



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



INNOVACIÓN EN LA GESTIÓN DE VENTANAS OPERATIVAS DE INTEGRIDAD: MACHINE LEARNING PARA LA PREDICCIÓN Y PREVENCIÓN DE DESVIACIONES DE IOW

Javier Armando González Lizcano, Yesid Carvajal Niño, Angélica María Zapata Uribe

Gerencia Refinería de Barrancabermeja

Email : javierar.gonzalez@ecopetrol.com.co, yesid.carvajal@ecopetrol.com.co,
angelica.zapata@ecopetrol.com.co

Barrancabermeja, Santander – Colombia

Resumen

La gestión de la integridad de activos en la industria de *oil and gas*, es un proceso transversal cuyo objetivo principal es asegurar que los activos operen de manera confiable, segura y eficiente durante su ciclo de vida.

Dentro de este proceso, el programa de Ventanas Operativas de Integridad (IOW por sus siglas en inglés) establece límites definidos para variables de proceso que, si se exceden, pueden afectar la integridad de los equipos. Los IOW se integran como un componente clave de la gestión de integridad, permitiendo monitorear y controlar parámetros operativos críticos para evitar o minimizar mecanismos de daño que como consecuencia podrían provocar paradas no programadas o pérdidas de contención. La correcta definición y seguimiento de los IOW es fundamental para prevenir la degradación acelerada de los activos. Sin embargo, tradicionalmente, el análisis de IOW ha sido reactivo, basado en la ocurrencia del evento de violación de estos límites.

Por medio del presente trabajo se presenta la evolución hacia un enfoque anticipativo, donde se busca predecir la ocurrencia de violaciones de IOW antes de que sucedan, permitiendo una gestión proactiva de la integridad. Esta innovación se soporta en el uso de metodologías de Machine Learning (ML), que facilita la identificación de patrones y correlaciones para relacionar datos de variables de proceso con ocurrencia de violaciones de IOW. Esto finalmente permite anticipar escenarios de riesgo y tomar acciones preventivas.

Perspectiva inicial: Gestión de la Integridad de activos e importancia de las IOW

Una parte sustantiva de fallas en equipos fijos se asocia a operación fuera de límites no detectados a tiempo, lo que acelera mecanismos de daño y eleva el riesgo de pérdida de contención; la práctica recomendada API RP 584 establece el marco para definir, monitorear y responder a IOW con base en mecanismos de daño y acciones escalonadas[1].

En entornos de refinación, la adecuada gestión de la integridad de activos depende de la capacidad para identificar y controlar oportunamente las condiciones operativas que aceleran mecanismos de degradación. Cuando las IOW no se gestionan eficazmente, las desviaciones pueden permanecer inadvertidas, favoreciendo incrementos



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



acumulativos en la tasa de degradación, pérdida de confiabilidad y eventual pérdida de contención, particularmente en equipos sometidos a cargas térmicas, químicas o mecánicas variables[2]. Estudios de integridad de activos destacan que aproximadamente el 40% de las fallas en equipos estáticos ocurren por operación fuera de límites críticos no detectados o no atendidos de manera oportuna [3]

La experiencia del sector evidencia que excursiones no detectadas de variables críticas escalan rápidamente en degradación, pérdidas de contención y paradas no programadas. El costo promedio de parada no planificada en una refinería mediana puede alcanzar USD 0.5–1.0 millón por día, considerando únicamente producción diferida, sin incluir costos de reparación, penalizaciones ambientales o impacto reputacional [4]. Casos emblemáticos como la explosión en BP Texas City en 2005, donde la operación fuera de límites en una unidad de isomerización contribuyó al evento catastrófico, sitúan el impacto total acumulado en aproximadamente USD 2.5–3.0 mil millones, subrayando el costo extremo de operar fuera de los *envelopes* de integridad y reaccionar tardíamente [5]. En contraste, programas IOW bien implementados, integrados con sistemas de monitoreo en tiempo real y gestión de daños por corrosión (CDM), habilita salvas operacionales que evitan semanas de indisponibilidad en equipos críticos, con impacto económico estimado entre USD 5–20 millones por evento evitado [4]

