StandardScaler desde sklearn.preprocessing y crea un escalador llamado scaler.

Ajústalo únicamente con X_train y transforma ese conjunto en X_train_scaled. Aplica después el mismo escalador a X_test para obtener X_test_scaled, sin volver a ajustarlo.

Muestra las dimensiones de ambos resultados. Conserva y_train e y_test en su escala original y guarda scaler para utilizarlo más adelante con SAG2.

EVIDENCIA ESPERADA

- ☑ scaler ajustado con X_train.
- ☑ X_train_scaled.
- ☑ X_test_scaled.
- ☑ RUL conserva su escala.

AJUSTAR SOLO CON TRAIN

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

20

B. MODELO · PROMPT 6

## Definir la red MLP

PROMPT PARA GEMINI

Importa MLPRegressor desde sklearn.neural_network y crea el modelo mlp_model para predecir RUL.

Configúralo con dos capas ocultas de 64 y 32 neuronas, hidden_layer_sizes=(64, 32), activation='relu', solver='adam', max_iter=500 y random_state=42.

Activa early_stopping=True y fija validation_fraction=0.1. Conserva los demás parámetros predeterminados. Todavía no entrenes el modelo. Explica brevemente el papel de las capas y de la detención temprana.

EVIDENCIA ESPERADA

- ☑ mlp_model creado.
- ☑ Capas 64 y 32.
- ☑ ReLU y Adam.
- ☑ Detención temprana activa.

MÁXIMO 500 ITERACIONES

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

21

B. MODELO · PROMPT 7

## Entrenar la red

PROMPT PARA GEMINI

Entrena el objeto mlp_model ya configurado utilizando X_train_scaled como entrada e y_train como objetivo.

Muestra un mensaje antes de iniciar el ajuste y otro cuando termine. Conserva el modelo entrenado con el mismo nombre para las siguientes predicciones.

Mantén sus parámetros actuales y deja actuar la detención temprana. Utiliza solo las variables de entrenamiento de este paso. No generes todavía métricas ni gráficos.

EVIDENCIA ESPERADA

- ☑ Modelo ajustado.
- ☑ X_train_scaled como entrada.
- ☑ y_train como objetivo.
- ☑ mlp_model disponible.

EL MODELO APRENDE AQUÍ

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

22

B. MODELO · PROMPT 8

## Predecir y medir el error en SAG1

PROMPT PARA GEMINI

Usa mlp_model para predecir la RUL de X_test_scaled y guarda el resultado como y_pred.

Importa mean_absolute_error, mean_squared_error y r2_score desde sklearn.metrics y compara y_pred con y_test. Calcula MAE, MSE, RMSE como la raíz cuadrada del MSE, y $R^2$. Guarda los valores en mae, mse, rmse y r2.

Crea metrics_df con las columnas Métrica y Valor y muestra la tabla. Usa el conjunto de prueba ya reservado y conserva el modelo sin reajustarlo.

EVIDENCIA ESPERADA

- ☑ y_pred calculado.
- ☑ MAE y MSE.
- ☑ RMSE y $R^2$.
- ☑ Tabla metrics_df.

$R^2$ NO ES % DE ACIERTOS

23

B. MODELO · PROMPT 9

## Comparar RUL real y predicha

PROMPT PARA GEMINI

Importa matplotlib.pyplot como plt y seaborn como sns. Usa el estilo whitegrid y una figura de 10 × 8.

Dibuja y_test en el eje horizontal e y_pred en el vertical, con puntos royalblue, alpha=0.6 y etiqueta Predicciones. Añade la referencia y=x en rojo discontinuo, grosor 2, desde el menor hasta el mayor valor de ambos conjuntos.

Titula el gráfico «Gráfico de Regresión: RUL Real vs. Predicho (MLP)», identifica ambos ejes, añade leyenda y ajusta el diseño antes de mostrarlo. Usa título de 14 en negrita, etiquetas de 12 y leyenda de 11.

