

PREDICCIÓN DE ENSUCIAMIENTO DE UN INTERCAMBIADOR DE PLACAS (PACKINOX) USANDO REDES NEURONALES LSTM

WILLIAN VARGAS SILVA; DOMINIGO A ESCALANTE SALAZAR
ECOPETROL
REFINERIA BARRANCABERMEJA

e.mail: William.vargass1@ecopetrol.com.co
Domingo.escalante@ecopetrol.com.co

Resumen

En este trabajo se presenta un modelo de mantenimiento predictivo, para el intercambiador de placas E-4701 (Packinox) de la planta de hidrot ratamiento de combustible de la Refinería de Barrancabermeja, el cual evidencia un ensuciamiento recurrente desde finales el año 2019, limitando la carga de la U4700. Debido a la complejidad del fenómeno físico químico y las múltiples variables que intervienen en la operación, se desarrolló un modelo basado en redes neuronales para identificar la variable problema y predecir el tiempo de ensuciamiento según las condiciones operacionales del equipo. En principio, se recopiló una base de datos de 21 variables de contexto operacional, desde enero 2013 a diciembre 2021, las cuales fueron correlacionadas y depuradas. Luego, se utilizó la librería de redes neuronales del programa Matlab, para construir el modelo de predicción de aumento de diferencial de presión en E-4701, utilizando una arquitectura de red tipo LSTM. Finalmente se logró un modelo que permite predecir el diferencial de presión teniendo en cuenta el histórico de los datos de entrenamiento, además se identificó el valor límite de la variable problema en la operación para evitar el ensuciamiento acelerado y el valor a partir del cual se revierte la reacción y se presenta la descomposición térmica de las sales disminuyendo el ensuciamiento del equipo.

Palabras clave: Predicción, Sublimación de sales, Ensuciamiento, Redes neuronales LSTM.

1. Introducción:

La pérdida de capacidad de transferencia de calor en los intercambiadores de la industria de petróleo, alteran el curso normal del proceso causando entre otras cosas mayor consumo de gas combustible, en algunos casos limitación de la carga y la inclusión de actividades de mantenimiento que genera aumento en costos operativos y disminución en los tiempos de corrida.

Una de las causas asociadas a la pérdida de transferencia de calor, es el ensuciamiento, conocido como la acumulación de depósitos no deseados en las superficies de transferencia. Esta

situación provoca un aumento de la resistencia térmica debido a que se reduce el área de la sección transversal de los tubos, lo que puede provocar el aumento de caída de presión y la reducción de caudal entre otros [1].

La planta de Hidrot ratamiento de Diésel (U4700) de la Refinería de Barrancabermeja, está diseñada con tecnología Prime DTM, licenciada por Axens, para procesar la mezcla de 56600 BPD de Diésel Virgen de alto azufre y Aceite liviano de ciclo (ALC) de las unidades de craqueo catalítico con un contenido de 5632 ppm de Azufre y 298 ppm de nitrógeno básico. El diésel virgen es una mezcla de las corrientes de

diésel de alto azufre provenientes de las unidades de destilación atmosférica y el ALC es una mezcla proveniente de las tres unidades de craqueo catalítico. Su proceso de hidrotratamiento, el cual elimina compuestos de azufre mediante la reacción con hidrógeno en reactores de lecho catalítico fijo, para producir Diesel de ultra bajo contenido de Azufre entre 5 y 25 ppm requerido por las regulaciones ambientales emitida por el gobierno nacional orientada a limitar los contenidos de azufre en los combustibles de Colombia recientes.

La planta inició su operación en agosto 2010; su primera corrida duro 8.5 años, se caracterizó por mantener una operación estable en su proceso, finalizo en enero 2019 cuando se realizó su primer mantenimiento Overhaul.

