

## PREDICCIÓN DE FALLAS EN INTERCAMBIADORES DE CALOR MEDIANTE EL USO DE INTELIGENCIA ARTIFICIAL: CASO DE ÉXITO DE LA REFINERÍA DE CARTAGENA DE ECOPETROL SA.

ASOCIACIÓN COLOMBIANA DE INGENIEROS

Calle 70 No. 9 – 10

Ramon.Ariza@ecopetrol.com.co – Ingeniero de Confiabilidad e Integridad, Ecopetrol SA

Herber. Rincon @ecopetrol.com.co – Líder de Gestión de Activos GRC, Ecopetrol SA

### Resumen

En la Unidad de Alquileración de la Refinería de Cartagena, se desarrolló un modelo predictivo basado en machine learning para anticipar fallas por corrosión bajo depósitos en el intercambiador de calor E-11. Entrenado con datos de una falla ocurrida en 2020, el modelo genera una probabilidad de falla al identificar patrones entre las variables que afectan la transferencia de calor y la acumulación de depósitos. Tras su implementación, el 1 de abril de 2024, el agente predictivo detectó un patrón de falla con más de un año de anticipación, permitiendo tomar acciones preventivas y evitar una nueva falla. El monitoreo continuo de las variables de proceso por parte de la inteligencia artificial optimizó la disponibilidad operativa y redujo costos asociados a paradas no programadas.

### Caso de Éxito: Pre calentador de Carga a la Isodespojadora, E-11.

La Unidad de Alquileración de la Refinería de Cartagena produce 8.700 BPD de alquilato, utilizando ácido fluorhídrico (HF) como catalizador en la reacción entre isobutano y butilenos mixtos. Tras la reacción, la corriente líquida es enviada a la isodespojadora, pasando previamente por el pre calentador de carga E-11, donde recupera calor del alquilato producto caliente proveniente de la columna desbutanizadora.

### Antecedente de falla y causas.

En septiembre de 2020 se presentó falla por rotura de tubos del intercambiador E-11, lo que permitió el pase de efluentes de reacción al alquilato producto, afectando la calidad de este, Ver Figura 1.




Figura 1. Falla del intercambiador de carga a ala isodespojadora.

Previo a la parada del equipo, una termografía externa evidenció zonas frías en el lado casco, indicando la acumulación de depósitos en la superficie del intercambiador, Ver Figura 2.




Figura 2. Termografía externa realizada mostró zonas frías por acumulación de depósitos,

La inspección interna del equipo confirmó la presencia de depósitos excesivos y la rotura de tubos, Ver Figura 3.



Figura 3. Falla de 2020 de los E-11, ocasionada por patrón de ensuciamiento acelerado y corrosión ácida bajo depósitos

La caracterización de los residuos encontrados en el interior del intercambiador confirmó que los depósitos correspondían a fluoruros orgánicos e inorgánicos, acumulados de manera no prevista en las paredes del equipo, Ver Figura 4.



Figura 4. Análisis de residuos y su coloración amarilla permitió concluir que se tenían compuestos azufrados.

El análisis histórico del coeficiente de transferencia de calor (U) permitió identificar una aceleración en la tasa de ensuciamiento, correlacionada con eventos previos de ingreso de azufre y otros contaminantes durante la corrida de la unidad. Sin embargo, estas contaminaciones estaban enmascaradas dentro de la tendencia general del coeficiente, Ver Figura 5, lo que dificultó su detección temprana.

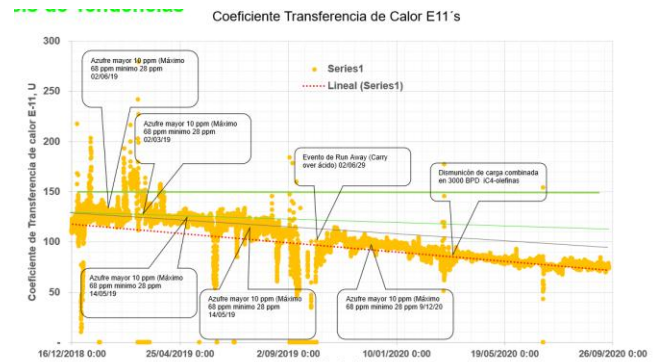


Figura 5. la disminución del coeficiente global de transferencia de calor en el E-11.

