



1



2

Presentación de una metodología, un concepto o una mejora práctica y de alto impacto.

En la Sesión Spark aprenderás cómo lograr un cambio a corto plazo, mediante proyectos simples y potentes que impactan la confiabilidad de tu planta, aquí se plantea el problema, el fundamento técnico y el paso a paso de implementación incluyendo los detalles y los beneficios esperados en términos financieros y de confiabilidad.

La Sesión Spark está diseñada para que tengas resultados notorios en tu estrategia.



SPARK



CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
COLOMBIA

1^a
EDICIÓN



Diagnóstico de fallas mediante Inteligencia Artificial Explicable: Un camino hacia el Mantenimiento Prescriptivo

PhD (c) Raymi Vásquez Moreno

Gerente y Académico

3



Preguntas



CONGRESO DE
MANTENIMIENTO
& CONFIABILIDAD
COLOMBIA

1^a
EDICIÓN

- ¿Qué tan lejos estamos de identificar la causa raíz y predecir la falla mediante Inteligencia Artificial Explicable (XAI)?
- ¿Cómo se utiliza la IA explicativa y cuál es su aporte para el Mantenimiento Prescriptivo (RxM)?

4

Más preguntas

¿Cuándo?

¿Cómo?

¿Porqué?

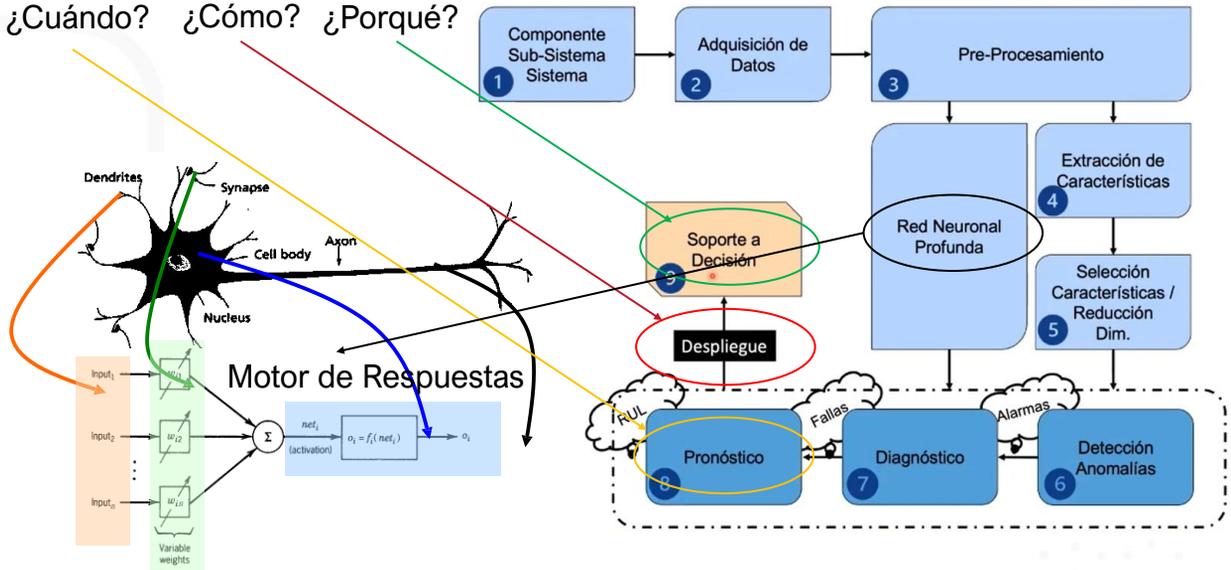


¡FALLA!

