

GESTIÓN DE INTEGRIDAD ¿QUÉ HICIMOS, ¿QUÉ ESTAMOS HACIENDO Y HACIA DÓNDE VAMOS?

Diego Sebastián López, Pan American Energy, dslopez@pan-energy.com

Rodolfo Eduardo Rodríguez, Pan American Energy, rerodriguez@pan-energy.com

Sinopsis

Pan American Energy (PAE) opera y mantiene más de 11.600 km de ductos entre oleoductos, gasoductos y acueductos en las cuencas del golfo San Jorge (**Figura 1**), Neuquina y Noroeste. Estos ductos se clasifican según su función y características en líneas de conducción, líneas de transferencia, líneas principales y ductos de venta (**Figura 2**).

Las líneas de conducción tienen bajo diámetro (3 o 4”), corta extensión (entre 300 y 1.500 m aproximadamente) y en su mayoría transportan grandes cantidades de agua. Los ductos de transferencia también transportan grandes cantidades de agua, tienen diámetros intermedios (entre 3 y 12”) y extensiones mayores (entre 2.000 y 10.000 m). Por otro lado, las líneas principales transportan fluido con bajo corte de agua y muchos de ellos son aptos para inspección instrumentada. Finalmente, los ductos de venta transportan fluido dentro de especificación.




Figura 1: Sistema de ductos de petróleo, gas y agua operados por PAE en Golfo San Jorge (Anticlinal Grande, Cerro Dragón y otros yacimientos).




Figura 2: Clasificación de ductos del sistema petrolero y agua, según el manual PIMS (Manual del sistema de gestión de integridad de ductos) de PAE [1].

La gestión de integridad de un parque de ductos tan heterogéneo tiene grandes desafíos, desde cuestiones netamente técnicas como puede ser la diversidad de mecanismos de daño, pasando por cuestiones normativas, tecnológicas e incluso de capital humano.

En PAE se desarrolló un modelo de riesgo basado en RBI que permite gestionar la integridad de todo el parque de ductos. Uno de los grandes facilitadores es la integración en línea de la base corporativa de ductos en GIS y la herramienta para la gestión de riesgo OMEGA.

La mejora continua nos ha permitido optimizar la eficiencia de nuestra gestión de integridad progresivamente, pero la relación esfuerzo/beneficio parece haber llegado a un punto límite. Por eso, **estamos preparando la operación para provocar un salto en la eficiencia de integridad basado en la innovación que nos permita migrar de modelos estáticos como los actuales a modelos dinámicos.** Para ello, actualmente estamos incorporando el uso de variables operativas en línea para calcular el riesgo utilizando condiciones de operación en lugar de parámetros de diseño que suelen adoptar valores conservativos. A su vez, estamos sensorizando ductos clave, definiendo la estrategia de gobierno de datos y capacitándonos. Para el caso particular de las líneas de conducción se está desarrollando un sistema basado en Data Analytics para identificar condiciones de sensibilidad a la falla, valiéndose de los antecedentes de daño y del historial operativo.

El plan a mediano plazo consiste en extender la interacción entre nuestras fuentes de información y medios de gestión, extender la digitalización de activos mediante el monitoreo permanente, definir ventanas de integridad e implementar algoritmos de machine learning e inteligencia artificial, entre otros.

Introducción

Podemos definir la gestión de integridad como un proceso abocado a garantizar la aptitud para el servicio de las instalaciones. Es decir, que la gestión de integridad busca maximizar la confiabilidad. Existen diversas formas de definir la confiabilidad, dependiendo del tipo de activo que se gestione o del tipo de información que se requiera. La confiabilidad de cada uno de los equipos estáticos se puede cuantificar mediante el cálculo de vida remanente. Por otro lado, para obtener un resultado global que represente la confiabilidad de un conjunto de activos podemos utilizar la definición propuesta en [2] que consiste en cuantificarla en función de la probabilidad de falla, de acuerdo con la siguiente ecuación:

$$R=1-P_f \quad (1)$$

donde R es la confiabilidad y P_f es la probabilidad de falla.

Pero, ¿a qué nos referimos cuando hablamos de falla? Para evitar ambigüedades, podemos recurrir a la definición de falla de la norma ISO 14224 [3]: **una falla es la pérdida de capacidad para desempeñarse como se requiere.** Por ejemplo, podemos hablar de falla por corrosión cuando se excede la presión segura de un defecto volumétrico según recomienda ASME B31.G [4], o de falla por fuga cuando se produce una pérdida de estanqueidad de un fluido. Nótese que el mecanismo de daño podría ser el mismo para ambos casos (ej: corrosión interna), pero el efecto, el modo de detección y la consecuencia son distintos.

La principal ventaja de la **Ecuación (1)** es que nos **permite resumir el resultado de todo el proceso de gestión de integridad en un único número.** También permite determinar la confiabilidad por grupos de activos, por yacimiento, por estrategia de operación, de mantenimiento, por antigüedad del sistema, etc. A modo de ejemplo, la **Figura 3** presenta valores de confiabilidad de algunos grupos de activos de PAE en función de su antigüedad.

La evolución de la confiabilidad en el tiempo nos permite comparar el desempeño del proceso de gestión de integridad. La mejora continua tiene un efecto positivo sobre la confiabilidad en función del tiempo, pero compite contra los efectos negativos de los mecanismos de daño dependientes del tiempo que se pueden acumular en los activos a medida que aumenta su antigüedad. A continuación, en la **Figura 4** se presenta una línea de tendencia (polinómica) de la confiabilidad estimada para una muestra de activos de PAE donde se puede observar un comportamiento como el descrito previamente.




Figura 3: Confiabilidad en función de la antigüedad promedio de los activos para distintos grupos de activos de PAE.