Inicialmente, el ensuciamiento se debía principalmente a condiciones de baja velocidad asociadas a baja carga en los equipos. No obstante, la combinación de baja velocidad y azufre provocó un ensuciamiento acelerado, generando un

mecanismo de degradación que llevó a la falla estructural del equipo.

### Antecedentes en el análisis de corrosión en intercambiadores de calor con Modelos de Machine Learning

#### **Modelos tradicionales de predicción y mitigación de la corrosión**

Las metodologías convencionales para la predicción de la corrosión en intercambiadores de calor se han basado en modelos empíricos y estudios experimentales. Un problema crítico en estos equipos es el ensuciamiento (fouling), que reduce la eficiencia térmica y favorece la corrosión por la acumulación de depósitos en las superficies metálicas. Sundar et al. (2020) aplicaron redes neuronales para predecir la resistencia al ensuciamiento, demostrando su alta precisión [1]. Sin embargo, su enfoque se limitó al impacto térmico del ensuciamiento, sin abordar la interacción entre depósitos y procesos corrosivos.

En sistemas de tuberías de hidrocarburos, se han desarrollado diversos modelos para predecir la corrosión interna y externa. Fang et al. (2023) utilizaron Random Forest y CatBoost para estimar tasas de corrosión en tuberías de crudo y gas natural [2]. Su estudio resaltó la influencia de variables como temperatura, velocidad del fluido y pH, aunque su aplicación a intercambiadores de calor sigue siendo un área de oportunidad.

#### **Aplicación de inteligencia artificial en la predicción de la corrosión**

Los avances en inteligencia artificial han permitido mejorar la detección y predicción de la corrosión. Al-Khalidi et al. (2024) emplearon redes neuronales convolucionales (CNN) para la identificación de corrosión en tuberías mediante imágenes de drones y mediciones ultrasónicas [3]. Akhlaghi et al. (2023) implementaron

aprendizaje profundo para predecir la corrosión por picadura en tuberías enterradas, obteniendo resultados de alta precisión [4]. No obstante, estos estudios se enfocan en infraestructuras de transporte de hidrocarburos, sin abordar equipos de proceso como intercambiadores de calor.

#### **Estudios sobre corrosión bajo depósitos en intercambiadores de calor**

Coelho et al. (2022) realizaron una revisión sobre la aplicación del aprendizaje automático en la predicción de corrosión, resaltando la necesidad de modelos específicos para escenarios industriales complejos [5]. Si bien los modelos de aprendizaje profundo han demostrado potencial en la predicción de corrosión, aún no se ha desarrollado un modelo específico para la corrosión bajo depósitos en intercambiadores de calor, lo que abre oportunidades para nuevas investigaciones en este campo.

### Implementación del Modelo de Machine Learning para la Predicción de Falla del Intercambiador E-11

El proceso de implementación de los agentes de inteligencia artificial para la predicción de fallas en el intercambiador E-11 de la Unidad de Alquiler siguió una secuencia estructurada que incluyó la selección de sensores clave, el desarrollo de modelos basados en el coeficiente de transferencia de calor  $U$  y la temperatura media logarítmica (LMTD), así como la evaluación del desempeño del agente mediante métricas como F1 Score y Sensitivity.

## Conexión con el Historiador y Creación de la Fuente de Datos de Sensores

Se estableció la conexión con el historiador de datos de la refinería, permitiendo la extracción de información operacional del intercambiador E-11.

Los sensores clave fueron organizados en dos grupos:

Sensores del intercambiador:

- Temperatura de entrada y salida del fluido caliente (lado casco).
- Temperatura de entrada y salida del fluido frío (lado tubos).
- Flujos volumétricos del lado casco y tubos.
- Diferencial de presión en el intercambiador

Sensores de proceso (aguas arriba y aguas abajo):

- Variables adicionales de composición del fluido y presión diferencial.
- Caudales de alimentación en los sistemas conectados al intercambiador.

Esta segmentación permitió evaluar cómo influían las condiciones externas en la degradación térmica del equipo.