EVIDENCIA ESPERADA

- ☑ RUL real en X.
- ☑ RUL predicha en Y.
- ☑ Referencia y=x.
- ☑ Dispersión visible.

DIAGONAL: PREDICCIÓN IDEAL

24

C. APLICACIÓN · PROMPT 10

## Cargar SAG2.csv

PROMPT PARA GEMINI

Define new_file_path con la ruta:
/content/drive/MyDrive/SURF_IA/SAG/SAG2.csv

Carga el CSV en un DataFrame llamado df_new. Muestra un mensaje con sus dimensiones y presenta las primeras 5 filas. Si ocurre un error, captura la excepción e informa el problema.

Reutiliza pandas ya importado. Conserva df, scaler y mlp_model. En este paso solo carga los datos de SAG2, que ya deben incluir la RUL real para su evaluación. Si falla la carga, detén el paso y evita usar un df_new anterior.

EVIDENCIA ESPERADA

- ☑ df_new creado.
- ☑ Ruta SAG2.csv.
- ☑ Dimensiones visibles.
- ☑ RUL real disponible.

SAG2 YA CONTIENE RUL

25

C. APLICACIÓN · PROMPT 11

## Preparar SAG2 con el mismo escalador

PROMPT PARA GEMINI

Trabaja con df_new. Guarda todas sus columnas excepto la última como X_new y la última como y_new, siguiendo la selección realizada para SAG1.

Verifica que el objetivo sea RUL y que las características de X_new coincidan en nombres y orden con X_train. Si hay una diferencia, informa cuál antes de continuar.

Aplica únicamente scaler.transform a X_new para crear X_new_scaled. Muestra que los datos quedaron preparados. Conserva y_new sin escalar.

EVIDENCIA ESPERADA

- ☑ X_new y y_new.
- ☑ Mismas columnas y orden.
- ☑ X_new_scaled.
- ☑ scaler reutilizado.

REUTILIZAR EL ESCALADOR

26

C. APLICACIÓN · PROMPT 12

## Evaluar la predicción en SAG2

PROMPT PARA GEMINI

Predice la RUL de X_new_scaled con mlp_model y guarda el resultado como y_new_pred.

Compara las predicciones con y_new. Calcula mae_new, mse_new, rmse_new como raíz de mse_new y r2_new, usando las mismas métricas de la evaluación anterior.

Crea metrics_new_df con las columnas Métrica y Valor (SAG2) y muestra MAE, MSE, RMSE y $R^2$. Mantén el modelo entrenado con SAG1 y el escalador existente sin reajustarlos.

EVIDENCIA ESPERADA

- ☑ y_new_pred.
- ☑ Cuatro métricas en SAG2.
- ☑ Tabla metrics_new_df.
- ☑ Modelo conservado.

EVALUAR SIN REENTRENAR

27

C. APLICACIÓN · PROMPT 13

## Visualizar la regresión en SAG2

PROMPT PARA GEMINI

Genera una figura de 10 × 8 con y_new en el eje horizontal e y_new_pred en el vertical. Usa puntos forestgreen, alpha=0.6 y etiqueta Predicciones (SAG2).

Añade la línea ideal y=x, roja y discontinua, de grosor 2, usando el mínimo y máximo de ambos conjuntos.

Titula «Gráfico de Regresión: RUL Real vs. Predicho en Datos Nuevos (SAG2)». Identifica los ejes como RUL Real (SAG2) y RUL Predicho (SAG2), incorpora leyenda, ajusta el diseño y muestra el resultado. Usa título de 14 en negrita, ejes de 12 y leyenda de 11.

EVIDENCIA ESPERADA

- ☑ Puntos de SAG2.
- ☑ RUL real y predicha.
- ☑ Referencia y=x.
- ☑ Misma lectura visual.

REVISAR LA DISPERSIÓN

28

C. APLICACIÓN · PROMPT 14

## Vincular predicciones y campañas

PROMPT PARA GEMINI

Crea results_new_df como una copia de df_new y agrega una columna llamada Predicted_RUL con los valores de y_new_pred.