Gestión de IOW: Enfoque tradicional

Históricamente, la gestión de IOW se ha apoyado en procedimientos manuales y el juicio del operador desde tableros de control, complementado con alarmas puntuales configuradas en el sistema de control distribuido (DCS) y análisis posterior a la excursión mediante revisión de históricos. Este esquema activa acciones correctivas una vez que el límite ya ha sido violado, consolidando un enfoque esencialmente reactivo centrado en la investigación "después" del evento [1]. Si bien la API RP 584 describe las IOW como límites de integridad y detalla respuestas escalonadas tras excedencias, en la práctica industrial este marco ha derivado en un esquema predominantemente reactivo [1]

Este enfoque tradicional presenta retos bien documentados en la literatura. El factor humano introduce variabilidad en la respuesta ante alarmas, especialmente en salas de control con alta densidad de alertas donde estudios indican que hasta el 80% de las alarmas pueden ser desestimadas o ignoradas por los operadores[6]. Adicionalmente, las ventanas definidas de forma parcial resultan insuficientes cuando el riesgo depende de paquetes de variables correlacionadas difíciles de vigilar manualmente — por ejemplo, la interacción entre temperatura de piel, distribución de flujo, eficiencia de combustión y composición del crudo en hornos de procesos— lo que favorece la detección tardía de condiciones precursoras de daño [7]

Las mejores prácticas actuales migran hacia una capa digital y proactiva que integra IOW con sistemas de gestión de daños por corrosión (CDM) y monitoreo en tiempo real mediante historiadores y sistemas de gestión de datos de integridad (IDMS). Esta integración se complementa con analítica avanzada y *Machine Learning* (ML) para identificar patrones precursores y predecir excursiones antes de que ocurran [8]. Casos de implementación a nivel refinería documentan la viabilidad operativa de esta integración, mientras que estudios en seguridad de procesos demuestran que los modelos de ML aceleran la detección de anomalías entre 2 y 4 horas



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



antes que los métodos convencionales, mejorando significativamente la toma de decisiones y reduciendo paradas no programadas[8] El caso de negocio se refuerza consistentemente: refinerías con programas maduros de confiabilidad y reducción de paradas no planificadas reportan impactos económicos del orden de USD 20–50 millones anuales, justificando la transición del paradigma reactivo hacia uno anticipativo habilitado por datos y ML [4]

Desafíos en la gestión de IOW

El desafío se acentúa porque, en la práctica industrial, la gestión de IOW suele estar condicionada por procesos altamente dependientes del factor humano. La identificación de excursiones recae en el juicio del operador que monitorea el tablero de control en tiempo real, introduciendo variabilidad en los tiempos de respuesta, priorización subjetiva ante múltiples alarmas concurrentes y potencial fatiga cognitiva que puede comprometer la efectividad de la detección [6]. Investigaciones recientes en seguridad operacional de refinerías evidencian que esta dependencia en decisiones reactivas aumenta la probabilidad de que anomalías tempranas pasen desapercibidas, especialmente en unidades de alta complejidad como hornos de reformación, sistemas de aminas o trenes de destilación al vacío donde las interacciones entre variables son numerosas y no lineales[9]

A nivel técnico, la definición de IOW también presenta dificultades significativas. En procesos complejos, un único parámetro rara vez captura la dinámica completa del riesgo asociado a un

mecanismo de daño específico. Muchos mecanismos, como la corrosión por ácidos nafténicos, la sulfidación a alta temperatura o el agrietamiento por tensión en medios alcalinos, requieren el monitoreo de conjuntos de variables correlacionadas (temperatura de piel, distribución de flujo, eficiencia de combustión, carga térmica, composición del crudo y presencia de especies corrosivas) [2]. La literatura especializada en gestión de integridad de activos reporta que la implementación de IOW a nivel de planta tiende a quedar parcial o incompleta, ya sea por falta de datos históricos suficientes para establecer límites estadísticamente robustos, complejidad en los mecanismos de degradación, o ausencia de sistemas que integren múltiples señales operativas de forma sincronizada para generar indicadores compuestos de riesgo[3]

Estas limitaciones operacionales y técnicas evidencian la necesidad de evolucionar desde un esquema tradicional reactivo, donde las acciones se toman después de la violación del límite, hacia un enfoque donde la gestión de la integridad sea anticipativa y predictiva. Avances recientes en integridad y seguridad de procesos demuestran que el uso de analítica avanzada y *Machine Learning* puede identificar patrones ocultos y precursores de falla antes de que se produzca una violación visible de los límites, reduciendo la dependencia del operador y fortaleciendo el control preventivo del riesgo mediante alertas tempranas basadas en datos [10]

Metodología

El enfoque anticipativo en la gestión de ventanas operativas de integridad se ejemplifica mediante un caso específico que involucra el horno de una unidad de destilación de crudos en la refinería de Barrancabermeja. En este contexto, la temperatura de piel de tubos constituye una variable crítica y se ha incorporado como límite de ventana operativa.