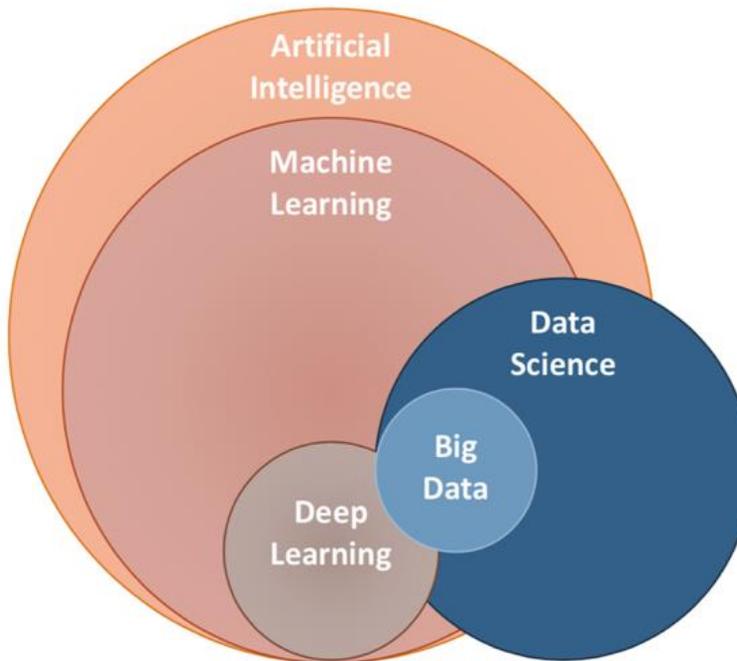
5

El camino a las respuestas

¿Cuándo? ¿Cómo? ¿Porqué?



6



Deep Learning

- Detección anomalías
- Diagnóstico de Fallas
- Pronóstico de Fallas (RUL)

7

Inteligencia Artificial Explicable (XAI)

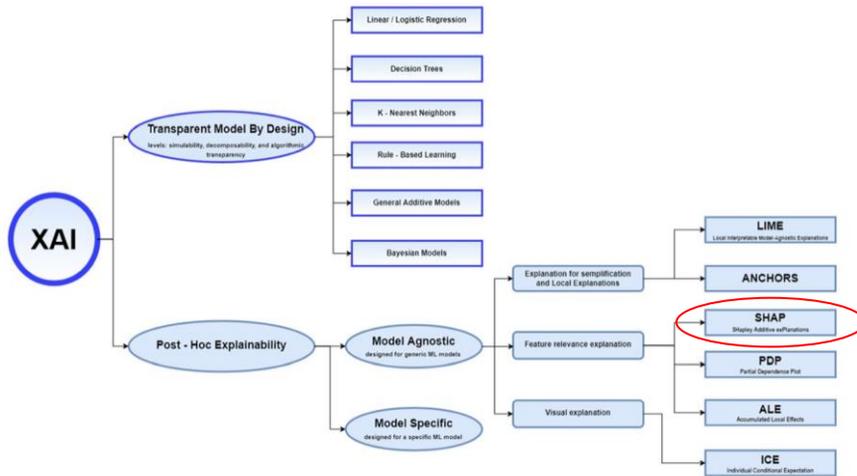
Interpretabilidad – Explicabilidad – Transparencia

Es una **técnica** o conjunto de reglas que sirve para **comprender el resultado producido por los algoritmos de aprendizaje de máquina**. La IA explicable **garantiza** que se entiende correctamente **lo que sucede dentro de la "caja negra"** y porqué algún modelo predictivo llega a un determinado resultado.



8

Interpretabilidad Transparente versus Post-Hoc



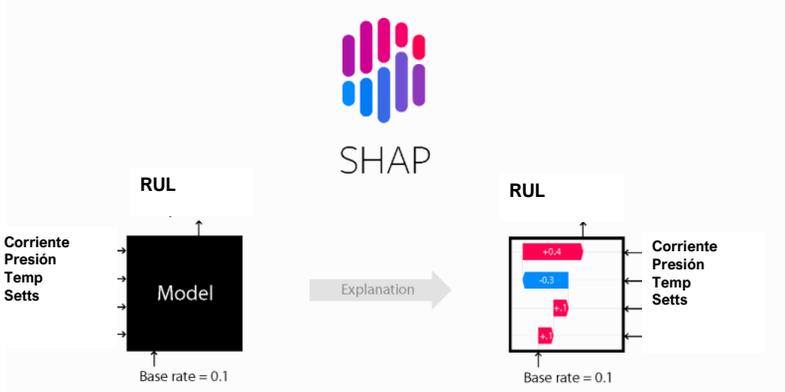
9

Herramientas

10

SHAP (SHapley Additive exPlanations)

El método SHAP se basa en la **teoría de juegos** y asigna valores de importancia a cada **característica o atributo de entrada**, indicando su **contribución al resultado de una predicción**.