La planta tiene instalado un intercambiador de placas E-4701 denominado Packinox, se caracteriza por su alta eficiencia en la recuperación de calor y mínima caída de presión, sin embargo, tenía un antecedente recurrente de aumento gradual del diferencial de presión del lado efluente en los últimos años desde finales del 2019. Para recuperar la eficiencia energética e hidráulica del intercambiador de placas E4701, era necesario realizar el procedimiento de sublimación de sales el cual se restablece por paradas de la unidad, asociadas principalmente a disparos del compresor, siendo el ultimo procedimiento en el mes de marzo de 2021.

Posteriormente en el mes de Octubre de 2021, seis meses después de la última parada programada el incremento en el diferencial de presión del lado efluente alcanzó 46 psi vs 22 psi en condición de inicio de corrida, consistente a la deposición de sales de cloruros de amonio en sus paredes, lo que conllevó a una limitación energética debido a que la capacidad de transferencia de calor del intercambiador también se vio afectada y la energía adicional para mantener la operación de la unidad la asumió el Horno H-4701, el cual estaba operando cerca de su corte por alta presión de gas a quemadores según en el informe de análisis Técnico restricción en la carga total a reacción en la

U4700 emitido por el departamento de ingeniería de proceso el 25 de enero del 2021. [2].

Con el propósito de reducir los tiempos de inactividad y aumentar la disponibilidad del equipo, se han propuesto estrategias de mantenimiento predictivo utilizando la herramienta de redes neuronales tipo LSTM, debido a su capacidad para aprender funciones complejas no lineales obteniendo una respuesta confiable con el mínimo error.

Red neuronal LSTM (Long Short Term Memory)

El término LSTM es un acrónimo y significa Long Short Term Memory. Las redes neuronales de memoria a largo y corto plazo o LSTM es un tipo de Red Neuronal Recurrente en Aprendizaje Profundo que se ha desarrollado específicamente para el manejo de problemas difíciles de predicción secuencial, ya que estas capturan dependencias temporales a largo plazo sin sufrir los obstáculos de optimización comunes a las redes recurrentes simples (SRN) [3]. Las redes LSTM han sido utilizadas para la predicción del tiempo, predicción del mercado de valores [4], reconocimiento y generación de escritura a mano, traducción del lenguaje, el análisis de datos de audio y video, entre otros.

Al igual que otras redes neuronales, contienen neuronas para realizar cálculos; sin embargo, para LSTM se las denomina células de memoria o simplemente células. Estas células contienen pesos y puertas; las puertas son la característica distintiva de los modelos LSTM. Hay 3 puertas dentro de cada celda: La puerta de entrada, la puerta de olvido y la puerta de salida; estas puertas se usan para decidir qué información conservar o descartar. Además, contiene un estado de celda, que es como una memoria a largo plazo de LSTM. La Fig. 1 muestra un diagrama simplificado (Sin los pesos ni los sesgos) de una unidad recurrente LSTM para ver cómo se procesa la información [5].




Fig 1. Unidad Recurrente LSTM.

Fuente: [5]

1. Estado oculto y nuevas entradas: el estado oculto de un paso de tiempo anterior (h_{t-1}) y la entrada en un paso de tiempo actual (x_t) se combinan antes de pasar copias a través de varias puertas [5]
2. Forget gate: esta puerta controla qué información debe olvidarse. Dado que la función sigmoidea oscila entre 0 y 1, establece qué valores en el estado de la celda deben descartarse (multiplicarse por 0), recordarse (multiplicarse por 1) o recordarse parcialmente (multiplicarse por algún valor entre 0 y 1).
3. La puerta de entrada ayuda a identificar elementos importantes que deben agregarse al estado de la celda. Tenga en cuenta que los resultados de la puerta de entrada se multiplican por el estado de celda candidato, y solo la información que la puerta de entrada considera importante se agrega al estado de celda.
4. Actualizar el estado de la celda: primero, el estado de la celda anterior (c_{t-1}) se multiplica por los resultados de la puerta de olvido. Luego agregamos nueva información de [entrada puerta $\times$ estado de celda candidato] para obtener el último estado de celda (c_t).

5. Actualizar estado oculto: la última parte es actualizar el estado oculto. El último estado de celda (c_t) se pasa a través de la función de activación $\tanh$ y se multiplica por los resultados de la puerta de salida.