## Auditoría de Sensores y Definición de Condiciones Offline

Antes del entrenamiento del modelo, se realizó una auditoría de sensores para detectar períodos sin datos o mediciones inconsistentes. Se aplicaron estrategias como:

- Interpolación de datos faltantes para corregir lagunas en los registros.
- Filtrado de valores atípicos para evitar distorsiones en el entrenamiento.

- Exclusión de datos en períodos fuera de servicio para evitar sesgos en el modelo.

Se identificó que algunos sensores aguas arriba carecían de registros en el período anterior a la falla, por lo que no pudieron utilizarse para el análisis.

## Sensores calculados: Cálculo del Coeficiente de Transferencia de Calor (U) y LMTD

Se establecieron los siguientes sensores calculados, que son parámetros derivados a partir de las variables de proceso:

El parámetro U (coeficiente de transferencia de calor) es un indicador clave para detectar el ensuciamiento del intercambiador. Se definió mediante la ecuación:

$$U = \frac{Q}{A \times LMTD} \quad (1)$$

Donde:

- Q es el flujo de calor entre los fluidos.
- A es el área de transferencia térmica (considerada constante).
- LMTD (Log Mean Temperature Difference) es la temperatura media logarítmica, calculada como:

$$LMTD = \frac{\Delta T_1 + \Delta T_2}{\ln\left(\frac{\Delta T_1}{\Delta T_2}\right)} \quad (2)$$

Siendo:

- $\Delta T_1$  = Diferencia de temperatura entre el fluido caliente y el fluido frío a la entrada.
- $\Delta T_2$  = Diferencia de temperatura entre el fluido caliente y el fluido frío a la salida.



La disminución progresiva de U y la reducción del LMTD fueron utilizados como indicadores tempranos de ensuciamiento crítico.

### Entrenamiento del Agente Predictivo: Análisis de Desempeño.

El desempeño del agente se evaluó con métricas estándar de machine learning. El F1 Score y la Sensitivity (Sensibilidad) son métricas clave en la evaluación del rendimiento del modelo de inteligencia artificial para la predicción de fallas en el intercambiador E-11.

La Tabla I, muestra los resultados del entrenamiento del agente de inteligencia artificial, en el que aprendió a predecir la falla que ocurrió en 2020.

Tabla I.

Métrica	Valor
F1 Score	0.836
Sensibilidad (Recall)	0.719
Precisión	1.000
Verdaderos Positivos	7547
Falsos Positivos	0
Verdaderos Negativos	20827
Falsos Negativos	2953
Número de Muestras	31327

### Interpretación de Sensibilidad

La sensibilidad, también conocida como recall o tasa de verdaderos positivos, mide la capacidad del modelo para identificar correctamente los casos positivos (fallas detectadas). Se define como:

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \quad (3)$$

Donde:

- TP (True Positives): Son las instancias positivas correctamente clasificadas.

- FN (False Negatives): Son las instancias positivas incorrectamente clasificadas como negativas.

Para el caso del E-11 la sensibilidad es 0.719, lo que significa que el modelo detecta correctamente el 71.9% de las fallas reales.

### Interpretación del F1 Score

El F1 Score es una métrica de desempeño que equilibra la precisión y la sensibilidad del modelo.

El F1 Score Se define como:

$$F1 = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{recisión} + \text{Sensibilidad}} \quad (4)$$

Donde

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (5)$$

En este caso, el F1 Score = 0.836, lo que indica que el modelo tiene un buen balance entre detectar correctamente las fallas (sensibilidad) y minimizar las falsas alarmas (precisión).

La evaluación del modelo predictivo mostró una precisión de 1.000, garantizando que no se generaron falsas alarmas y que todas las fallas detectadas fueron reales. Con un F1 Score de 0.836, el modelo logró un buen balance entre precisión y sensibilidad, detectando correctamente 7547 fallas. Sin embargo, la sensibilidad de 0.719 indica que aún 2953 fallas no fueron identificadas a tiempo, lo que representa un 28.1% de falsos negativos.

La gráfica de resultado del entrenamiento respecto a la falla de septiembre de 2020 muestra cómo el modelo identificó una tendencia creciente de ensuciamiento desde 2019, (dos años después de inicio de operaciones en 2017) alcanzando su punto crítico de falla en 2020, Ver Figura 6.