Mantén el orden original de las filas para que cada predicción corresponda al registro que la generó. Conserva todas las columnas, en especial ID, Cycle y RUL.

Verifica que la cantidad de predicciones coincida con la cantidad de registros. Este DataFrame será la base para comparar el comienzo de las campañas de SAG2.

EVIDENCIA ESPERADA

- ☑ results_new_df.
- ☑ Predicted_RUL incorporada.
- ☑ ID y Cycle conservados.
- ☑ Una predicción por fila.

UNA PREDICCIÓN POR FILA

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

29

C. APLICACIÓN · PROMPT 15

## Comparar la RUL inicial por campaña

PROMPT PARA GEMINI

Verifica que ID, Cycle, RUL y Predicted_RUL de results_new_df no tengan nulos. Si existen, detén el paso.

Ordena por ID y Cycle. Agrupa por ID, toma first y restablece el índice en campaign_summary.

Crea campaign_comparison con ID y dos columnas renombradas: RUL como RUL_Real_Max y Predicted_RUL como RUL_Predicho_Inicial. Agrega su diferencia absoluta en Error_Absoluto y muestra la tabla. Verifica si la primera observación tiene Cycle=1 y la RUL máxima de su campaña.

EVIDENCIA ESPERADA

- ☑ Una fila por ID.
- ☑ RUL_Real_Max.
- ☑ RUL_Predicho_Inicial.
- ☑ Error_Absoluto.

PRIMER REGISTRO POR ID

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

30

C. APLICACIÓN · PROMPT 16

## Mostrar la comparación por ID

**PROMPT PARA GEMINI**

Usa campaign_comparison para dibujar barras agrupadas en una figura de 12 × 6. Crea x_indices con np.arange y fija width=0.35.

Grafica RUL_Real_Max en forestgreen y RUL_Predicho_Inicial en orange, con alpha=0.8. Ubica las barras en x_indices menos y más width/2.

Titula «Comparativa de RUL Máximo al Inicio de cada Campaña (SAG2)». Eje X: «ID de Campaña / Máquina». Eje Y: «Ciclos de RUL». Usa título 14 en negrita, ejes 12, etiquetas de ID, leyenda y cuadrícula horizontal discontinua con alpha=0.5. Ajusta el diseño y muestra el gráfico.

**EVIDENCIA ESPERADA**

- Dos barras por ID.
- Real frente a predicho.
- Unidad: ciclos de RUL.
- Diferencias por campaña.

**COMPARACIÓN AL INICIO**

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

31

CIERRE DEL EJERCICIO

## Qué comprobar al interpretar el modelo

**LECTURA DOCENTE**

El modelo aprende con SAG1 y se evalúa en su prueba interna y en SAG2.

La prueba interna usa una división aleatoria de filas. Esto no verifica el desempeño en campañas nuevas.

ID y Cycle son entradas del modelo. Revisa el aporte del identificador al extrapolar a otros equipos.

Las barras usan el primer registro de cada campaña. Su RUL es el máximo solo si los datos lo confirman.

**EVIDENCIA DEL EJERCICIO**

- Métricas de SAG1 y SAG2.
- Gráficos real frente a predicho.
- RUL inicial por campaña.
- Prompts y resultados trazables.

**INTERPRETAR CON CONTEXTO**

DIMEC INGENIERÍA MECÁNICA UNIVERSIDAD DE CHILE

STGI INDUSTRIES

32

SESIÓN 21

ESCANEA EL CÓDIGO QR

RESPONDE UNA BREVE ENCUESTA

CONGRESO DE MANTENIMIENTO & CONFIABILIDAD CHILE 7ª EDICIÓN

# ¡GRACIAS!

**Raymi Vásquez Moreno**

rvasquez@stgi.cl

DIMEC INGENIERÍA MECÁNICA

33