Finalmente, el último estado de celda (c_t) y el estado oculto (h_t) regresan a la unidad recurrente y el proceso se repite en el paso de tiempo $t+1$. El bucle continúa hasta que llegamos al final de la secuencia.

En el presente documento se mostrará cómo, a través del uso de inteligencia artificial, se ha logrado crear una herramienta tecnológica que predice con un alto grado de exactitud el ensuciamiento del intercambiador packinox que opera con sistema de supervisión en línea y control de la condición operativa además de predecir la causa raíz del ensuciamiento acelerado del equipo.

2. METODOLOGÍA

Las actividades metodológicas se realizaron de forma secuencial en 6 etapas que se describen a continuación:

2.1 Identificación de variables del contexto operacional del intercambiador Packinox

A partir de la información reportada en PI datalink de Ecopetrol, se identificaron 21 variables de entrada y una de salida (PDI47120), con relevancia en el contexto operacional del intercambiador.

2.2 Definición del Periodo e Intervalo de Recolección de la Data

El periodo de recolección de datos fue desde enero 2013 a enero 2022, durante este tiempo se tiene la información de una operación estable en los primeros 6 años, y 3 años siguientes se evidenció una operación con comportamiento acelerado en ensuciamiento del intercambiador, requiriendo 2 paradas programadas de la planta para realizar el proceso de sublimación de sales y recuperar el

diferencial de presión y la eficiencia de intercambio energético.

2.3 Limpieza de la data y cálculo de variables

Se realizó una limpieza a los 108.79 millones de datos recopilados durante el periodo definido anteriormente, se eliminaron ruidos, valores congelados, valores atípicos, variables con data incompleta; debido a que entre más limpia es la data el aprendizaje de la red neuronal en más rápido, sin embargo, por la cantidad de variables y datos el proceso de convergencia tomó varias horas.

Se realizó el cálculo de las variables (PDI47163, PDI47016, PD47117), de las cuales no se tenía información en el PI datalink.

2.4 Correlación y Definición de Variables

Se grafican las 21 variables, y se analiza la correlación con la variable de salida asociado al ensuciamiento del equipo. Se elimina las variables que son constantes o no presenta variación en el tiempo de operación de 9 años.

De las 21 variables se seleccionaron 8 que presentaron mayor variabilidad correspondientes a: 1) PDI_47120, 2) LV_47002, 3) FIC_47002, 4) FIC_47003, 5) FI_47012, 6) TI_47099, 7) TI_47033, y 8) PI_47016.

De igual manera, se creó un conjunto de datos de prueba con las 8 variables, para cada uno de los casos se evaluó el comportamiento de la variable de salida.

2.5 Diseño del modelo de predicción de caída de presión PDI 47120 usando Red neuronal LSTM

Con la data limpia y las variables seleccionadas se inició el desarrollo del modelo de mantenimiento predictivo. Para esto se realizaron simulaciones a prueba y error, variando el número de capas y el número de neuronas por capa, hasta obtener un buen entrenamiento de la red neuronal LSTM, con desempeño óptimo en la predicción; Se llevó a cabo

los siguientes pasos:

- **Normalización de datos**

Los datos de los conjuntos de entrenamiento y de prueba, se estandarizaron utilizando el método de puntuación estándar o tipificada, descrito en la ecuación 1:

$$y_i = \frac{x_i - \bar{x}}{s} \quad (1)$$

Donde y_i es el valor estandarizado, x_i son los datos de entrada, $\bar{x}$ es el promedio de los datos de entrada y s es la desviación estándar de los datos de entrada calculados mediante las ecuaciones 2 y 3:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2)$$

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

- **Descripción de la red LSTM**

Para la simulación desarrollada se utilizó una red neuronal LSTM de 4 capas: una capa de entrada de secuencia con 8 dimensiones, dos capas ocultas de tipo LSTM con 180 y 90 neuronas respectivamente, y una capa de salida totalmente conectada de dimensión 1, correspondiente al valor de la predicción de PDI_47120, con salida de regresión con el valor del error cuadrático medio (mean-squared-error) como respuesta.