Figura 6. Patrón de falla aprendida por el modelo de Machine Learning, se muestra curva de probabilidad de falla coincidiendo con la fecha del evento real de septiembre 2020.

El cálculo de la probabilidad de falla aprendida por el entrenamiento de modelo mostró una dependencia del parámetro LMTD y el coeficiente de transferencia lado tubos, ver Tabla II.

Tabla II.

Prevalencia (%)	Sensor Role
80.72%	LMTD
9.76%	Uf-tubos
3.31%	Temperatura entrada lado casco E-11/11A
1.55%	Delta T2
1.43%	Flujo lado tubos
0.98%	U Global

### Detección de Patrones de Falla: Caso del 1 de abril de 2024

Tras el ajuste del agente, se procedió a su despliegue en vivo (Deploy Live), donde comenzó a operar en modo de monitoreo continuo.

El 1 de abril de 2024, el agente de inteligencia artificial detectó un patrón de falla con más de un año de anticipación. La alerta fue analizada por un equipo interdisciplinario, que identificó restricciones en el flujo del intercambiador E-11 debido a obstrucciones aguas arriba. Se implementó un plan correctivo para restablecer la

operación confiable y prevenir una falla similar a la de 2020. Ver Figura 7.



Figura 7. Alerta temprana generada por el modelo de Machine Learning

### Discusión: Avances y Desafíos en la Implementación del Modelo Predictivo en el Intercambiador E-11

#### **Contribución de las Variables Físicas y Evaluación del Modelo**

La detección del ensuciamiento en intercambiadores de calor es un desafío que involucra múltiples factores físicos, entre ellos, la influencia del coeficiente de transferencia de calor (UU) y la temperatura media logarítmica (LMTD) como parámetros intermedios en el mecanismo de degradación. La reducción progresiva de U refleja un deterioro térmico del equipo, lo que indica la acumulación de depósitos que pueden incubar procesos de corrosión localizada.

Un aspecto clave es la relación entre tiempos y masas críticas de formación de depósitos y su efecto en la aceleración del ensuciamiento. En este sentido, la curva de aceleración de acumulación de depósitos obtenida por el modelo sugiere que existe un período crítico donde la tasa de ensuciamiento se incrementa significativamente, lo que puede inferirse a partir del comportamiento dinámico de las variables de temperatura y flujo. Este tipo de análisis es difícilmente realizable con modelos convencionales manuales, que dependen de mediciones puntuales y suposiciones sobre las propiedades del fluido.

El modelo predictivo no solo aprendió cómo se desarrolló el primer evento de ensuciamiento, sino que también estableció una probabilidad de falla basada en la afinidad entre los datos actuales del equipo y el patrón aprendido inicialmente.

### **Impacto en la Operación y Potencial de Mejora**

La implementación del modelo permitió tomar acciones correctivas a tiempo, evitando una parada no programada y estableciendo estrategias operativas para minimizar los efectos del ensuciamiento en el E-11. Un hallazgo relevante fue que la alerta generada llevó a los ingenieros de confiabilidad y procesos a identificar restricciones en equipos aguas arriba, lo que permitió realizar ajustes operativos y optimizar el uso del intercambiador. Esto demuestra que los agentes predictivos no solo detectan fallas locales, sino que pueden ayudar a descubrir problemas sistémicos en la unidad.

Un aspecto crítico en la discusión es la comparación del modelo basado en machine learning con metodologías convencionales. Anteriormente, la predicción del ensuciamiento dependía del análisis manual de tendencias de temperatura y flujo, basado en ecuaciones tradicionales y juicios cualitativos de los ingenieros. Este proceso consumía tiempo y recursos sin garantizar una detección temprana de fallas. Con el modelo de IA, se logró automatizar el monitoreo y mejorar la capacidad de respuesta, reduciendo la necesidad de intervención humana en tareas rutinarias y permitiendo a los ingenieros enfocarse en análisis estratégicos.

Sin embargo, un desafío importante es la falta de modelos de referencia con los cuales comparar la eficacia del agente predictivo. La literatura sobre modelos específicos para predicción de fallas en intercambiadores de calor sigue siendo limitada, lo que abre una oportunidad para futuros estudios en este campo.