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



Esto se debe a que, desde la perspectiva de integridad, superar dicho valor límite puede ocasionar la degradación prematura o incluso la rotura de la tubería.

Este caso de estudio se centra en el horno de una unidad de destilación de crudos en la refinería de Barrancabermeja, donde se ejemplifica el enfoque anticipativo en la gestión de ventanas operativas de integridad. En este contexto, la temperatura de piel de tubos ha sido identificada como una variable crítica y se ha establecido un límite por alta temperatura. Desde una perspectiva de integridad, superar este valor límite puede desencadenar la degradación prematura o incluso la rotura de la tubería.

La anticipación se fundamenta en la identificación de patrones en las variables operativas del horno, que permiten detectar de manera temprana la ocurrencia de una violación a este límite establecido.

Principio de anticipación en la ciencia de datos

Implementación de modelos predictivos

El principio de anticipación aplicado en la gestión de ventanas operativas de integridad se materializa, desde la perspectiva de la ciencia de datos, mediante el uso de modelos de clasificación binaria. Estos modelos tienen como objetivo determinar si ocurrirá una violación del límite de la ventana operativa en un futuro próximo.

Variables predictoras basadas en series temporales

Para alcanzar esta meta, se utilizan variables predictoras extraídas de series temporales. Los datos operativos se recopilan de manera continua a lo largo del tiempo, permitiendo analizar el comportamiento de las variables antes del momento en que se produce la violación del límite establecido para la ventana operativa. De esta forma, el modelo puede anticipar el riesgo y contribuir a una gestión proactiva del mantenimiento y la integridad en las operaciones.

Recolección de datos:

La recolección de datos se llevó a cabo con una resolución temporal de una hora, abarcando el periodo comprendido entre 2020 y 2025. Para el análisis, se seleccionaron variables claves relacionadas con la combustión, la cantidad de calor absorbido por el producto, el calor suministrado por el gas, las condiciones del hogar y el tiro, entre otras. En total, se consideraron 40 variables (véase Tabla 1), las cuales fueron identificadas como relevantes para la predicción de la violación de la ventana operativa.

Tipo de Variable	Cantidad
Presión	14
Temperatura	13
Flujo	6
Temperatura de piel	5
Duty	1
Nivel	1
Porcentaje	1
Total	41

Tabla 1 Tipos de variables usadas en modelamiento

Ingeniería de variables

Basándose en el juicio de expertos, se crearon variables derivadas cuyo objetivo es identificar



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



factores que puedan influir en la excedencia de los límites operativos de IOW.

Variable	Descripción	Justificación
Tiempo_de_sde_decoqu	Tiempo desde el último decoquizado	Mayor tiempo implica más ensuciamiento interno y aumento de temperatura de piel.
Delta_T_piel	Pendiente de temperatura de piel	Pendiente positiva señala tendencia sostenida de incremento térmico.
Delta_Delta_T_piel	Cambio en la pendiente de T° de piel	Variaciones bruscas indican aceleración anómala del calentamiento.
Qabs – Qentr	Calor absorbido menos calor entregado	Diferencias crecientes reflejan pérdida de eficiencia por ensuciamiento interno.
Qabs – Bridgewall	Relación calor absorbido vs. temperatura de techo	Incrementos del techo a igual flujo de calor revelan ineficiencias térmicas.
Delta_P_dámper	Diferencial de presión en el dámper	Mayor retención de gases eleva la exposición térmica y la T° de piel.
F_masico	Flujo másico del crudo	Flujos por debajo del mínimo de diseño favorecen el coquizamiento.

Tabla 2 Ingeniería de variables

Selección de las variables:

Grupos de variables

Con el objetivo de optimizar la detección de desviaciones y el proceso de modelado, las variables se organizan en conjuntos atendiendo a su vinculación con procesos específicos, ej. Combustión, Gases, Lado producto, entre otros. Esta clasificación se realiza mediante un enfoque sistemático que integra el juicio experto, el análisis de covarianza y la evidencia obtenida de resultados previos de modelos. El procedimiento seguido se detalla a continuación:

1. Se agrupan inicialmente todas las variables en un solo conjunto y se entrena un modelo básico.
2. Se evalúa la importancia de cada variable en la predicción.
3. Si alguna variable supera el 50% de importancia, se considera su exclusión y se forma un nuevo grupo.
4. El proceso se repite hasta obtener un conjunto de variables con el mejor poder predictivo.