- **Entrenamiento del modelo**

Para entrenar el modelo de red LSTM se utilizó el conjunto de datos de entrenamiento con sus 8 variables y el vector de Targets de entrenamiento correspondiente a la variable PDI_47120 adelantada un tiempo en la secuencia. El entrenamiento de la red LSTM utiliza el parámetro RMSE (mean-squared-error) de la secuencia de datos de entrenamiento como indicador de comportamiento, para el ajuste de los pesos de la red neuronal con una tasa de

aprendizaje de 0,005.

La Fig. 2 muestra la evolución de los parámetros de entrenamiento a lo largo de 20 iteraciones de aprendizaje, con una reducción progresiva del error.




Fig 2. Evaluación de parámetros de entrenamiento.
Fuente Autor

La Fig. 3 muestra la validación del entrenamiento realizado comparando el PDI_47120 real y su predicción, obteniéndose un error cuadrático medio final de RMSE = 0,94803.




Fig 3. Validación del entrenamiento. Fuente Autor

• Simulación con los datos de prueba

El conjunto de datos de prueba también se estandarizó usando el método de estandarización de puntuación estándar.

• Predicción

El conjunto de datos de prueba estandarizados se ingresa en el modelo de red LSTM entrenado para hacer predicciones en lazo cerrado del comportamiento de PDI_47120.

• Filtrado usando filtro de Kalman

Las salidas de predicción de la red LSTM se filtraron usando el algoritmo de filtro de Kalman para mejorar la estimación de la salida, eliminando ruidos e incertidumbres de medición. Para la implementación del filtro de Kalman se usaron las ecuaciones 4, 5, 6 y 7, correspondientes a un sistema dinámico unidimensional.

$$\hat{x}_{n,n} = \hat{x}_{n,n-1} + K_n(z_n - \hat{x}_{n,n-1}) \quad (4)$$

$$K_n = \frac{p_{n,n-1}}{p_{n,n-1} + r_n} \quad (5)$$

$$p_{n,n} = (1 - K_n)p_{n,n-1} \quad (6)$$

$$p_{n+1,n} = p_{n,n} + q_n \quad (7)$$

Donde $\hat{x}$ es el estado del sistema, K es la ganancia de Kalman, z es la medición del estado del sistema, p es la incertidumbre de la estimación extrapolada, r es la incertidumbre de la medición y q es la varianza del ruido de proceso [6].

2.6 Validación de resultados

Los resultados arrojados por el modelo fueron validados teniendo en cuenta información reportada en literatura e información de corrida en planta. Además, con estos se buscó dar una explicación fisicoquímica del fenómeno.

3. RESULTADOS

Teniendo en cuenta que los problemas de ensuciamiento en el intercambiador de calor E-4701 se evidencian principalmente, con el aumento de la caída de presión y la reducción en la transferencia de calor al precalentamiento de la carga asociado a un incremento de temperatura de salida al lado efluente. A continuación, se presenta los resultados obtenidos para cuatro simulaciones a diferentes grados de temperatura TI_47099, con sus respectivos datos de prueba estandarizados, los cuales fueron ingresados al modelo de la red LSTM entrenado para hacer predicciones en lazo cerrado del comportamiento de PDI_47120.

Simulación 1. Este escenario se construyó tomando una Temperatura TI_47099 alta (650°F), evaluada por un lapso de 5 meses, obteniendo un PDI_47120 final de 51,7782 psi. De acuerdo con la Figura 4, se puede observar que la tendencia del diferencial de presión es acelerada creciente en el tiempo llegando a valores de caída de presión altos en 4 meses.



Fig 4. Simulación con TI 47099=650°F.
Fuente autor

Simulación 2. Este escenario se construyó tomando una Temperatura TI_47099 intermedia alta (640°F), evaluada por un lapso de 6 meses, obteniendo un PDI_47120 final de 52,3422 psi. De acuerdo con la Figura 5, se puede observar que la tendencia del diferencial de presión es creciente con menor rapidez de ensuciamiento en el tiempo que en la

simulación 1.