### **Conclusión**

El éxito del modelo implementado en el E-11 demuestra que los agentes predictivos pueden ser altamente eficaces en la detección temprana de fallas en equipos estáticos, un área donde tradicionalmente los modelos de IA han estado más enfocados en equipos rotativos. Sin embargo, aún existen desafíos importantes en la integración de modelos de corrosión bajo depósitos, la mejora en la sensibilidad del agente y la validación de predicciones en otros intercambiadores de la planta.

Además, la relación entre las condiciones operativas, la composición del fluido y la geometría del equipo sigue siendo un factor clave en la evolución del ensuciamiento, lo que sugiere la necesidad de desarrollar modelos híbridos que combinen machine learning con simulaciones físicas y modelos determinísticos.

En última instancia, el impacto más significativo de esta implementación radica en su capacidad para optimizar la confiabilidad operativa, reducir costos de mantenimiento y minimizar tiempos de inactividad. Con la evolución de estos modelos, la predicción de fallas en equipos de proceso avanzará hacia un enfoque más proactivo e integrado, transformando la manera en que las plantas industriales gestionan la integridad de sus activos.

### **Referencias**

- [1] Sundar, S., "Deep Learning Model for Fouling Prediction in Heat Exchangers", *Journal of Process Engineering*, Vol. 35, pp. 120-135, 2020.
- [2] Fang, Y., Li, T., y Zhang, W., "Application of Machine Learning for Corrosion Rate Prediction in Crude Oil Pipelines", *Energy & Fuels*, Vol. 37, pp. 255-270, 2023.

[3] Al-Khalidi, R., Chen, M., y Liu, H., "Detection of Pipeline Corrosion Using Convolutional Neural Networks", *International Journal of Corrosion Science*, Vol. 48, pp. 95-110, 2024.

[4] Akhlaghi, M., y Rahimi, P., "Predicting Pitting Corrosion in Buried Pipelines Using Deep Learning Models", *Materials Performance Journal*, Vol. 27, pp. 65-80, 2023.

[5] Coelho, J., Silva, R., y Martínez, F., "A Review on Machine Learning Applications for Corrosion Prediction in Industrial Environments", *Corrosion Reviews*, Vol. 40, pp. 312-329, 2022.

#### Ramón Ariza

Ingeniero Mecánico de la UIS. Actualmente se desempeña como Ingeniero de Confiabilidad e Integridad de la Refinería de Cartagena, donde ha liderado proyectos de RBI, RCM, modelado de datos y machine learning para la optimización de estrategias de mantenimiento. Ha participado en múltiples paradas de planta y gestión de integridad de unidades de proceso.

#### Herber Rincon

Ingeniero Mecánico de la UIS. Actualmente es el Líder de Gestión de Activos en la Refinería de Cartagena, con más de 15 años de experiencia en la industria del petróleo y gas. Ha ocupado roles clave en Ecopetrol y Reficar, especializándose en mantenimiento, confiabilidad y optimización de equipos estáticos y rotativos. Ha liderado proyectos de mantenimiento predictivo y machine learning para la prevención de fallas en equipos críticos. Es reconocido por su enfoque en la optimización de procesos, mejora continua y gestión estratégica de activos industriales.

#### NOTA

Para facilitar el contacto con los autores de trabajo se hace necesario suministrar al final del trabajo los siguientes datos:

#### Ramón Ariza

2. Teléfono
  - a. 3183899796
3. Dirección del autor(es)
  - a. Residencia: Av via al mar km 12, conjunto Puerta de las Americas, b6 APTo 3i.
  - b. Oficina: Av Mamonal km 10 , refineria de cartagena
  - c. E. mail ramon.ariza@ecopetrol.com.co
  - d. Caratgena
  - e. Colombia

#### Herber Rincon

2. Teléfono
  - a. 3176443578
3. Dirección del autor(es)
  - a. Residencia: Av via al mar km 10, conjunto Barcelona de Indias
  - b. Oficina: Av Mamonal km 10 , refineria de cartagena
  - c. E. mail herber.rincon@ecopetrol.com.co
  - d. Caratgena
  - e. Colombia