11

Teoría del Juego



Lloyd Shapley Premio Nobel en Economía 2012

¿Cuál es la contribución de cada jugador (en pulgadas)?



Permutacione	Contribución Marginal			Total
	Ana	Bernardo	Carmen	
A, B, C	2	32	4	38
A, C, B	4	34	0	38
B, A, C	2	32	4	38
B, C, A	0	28	10	38
C, A, B	2	36	0	38
C, B, A	0	28	10	38
Promedio	2	32	4	38

En base a todas las permutaciones de jugadores, se obtiene la contribución marginal de cada jugador:

Valor de Shapley: promedio de las contribuciones marginales en todas las permutaciones

12

Implementación

13

Casos de Aplicación



Diagnóstico

Diagnóstico de aceite en ejes, engranajes, sistemas hidráulicos y bombas



Pronóstico

Modelo de predicción de RUL Chancador de Conos

14

Diagnóstico de Aceite Mediante Redes Neuronales y SHAP

Los datos de aceite analizados contienen los resultados de las pruebas de aceite químico de cuatro tipos de equipos: ejes, engranajes, hidráulica y bombas, cada uno asociado con los siguientes estados de salud:

La base de datos levantada contiene 29 variables medidas:

– Concentración (en ppm) de los siguientes elementos químicos:

Fe, Cr, Al, Cu, Pb, Ni, Ag, Sn, Ti, V, Cd, Mn, Na, K, Si, Zn, Ba, B, Ca, Mo, Mg, P

– Y también contiene el contenido de agua, V40, índice de oxidación y la cantidad de partículas 4, 6 and 14 [μm]

Estados de Salud
Contaminación por Agua
Contaminación Lubrificante
Contaminación por Sílice (Desgaste)
ISO 4406 - Sílice
Degradacion Componente
Normal