Fig. 5. Simulación con TI_47099 = 640°.
Fuente Autor

En estas dos primeras simulaciones se puede identificar la formación de sal de cloruro de amonio, la cual requiere la presencia de HCl, compuesto formado en las reacciones laterales del hidrotratamiento a condiciones severas, debido a la interacción de los cloruros con el hidrogeno.

Simulación 3: En este escenario se tomó una Temperatura TI_47099 de 630°F por un lapso de 6 meses, obteniendo un PDI_47120 final de 26,5742 psi con una tendencia no progresiva en el tiempo. Como se muestra en la Figura 6.



Fig. 6. Simulación con TI_47099 = 630°.
Fuente: Autor

Simulación 4: Temperatura TI_47099 baja: Se seleccionó una temperatura baja de 584°F para TI_47099 por un lapso de 15 meses, obteniendo un PDI_47120 final de 11,4663. Como se muestra en la Figura 7. El periodo de evaluación permitió establecer que no hay un incremento del diferencial de presión en el tiempo en esas condiciones.



Fig 7. Simulación con TI_47099 = 584°
Fuente: Autor.

De lo anterior se puede inferir, que, a mayor temperatura, se tiene un aumento en la caída de presión y disminución en la eficiencia de la transferencia de calor. Favoreciendo la deposición de cloruro de amonio (NH_4Cl) o bisulfuro de amonio (H_5NS o NH_4HS); fenómeno que ocurre cuando la sal precipita de un vapor que contiene tanto amoníaco como cloruro de hidrógeno.

Esta deposición se produce cuando el producto de las presiones parciales molares del amoníaco y el cloruro de hidrógeno es mayor que la constante de estabilidad (K_p) del cloruro de amonio a la temperatura del sistema. Si el producto de las presiones parciales es menor, o si la temperatura es mayor, el amoníaco y el cloruro de hidrógeno serán termodinámicamente más estables que la sal sólida de cloruro de amonio y no se produciría la deposición.

Por su parte, el bisulfuro de amonio precipita a condiciones menores de temperatura y mayores de presión, dentro ciertos límites, mientras que el

cloruro de amonio puede precipitar en un amplio rango de temperatura y presiones parciales.

Análisis Fenómeno de Sublimación

A partir de la correlación de variables Figura 8 se puede evidenciar que, a temperaturas mayores a 380°F (línea negra en escala 1:10), se ocasiona el fenómeno de sublimación, disminuyendo la diferencial de presión PDI47120 (línea roja).




Fig 8. Fenómeno de sublimación de sales. Fuente Autor

De acuerdo con Alvisi & Lins, 2018, quienes referencian la parada de una unidad de hidrotreatment de Diesel por ensuciamiento (obstrucción) de los intercambiadores del efluente de reacción, las sales que se forman y ensucian son típicamente el Bisulfuro de Amonio y principalmente el Cloruro de Amonio, este último se forma y precipita por debajo de los 200°C (390°F) por la reacción del amoníaco y el ácido clorhídrico.



lo cual indica que cuando se sube la temperatura por encima de 390°F se revierte la reacción y se presenta la descomposición térmica de las sales (en algunos artículos llaman a este fenómeno Chemical Sublimation) y por esto el Packinox se limpia. [7].

Validación de Hipótesis.

Con el modelo de la red neuronal LSTM validado, se realiza predicción variando una de las variables de entrada, de acuerdo con la hipótesis que se esté evaluando. A continuación, se evalúa la hipótesis del efecto del agua sobre PDI_47120.

Simulación 5: Se realizó el ejercicio de predicción del comportamiento de la diferencial de presión manteniendo al 100% apertura la válvula LV47002 durante 30 días continuos, en dos escenarios con temperatura de entrada lado efluente TI47099 a 630°F y 640°F con una operación normal de las demás variables de entrada. Las figuras 9 y 10 muestran que, al agregar agua no hay cambios considerables en la tendencia de la variable de salida.




Fig 9. Predicción LV47002=100% 30 días continuos a 630°F. Fuente autor.