Desarrollo y prueba de modelos:

El proceso de desarrollo de modelos se llevó a cabo utilizando la plataforma Mtell (Aspentech) y el entorno de desarrollo Visual Studio Code con Python. En el caso de Mtell, la selección de variables para el entrenamiento se realizó por grupos de variables, y eligiendo aquellas más relevantes para el fenómeno a modelar. Asimismo, se definió un rango temporal de entrenamiento que incluyó tanto los momentos en los que se presentaron violaciones de la ventana operativa, como periodos previos y posteriores a dichos eventos. Esta estrategia permite capturar adecuadamente la dinámica del sistema antes, durante y después de la ocurrencia de las anomalías, lo que contribuye a una mejor capacidad predictiva del modelo.

Se desarrollaron modelos de predicción de fallas, denominados agentes de falla, en la plataforma Mtell con el propósito de anticipar la ocurrencia de violaciones de la ventana operativa en un horizonte temporal futuro. Estos modelos generan, para cada instante de tiempo, una probabilidad de ocurrencia del evento de violación de IOW, donde el valor 1 indica la máxima probabilidad y 0 la mínima. Al evaluar continuamente este resultado probabilístico, se obtiene una curva temporal que refleja la evolución de la probabilidad de violación, la cual se espera que aumente progresivamente conforme se aproxima el momento real del evento.



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



Para el caso de Modelos en Python, se configuraron modelos de clasificación binaria, cuya tarea es predecir si en una ventana futura de tiempo existirá una violación de ventana operativa de piel de tubos o no. (1 – Violación en ventana de 8 h futuras, 0 no hay violación). Los modelos probados son Random Forest, Gradient Boosting, con una estrategia de sintonización de parámetros mediante Random Search.

Se configuran modelos de clasificación binaria en Python, orientados a predecir la ocurrencia de una excedencia de IOW de piel de tubos dentro de un horizonte temporal futuro. El objetivo del modelo es determinar, para una ventana de 8 horas siguientes, si se presentará una violación (valor 1) o no (valor 0). Se emplean algoritmos de Random Forest y Gradient Boosting, implementando una estrategia de sintonización de hiperparámetros basada en Random Search para optimizar el desempeño del modelo.

Datos para test:

Los modelos de clasificación desarrollados en Python utilizan una técnica de segmentación de datos para series temporales denominada ventana expansible. Esta metodología incrementa progresivamente el tamaño de la ventana de entrenamiento y el conjunto de pruebas, asegurando en todo momento que no se produzca fuga de información hacia el set de pruebas, lo que garantiza la integridad y validez de los resultados obtenidos por el modelo.

En los modelos desarrollados con Mtell, se omite de la selección del rango de entrenamiento algunos intervalos en los

que se registraron violaciones de IOW. Dichos periodos se reservan exclusivamente para la fase de validación, con el objetivo de evaluar el modelo.

Validación

Métricas de desempeño

Para evaluar la calidad del modelo, se usó principalmente la métrica F1 score combinada con sensibilidad (Recall).

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall}$$

$$Recall = \frac{TP}{TP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

TP: Casos donde el modelo detecta correctamente una violación de IOW.

FN: Casos donde el modelo no detecta una violación de IOW que sí ocurrió.

FP: Falsos positivos: el modelo indica una violación de IOW que no ocurrió.

En el contexto del estudio, resulta prioritario maximizar la detección de eventos “positivos” de violación de IOW en lugar de identificar los casos en que no se presentan dichas violaciones. Los falsos positivos pueden admitirse hasta un nivel medio, puesto que el análisis operacional de la alerta determinará si es necesario ejecutar acciones operativas para prevenir una violación inminente de la IOW.

Para los modelos desarrollados en Python, se aplica la estrategia de validación cruzada (Cross-Validation) con el objetivo de entrenar el modelo en diferentes subconjuntos de datos de entrenamiento. De este modo, el modelo incrementa su capacidad de generalización y robustez, lo que mejora su desempeño ante datos no vistos.