15

Dataset

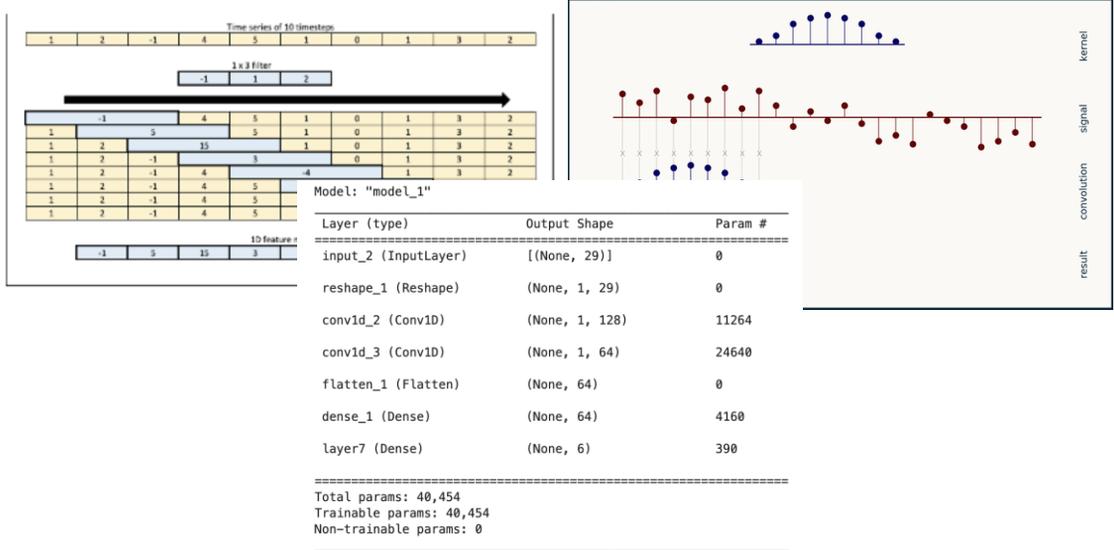
AceiteDataFinal

	Hierro	Cromo	Aluminio	Cobre	Plomo	Nickel	Plata	Estano	Titanio	Vanadio	Cadmio	Manganeso	Sodio	Potasio	Silicio	Zinc	Bario	Boro	Calcio	Molibdeno	Magnesio	Fosforo	v 40	Contenido agua	Índice PQ	Oxidacion	Particulas > 4um	Particulas > 6um	Particulas > 14um	
305835	4.6	0.1	0.1	2.1	0.8	0.1	0.1	0.6	0.1	0.1	0.1	0.5	0.1	0.1	0.1	0.1	0.1	0.1	2.4	0.1	0.1	0.1	171.0	325.45	0.0	5	3.41	59773	13379	
35359	8.9	0.1	0.2	7.4	13.4	0.1	0.1	1.5	0.1	0.1	0.1	0.7	3.2	0.1	0.8	5.8	0.1	0.1	0.1	0.1	0.1	0.1	0.1	46.61	0.0	0	1.34	100707	19985	
40110	18.6	0.2	0.6	17.8	5.6	0.2	0.1	0.9	0.1	0.1	0.1	0.1	4.2	0.9	2.9	9.4	0.1	0.2	2.8	0.1	0.4	0.1	0.4	45.87	0.0	5	2.1	175972	35857	
41584	10.9	0.1	0.5	8.1	3.1	0.1	0.1	2.1	0.1	0.3	0.1	0.1	2.6	0.1	1.9	7.9	0.1	0.1	0.8	0.1	0.1	0.1	0.1	44.18	0.0	5	3.14	66324	12836	
44097	24.8	0.4	2.3	4.5	3.2	0.2	0.1	0.2	0.2	0.2	0.1	0.1	6.7	1.9	8.1	8.8	0.2	0.1	14.1	0.1	0.4	0.1	0.4	44.71	0.0	20	1.64	251923	34960	
44100	4.9	0.1	0.5	11.2	6.0	0.3	0.1	1.1	0.1	0.1	0.3	0.1	0.9	0.6	5.5	4.4	0.1	0.1	0.6	0.1	0.1	0.1	0.1	44.82	0.0	0	1.74	170759	31676	
46566	15.3	0.1	0.7	4.3	7.4	0.1	0.1	2.3	0.3	0.1	0.1	0.1	2.2	0.4	7.0	8.3	0.1	0.1	2.0	1.0	0.1	0.1	0.1	47.11	0.0	5	3.67	66079	8601	
50512	29.1	0.3	2.4	12.7	4.9	0.2	0.1	0.1	0.5	0.1	0.1	0.1	9.9	7.9	4.5	2.8	0.1	0.3	5.8	0.1	0.5	0.1	0.1	47.11	0.0	10	2.29	72814	12284	
222045	3.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	1.8	0.1	3.3	7.0	0.1	0.1	77.3	0.1	0.1	0.1	0.1	278.0	31.33	0.0	10	11.62	3543	1164
49314	56.9	0.4	0.3	29.2	0.1	0.1	0.1	0.1	0.3	0.1	0.2	0.1	21.5	2.2	5.2	2.2	0.1	0.1	6.7	0.1	0.9	0.1	0.9	246.0	207.46	0.0	55	3.44	460126	51881
117268	13.0	0.3	0.2	7.5	0.1	0.1	0.1	0.1	0.1	0.1	0.5	0.1	0.1	6.9	0.1	0.1	2.2	0.1	0.4	4.6	0.1	0.1	0.1	162.0	195.33	0.0	30	3.4	197378	63841

	value counts	normalized value counts
Normal	6156	0.492322
Component Wear	3391	0.271193
Silica ISO 4406	1251	0.100048
Oil Contamination	671	0.053663
Silica and Wear	530	0.042386
Water Contamination	505	0.040387