Para este caso se evaluó solo contenido de agua, no es posible evaluar el agua con otros contaminantes debido a que no se tiene data. De acuerdo con Aydee Quiroga & Laura G. (2021) quienes referencian en el excelente informe contenido de sales en la carga producto de los lavados de la UOPII que termina en la corriente de ALC como carga a la U4700 [8].




Fig 10. Predicción LV47002=100% 30 días continuos a 640°F. Fuente autor.

CONCLUSIONES

- El modelo desarrollado con la red neuronal LSTM mostró como resultado de parámetro de validación del entrenamiento un error cuadrático medio final de RMSE: 0.94803, logrando predecir el ensuciamiento basado en las condiciones operacionales; de esta manera se puede incluir como una herramienta de toma de decisiones por parte de los ingenieros de proceso de la planta que les permite aumentar la disponibilidad del equipo y disminuir los costos operacionales.
- Con el modelo se pudo descartar varias hipótesis que se habían planteadas como: el contenido de agua en la carga, aumento de presión del sistema, aumento de carga de ciclo los cuales se observaron todos con respecto al DP47120 en ningún de los escenarios presentó tendencia a aumentar la diferencial de presión.
- Los resultados del modelo fueron muy confiables, tiene concordancia con la explicación fisicoquímica de la interpretación de los datos mencionados anteriormente, por tanto, se realizó

la sublimación de sales sin parar la planta disminuyendo la diferencia de 50 psig a 16 psig, y recuperando la eficiencia energética de la unidad el 1 de febrero 2022.

- Con los resultados de la herramienta se obtuvo un ahorro por eficiencia energética de 20000 PCEH en consumo de gas combustible que equivale a 65376 USD además de los costos por no parar la planta para realizar la sublimación 460.000 USD.
- El proceso de sublimación de sales se debe realizar controlado el flujo de hidrogeno y flujo de carga liquida para evitar posible remoción ligera de los sólidos del lado carga que podría afectar el primer lecho del R-4701.

BIBLIOGRAFÍA

[1] Hale, M. (2020). Comprender y prevenir el ensuciamiento del intercambiador de calor. *IndustriAmbiente: gestión medioambiental y energética*, (31), 32-34.

[2] Muñoz Andrés., & M.E Oswaldo. (2022). Análisis Técnico Restricción en la carga total a reacción en la U4700. Disponible: Departamento de ingeniería de proceso en la refinería de Barrancabermeja.

[3] Klaus Greff, et al., LSTM: Una odisea espacial de búsqueda, 2015.

[4] WU, Jimmy Ming-Tai, et al. Un algoritmo de predicción de precios de acciones CNN-LSTM basado en gráficos con indicadores principales. *Sistemas multimedia*, 2021, pág. 1-20.

[5] Dobilas, Saúl. Redes neuronales recurrentes LSTM: cómo enseñar a una red a recordar el pasado, 2022. Disponible en: [https://towardsdatascience.com/lstm-recurrent-neural-networks-how-to-teach-a-network-to-](https://towardsdatascience.com/lstm-recurrent-neural-networks-how-to-teach-a-network-to-remember-the-past-55e54c2ff22e)

[remember-the-past-55e54c2ff22e](https://towardsdatascience.com/lstm-recurrent-neural-networks-how-to-teach-a-network-to-remember-the-past-55e54c2ff22e)

[6] Becker, Alex (2022). Filtro Kalman en una dimensión. Disponible en: https://www.kalmanfilter.net/ES/kalman1d_es.html

[7] Alvisi, P., & Lins, V. D. F. C. (2008). Acid salt corrosion in a hydrotreatment plant of a petroleum refinery. *Engineering Failure Analysis*, 15(8), 1035-1041.

[8] Aydee Quiroga & Laura G. (2021). Analítica operacional para identificar la causa raíz de los problemas de ensuciamiento de la Prime D (4700) del E4701, con base en la actualización de la información de plantas aguas arriba de la unidad 2021. Disponible: Centro de innovación y tecnología – ICP Gerencia de desarrollo Tecnológico.