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



Resultados e impacto

La Tabla 3 y Tabla 4 presentan la descripción y los resultados obtenidos de los modelos más destacados durante la experimentación. Allí se expone las métricas de desempeño y las características técnicas de cada modelo evaluado.

El modelo M1 exhibe un rendimiento superior en las métricas F1 score y sensibilidad (recall) para modelo Mtell. El modelo identifica correctamente hasta el 71% de los eventos de violación de IOW. El modelo prioriza la detección de eventos positivos de violación de IOW, conforme a los objetivos del estudio.

Id	Tipo	Grupo de variables	Algoritmo
M1	Mtell	IOW TP Crítica	Non-linear resilient propagation
M2	Mtell	IOW TP Crítica w Temp. Piel	XGBoost
M3	Mtell	IOW TP Crítica	Linear
M4	Python	Lag rolling aggregates	Random Forest
M5	Python	Lag rolling aggregates	Gradient Boosting

Tabla 3 Descripción de modelos

Id	Lead time avg	F1 Score	Sensitivity	Precision
M1	5 d	0.45	0.713	0.329
M2	5 d	0.28	0.757	0.172
M3	4.5 d	0.148	0.417	0.090
M4	8h	0.769	0.811	0.773
M5	8h	0.697	0.679	0.761

Tabla 4 Resultados Modelos en set de prueba

La Figura 1 muestra los resultados obtenidos por el modelo M1. En el eje horizontal el tiempo, mientras que la línea roja punteada vertical indica el momento exacto en que ocurre el evento de excedencia de IOW. La curva superior, de

color verde, corresponde a la probabilidad de tener una violación de IOW calculada por el modelo. Debajo, se despliegan las gráficas de líneas que representan cada una de las variables seleccionadas como predictores en el modelo, permitiendo observar su comportamiento en el tiempo.



Fig. 1 Curva de probabilidad – variables predictoras modelo M1




Fig. 2 Detalle de curva de probabilidad de ocurrencia de violación de IOW – Evento 20-02-2022

El modelo M4, configurado en Python, demuestra un rendimiento superior en las tres métricas evaluadas: F1 Score, sensibilidad y precisión. Estos modelos, al compararse con la metodología de evaluación de Mtell, presentan mejores resultados. Sin embargo, se destaca la diferencia en la configuración de la tarea de predicción. En Python, el objetivo consiste en identificar si ocurrirá al menos una violación de la IOW en las próximas 8 horas. Por otro lado, Mtell busca calcular una probabilidad de falla que aumenta progresivamente conforme se aproxima el momento del evento.

Importancia de variables predictoras

La identificación de variables relevantes para la predicción resulta fundamental en el análisis de confiabilidad. El modelo no solo detecta eventos,



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



sino que también determina qué variables tienen mayor influencia en la anticipación de excedencia de IOW. Este análisis permite validar la robustez de los modelos con la evaluación de expertos en confiabilidad del equipo en estudio y orienta al área operativa sobre los parámetros críticos a monitorear para prevenir violaciones.

La Fig. 3 presenta el grado de importancia relativa entre variables del modelo M4, evidenciando que la variable **duty_gas_slope_24h**, que representa la pendiente de la relación entre calor absorbido por el producto y gas consumido, aporta hasta cinco veces más que otras variables.

Este resultado confirma, desde la perspectiva operativa del horno y los mecanismos de degradación, que se origina una aceleración en la pérdida de eficiencia y un aumento en el consumo de gas combustible para satisfacer la misma demanda de calor. La causa principal radica en el proceso de coquizamiento interior del crudo dentro del tubo del horno. Este fenómeno reduce la transferencia de calor, lo que obliga al sistema a consumir más gas combustible y provoca un incremento en la temperatura superficial de los tubos.




Fig. 3 Importancia de variables Modelo M4

Impacto

• Impacto operativo

El modelo se integra al análisis de condición del activo del horno y permite anticipar, con hasta 8 horas, la posible ocurrencia de una violación de la IOW. Esta capacidad habilita el envío automático de notificaciones por correo al personal de Operaciones y Confiabilidad, facilitando una respuesta temprana, el ajuste de parámetros operativos y la prevención de condiciones que comprometan la integridad del horno.

• Impacto económico

La reducción de violaciones de IOW genera beneficios directos al disminuir:

- Degradación acelerada de vida útil
- Alcance adicional de mantenimiento correctivo.