16

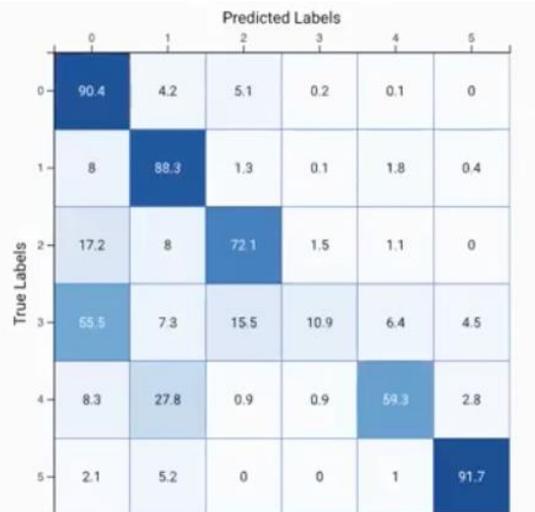
Modelo Convolucional CNN 1D



17

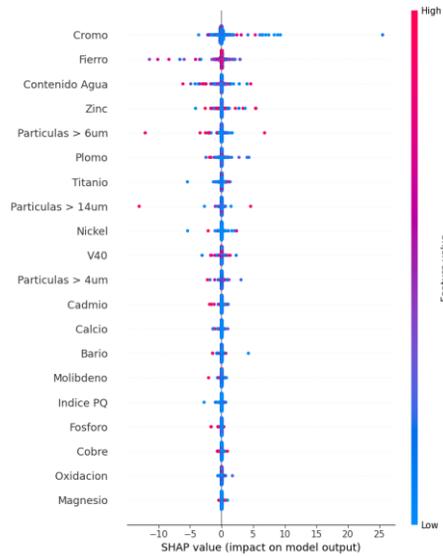
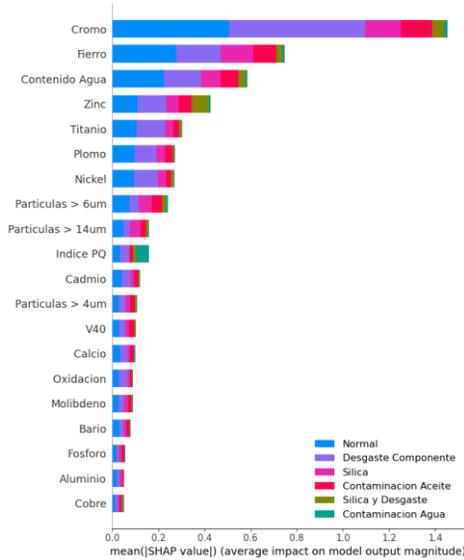
Resultados Modelo

	value counts	normalized value counts
Normal	6156	0.492322
Component Wear	3391	0.271193
Silica ISO 4406	1251	0.100048
Oil Contamination	671	0.053663
Silica and Wear	530	0.042386
Water Contamination	505	0.040387



18

Explicabilidad - SHAP



19

Modelo de Predicción de RUL usando Aprendizaje Profundo y Explicabilidad

Objetivo:

Predicir la Vida Útil Remanente (RUL) de un Chancador, interpretando el aporte con que las variables medidas contribuyen al resultado, entregando información útil para agregar valor a la Gestión de Mantenimiento.

Tabla 1: Variables Proceso Chancador

Sensor	Unidad
Nivel de Taza	%
Setting	Mm
Corriente	%
Vibración Anillo A	%
Vibración Anillo B	%
Vibración Anillo C	%
Vibración Anillo D	%
Temperatura Retorno	°C
Temperatura Socket Liner	°C
Temperatura Excéntrica	°C
Temperatura de Alimentación	°C
Temperatura Descanso Contraeje	°C
Presión Contraeje	KPa
Momento de extracción del dato	Minutos