En total, la aplicación del modelo de anticipación a IOW de piel de tubos en el horno representa un beneficio potencial de 300K USD/año, considerando la sensibilidad actual del modelo (71%), que determina cuántas violaciones reales logra anticipar.

• Impacto en capacidades técnicas y escalabilidad

La implementación de este modelo abre el camino para desarrollar y escalar modelos anticipativos de IOW en otros hornos y equipos críticos del proceso. La experiencia adquirida fortalece las capacidades analíticas del equipo, habilita la adopción de estrategias de mantenimiento predictivo más robustas y consolida una base metodológica para futuras aplicaciones de IA operativa en la organización.



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



Conclusiones

- El uso de modelos de Machine Learning permite evolucionar la gestión de IOW hacia un enfoque anticipativo, se mostró la capacidad de identificar patrones operativos asociados a futuras violaciones de límites de integridad antes de que estas ocurran.
- El caso estudio aplicado a un horno de una refinería muestra que es posible anticipar la violación de ventana operativa de integridad por piel de tubos en hasta 8 horas en los modelos de clasificación binaria y hasta 5 días en modelos probabilísticos.
- El análisis de importancia de variables confirma los precursores identificados en los modelos son coherentes con mecanismos físicos de degradación del horno, en especial los asociados con pérdida de eficiencia térmica.
- La integración del modelo anticipativo al análisis de condición del activo fortalece la toma de decisiones de confiabilidad y operacionales para intervenir con oportunidad antes que se materializa el escenario de degradación.
- Desde el punto de vista de la gestión de activos, la anticipación a violaciones de IOW impacta en la mejora de la confiabilidad operativa, toda vez que evita situaciones que activan mecanismos de daño en los equipos. Esto impacta en una reducción en el mantenimiento correctivo no planificado y extendiendo la vida útil de los equipos críticos.
- Integrar los modelos predictivos y sus resultados al equipo operativo, con el fin de mejorar la adopción de estas herramientas avanzadas de analítica predictiva en la organización.
- Mantener los modelos vigentes, la gestión de alertas, identificación y marcaje de falsos positivos, y reentrenamiento, permite garantizar el ciclo de vida de los modelos analíticos y así, mantener resultados fiables y alineados con los cambios en los esquemas de operación.
- Es importante establecer una estrategia clara de respuesta operativa ante las alertas arrojadas por los modelos, definiendo acciones escalonadas para validas, ajustar y/o reducir severidad antes de la violación de IOW.
- Escalar la metodología a otros hornos y equipos críticos aprovechando la experiencia adquirida en el caso estudio como base metodológica para otros equipos, plantas y/o variables operativas.
- Continuar con la implementación del esquema sistemático de captura de beneficios reales durante un ciclo de corrida del horno.

Referencias

- [1] American Petroleum Institute, “API Recommended Practice 584: Integrity Operating Windows”, 2021, *API Publishing Services, Washington, DC, USA*.
- [2] Z. Han, J. Liu, J. Li, H. Kang, y G. Xie, “Integrated Application of Dynamic Risk-Based Inspection and Integrity Operating Windows in Petrochemical Plants”, *Processes*, vol. 12, núm. 7, p. 1509, jul. 2024, doi: 10.3390/pr12071509.
- [3] A. Giacobbe, G. Ancione, M. F. Milazzo, F. D’Antonio, P. Bragatto, y E. Piperopoulos, “Integrating IOW in the Estimation of the Risk of an

Recomendaciones



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



- Atmospheric Distillation Unit by Using a Bayesian Network”, en *Proceedings of the 33rd European Safety and Reliability Conference (ESREL 2024)*, Southampton, UK, 2024, pp. 2345–2352.
- [4] V. H. S. Venkatesh, “Maximizing Uptime: The High Cost of Downtime in Capital-Intensive Industries”, marzo de 2025. [En línea]. Disponible en: <https://www.linkedin.com/pulse/maximizing-uptime-high-cost-downtime-industries-srambikal-mzjaf/>
- [5] U.S. Chemical Safety y H. I. Board, “Investigation Report: BP Texas City Refinery Explosion and Fire”, Washington, DC, USA, 2007.
- [6] M. K. Caserta, “So, You’ve Got IOWs – What’s Next?”, *Inspectioneering Journal*, feb. 2025, [En línea]. Disponible en: <https://inspectioneering.com/journal/2025-02-27/11453/so-youve-got-iows-whats-next>
- [7] Inspectioneering y Antea, “Intelligent Integrity Operating Windows: From Limits to Live Signals”, junio de 2025. [En línea]. Disponible en: <https://inspectioneering.com/events/2025-05-13/11570/intelligent-integrity-operating-windows-from-limits-to-live-signals>
- [8] Persian Gulf University, “AI Applications in Oil, Gas, and Petrochemical Industries: Monitoring and Optimization”, en *Proceedings of the 2nd International Biennial Conference on Advances in Artificial Intelligence and Data Science (IBCAIDS 2026)*, Bushehr, Iran, 2026, pp. 45–52.
- [9] ABB, “Shymkent oil refinery adopts predictive maintenance with ABB technologies”, diciembre de 2025. [En línea]. Disponible en: <https://new.abb.com/chemical/shymkent-oil-refinery-adopts-predictive-maintenance-with-abb-technologies>
- [10] J. B. Avanashilingam y B. P. Velayudhan, “Explainable and Trustworthy AI for Fault Classification in the Tennessee Eastman Process: A Step Toward Industrial Autonomy”, *Int. J. Progn. Health Manag.*, vol. 17, núm. 1, pp. 112–128, ene. 2026.

Acerca de los autores

González Lizcano, Javier Armando

Profesional con más de 10 años de experiencia en los sectores industrial, energético, y tecnológico. Ingeniero Mecánico de la Universidad Industrial de Santander, Magister en Ciencia de Datos y Analítica de Negocios de la Universidad ESSEC – CentraleSupélec Paris MBA de la Universidad Pontificia Bolivariana. Ha desarrollado su carrera en compañías de talla mundial como Ecopetrol, Amazon, Total Energies. Su perfil integra ingeniería de confiabilidad, inteligencia de negocios y analítica



XXVIII CONGRESO INTERNACIONAL DE MANTENIMIENTO Y GESTIÓN DE ACTIVOS

22 AL 24 DE ABRIL DE 2026. Bogotá - Colombia



avanzada para potenciar el desempeño de los activos, la resiliencia operativa y mejorar la toma de decisiones. Actualmente orienta su trabajo en la aplicación de ciencia de datos e inteligencia artificial en confiabilidad, la optimización del mantenimiento y la solución de desafíos operativos a gran escala, integrando conocimiento técnico profundo con impacto en el negocio.

Carvajal Niño, Yesid

Ingeniero metalúrgico, cuenta con maestría en Ingeniería Metalúrgica y especialista en corrosión. Cuenta con más de 30 años de experiencia en gestión de integridad de activos, confiabilidad operativa y control de corrosión en equipos estáticos de procesos industriales de alta criticidad. Su trabajo se enfoca en la identificación y evaluación de mecanismos de daño, gestión de corrosión, definición y seguimiento de Ventanas Operativas de Integridad (IOW), y soporte técnico a paradas de planta. Ha participado en análisis de condición, inspección basada en riesgo y articulación entre operaciones, mantenimiento e integridad mecánica para la mitigación de riesgos y la mejora de la confiabilidad. Su perfil combina conocimiento técnico, criterio ingenieril y experiencia práctica en la gestión del ciclo de vida de los activos.

Zapata Uribe, Angélica María

Ingeniera Mecánica de la Universidad Industrial de Santander, con especialización en Gerencia de Recursos Energéticos y estudiante de la Maestría en Administración de la Energía y sus Fuentes Renovables del Tecnológico de Monterrey. Cuenta con experiencia profesional en el sector de refinación como ingeniera de confiabilidad, con participación en gestión

de mantenimiento, análisis de condición de activos y uso de analítica de datos para el apoyo a la toma de decisiones técnicas en la Refinería de Barrancabermeja. Su trayectoria investigativa incluye trabajos en materiales compuestos, recubrimientos funcionales, nanotecnología y análisis de falla. Actualmente, sus intereses académicos y profesionales se orientan a la eficiencia energética, la gestión de activos físicos y la mejora de la confiabilidad operacional en entornos industriales.

Contactos

- Gonzalez Lizcano, Javier Armando
+57 3162950709
Refinería de Barrancabermeja, Colombia
- Zapata, Angelica María
+57 3107990298
Refinería de Barrancabermeja, Colombia
- Yesid Carvajal Niño
+57 3165354815
Refinería de Barrancabermeja, Colombia
Barrancabermeja, Colombia