20

Dataset

	Corriente	Presion Eje	T Retorno	T Linner	T Excentrica	T Aliment	T Eje	Salto Anillo A	Salto Anillo B	Salto Anillo C	Salto Anillo D	Nivel Taza	Setting
0	53.116678	397.350503	42.511208	38.548751	55.440959	37.087506	37.142696	6.308733	7.797914	5.269836	12.928383	58.329089	30.900005
1	53.546035	395.546147	42.518389	38.555126	55.461630	37.116928	37.125363	6.330681	7.830601	5.277999	12.973285	58.419730	30.900005
2	53.858053	393.518869	42.525626	38.565060	55.484201	37.148881	37.109482	6.349047	7.854290	5.286077	12.999629	58.464022	30.900005
3	54.143239	391.388374	42.535520	38.575420	55.507048	37.176316	37.095289	6.351748	7.874629	5.295749	13.039208	58.581805	30.900005
4	54.421468	389.397444	42.545053	38.585373	55.530216	37.204764	37.081771	6.366810	7.903681	5.312778	13.070902	58.685670	30.900005
...
108990	37.434734	291.689619	39.049215	38.768671	50.969099	34.523347	36.866025	6.164857	10.703224	5.284494	9.850106	3.120214	34.105095
108991	36.194670	289.110832	38.977744	38.720983	50.799280	34.542031	36.753359	6.002350	10.376490	5.133574	9.565115	2.605324	34.084756
108992	34.885465	286.729674	38.906723	38.676570	50.632756	34.563979	36.641144	5.827959	10.051675	4.971431	9.292903	2.090431	34.064417
108993	33.664623	283.737090	38.837840	38.634441	50.468479	34.588403	36.530279	5.663102	9.736394	4.820048	9.045319	2.090277	34.044078
108994	32.624796	279.563692	38.774135	38.594506	50.306511	34.615753	36.419865	5.505859	9.420716	4.679721	8.789691	2.090153	34.023739

108995 rows × 13 columns

Modelo Predictivo Denso DNN

Internal Structure Of Neural Network

Capa 1 Capa 2 Capa

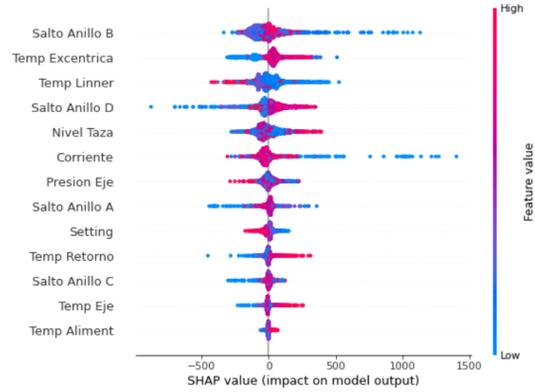
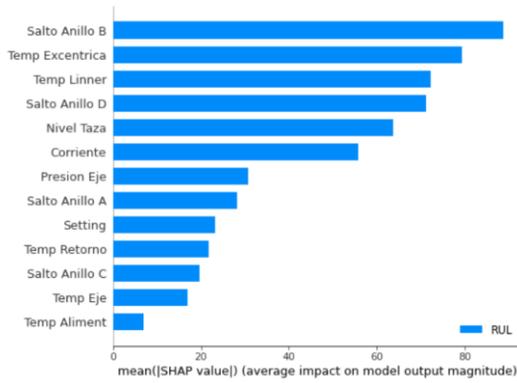
Sensors

x 13 x 200 x 200 x 200

```
# Compile the trained model
model.compile(loss = 'mse', optimizer = 'adam')
model.summary()

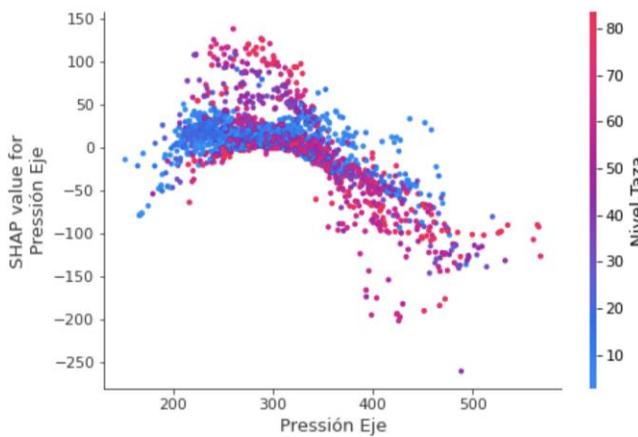
Model: "model_10"
-----
Layer (type)                Output Shape         Param #
-----
input_12 (InputLayer)      [(None, 13)]         0
dense_14 (Dense)            (None, 200)          2800
dense_15 (Dense)            (None, 200)          40200
dense_16 (Dense)            (None, 200)          40200
layer12 (Dense)             (None, 1)            201
-----
Total params: 83,401
Trainable params: 83,401
Non-trainable params: 0
```

Explicabilidad – SHAP – Reportes Globales



23

Correlación

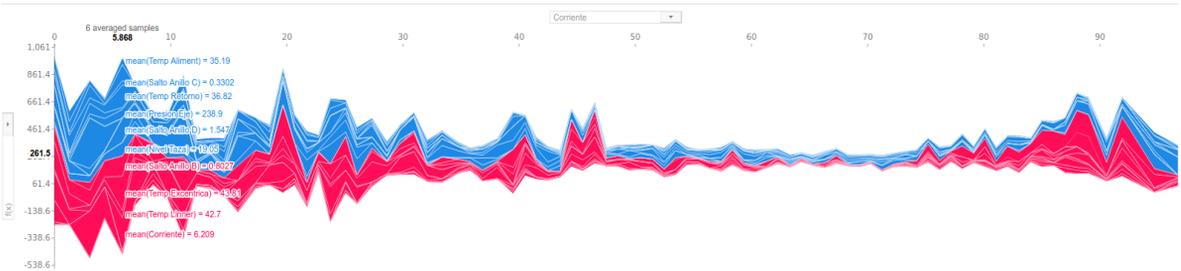


Muestra el efecto marginal que tienen una variable sobre el resultado predicho por el modelo

- Presión Eje: tiene una tendencia no lineal y positiva con RUL
- Nivel Taza es la variable que interactúa frecuentemente con presión eje

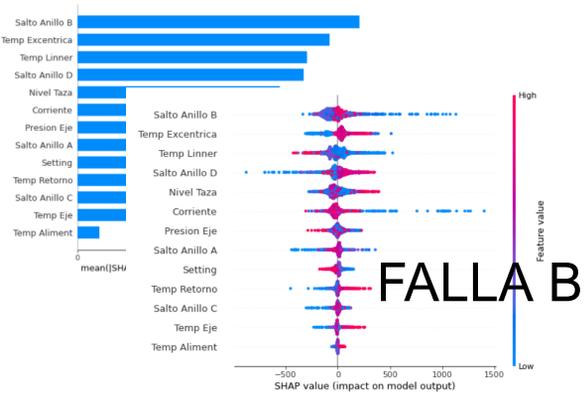
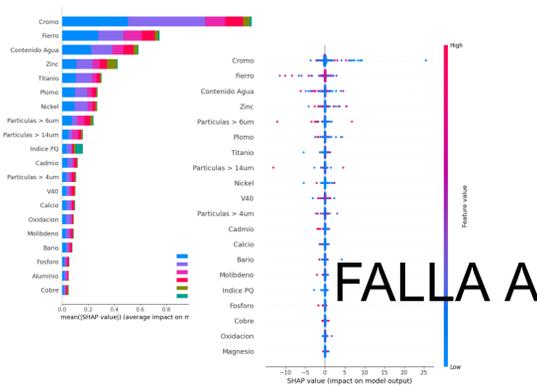
24

Reportes Locales



Mantenimiento Prescriptivo (RxM)

El mantenimiento prescriptivo representa un enfoque vanguardista de la gestión de activos, que utiliza análisis avanzados y aprendizaje automático para predecir las necesidades de mantenimiento y optimizar el rendimiento de los equipos antes que fallen de manera imprevista.



Operador consulta...



¡Los patrones de falla “catalogada” y “estudiada” ACR se presentan!



¡Sabemos cuándo pasa, cómo pasa y por qué pasa!

27

¡Gracias!

Raymi Vásquez M.
rvasquez@stgi.cl

28