Figura 4: Línea de tendencia para la confiabilidad de una muestra de activos de PAE.

Otro ejemplo relevante que podemos analizar es la frecuencia de falla de UKOPA (Asociación de operadores de ductos onshore del Reino Unido) [5], donde la mejora continua prevaleció sobre

los mecanismos de daño dependientes del tiempo resultando en una reducción en la frecuencia de falla en el tiempo. Sin embargo, **pareciera que se está alcanzando un comportamiento asintótico donde la frecuencia de falla está llegando a un mínimo difícil de romper** (ver **Figura 5**). Si aplicamos la ecuación (1), esto equivale a decir que la confiabilidad está llegando a un máximo difícil de superar.




Figura 5: Evolución temporal de la frecuencia total de incidentes con pérdida de producto en compañías participantes de UKOPA [5].

Desarrollo

Creemos que, en grandes parques de activos, un factor adicional que limita la confiabilidad es la capacidad de análisis de la información. A escala mundial, estamos generando una cantidad creciente de datos, como lo muestra el ejemplo de la **Figura 6**. Se estima que solo en 2017 se generaron más datos que en los 5000 años anteriores. Sin embargo, aún no hemos explotado al máximo las capacidades que nos brindan las nuevas tecnologías de análisis y procesamiento. En la **Figura 7**, podemos observar cómo creció en el tiempo la capacidad acumulada de procesamiento de datos, producto del desarrollo de nuevas tecnologías. De hecho, ocurrió un salto en la capacidad de procesamiento alrededor del año 2010 producto del desarrollo de las tecnologías de Big Data, Analytics, Visualization, IOT (Internet de las cosas) y Smart Machine. Además, la inteligencia artificial tiene una pendiente similar a las anteriores, por lo que podría provocar un nuevo salto en la capacidad de procesamiento.




Figura 6: Volumen de datos para la economía, a partir de datos del Banco de Inglaterra [6].




Figura 7: Aumento de la capacidad acumulada de las tecnologías digitales [7].

En este contexto, para optimizar la operación y buscar un salto en la confiabilidad de los activos PAE está implementando un plan disruptivo mediante la incorporación de nuevas tecnologías

digitales. Contamos con grandes cantidades de datos asociados a la operación, el mantenimiento y la condición de nuestros activos almacenados y gestionados en distintos sistemas.

El sistema SIG PAE es el maestro oficial de datos estáticos de activos. Por eso, envía las características de los ductos y sus trazas geospaciales al software de gestión de integridad OMEGA para simplificar las tareas de actualización de información y carga de datos. La TQWeb es un sistema que recopila información de tratamiento químico incluyendo dosis recomendadas y dosificación en tiempo real mediante un cálculo basado en mediciones de volumen y en el funcionamiento de las bombas dosificadoras (ver **Figura 8**). **Estamos planificando la vinculación de la TQWeb con Omega para impactar de manera automática los efectos del tratamiento químico en el riesgo de los ductos.**




Figura 8: Gráfico de dosificación por inyección continua de inhibidor de corrosión y monitoreo de funcionamiento de la bomba dosificadora.




Figura 9: Ejemplo de determinación de MAPO por historial de operación.

El sistema Gestor de MAPO (máxima presión de operación admisible) realiza un cálculo automático de determinación, considerando la prueba hidráulica, una evaluación de aptitud para el servicio (si la hubiera) o bien el historial de operación: la máxima presión de operación a la que fue sometido el ducto, y que se mantuvo durante 4 horas continuas en el último año (ver **Figura 9**).

El sistema MID (monitoreo de integridad de ductos) integra y analiza información para valorizar el estado de condición considerando las categorías de corrosión interna, corrosión externa, procesos, riesgo, plan de integridad, sensibilidad ambiental y derrames (ver **Figura 10**). Es una herramienta que se complementa con el análisis de riesgo dado que **captura diariamente variables dinámicas** como las presiones, temperaturas, bombeos, la dosificación, el stock de químicos, entre otras, para evaluar el estado de condición de los ductos. Es decir, que el MID busca dinamizar la evaluación de condición de las cañerías. En la **Figura 11** se presenta un diagrama que resume el flujo de información actual y la interacción entre las herramientas utilizadas para la gestión de integridad.

En la actualidad **estamos desarrollando la vinculación entre el Gestor de MAPO y el SIG PAE para poder actualizar la MAPO en GIS según los criterios establecidos**. Esto impactará sobre el cálculo de riesgo de los ductos ya que utilizará el resultado de las condiciones de operación, evaluación y pruebas hidráulicas en lugar de la MAPO determinada durante la etapa de diseño.

Corrosión Interna	Peso
Eficiencia mitigación por TQ	0.25
Monitoreo de eficiencia de TQ	0.23
Plan de limpieza	0.25
Velocidad de corrosión interna	0.28
Peso corrosión interna	0.23

Corrosión Externa	Peso
Sistema de protección catódica	0.5
Velocidad de corrosión externa	0.5
Peso corrosión externa	0.14

Procesos	Peso
Presión de oleoducto	0.207
Inestabilidad de presión de oleoducto	0.207
Alarmas de presión	0.172
Marcha/parada de bomba	0.172
Temperatura de oleoducto	0.035
Caudal	0.207
Peso procesos	0.22

Riesgo Integridad	Peso
Probabilidad de falla	0.26
Consecuencia de falla	0.17
Riesgo integridad	0.57
Peso riesgo integridad	0.23

Plan Integridad	Peso
Cumplimiento de planes de inspección	1
Peso plan integridad	0.08

Sensibilidad Ambiental	Peso
Sensibilidad Ambiental	1
Peso sensibilidad ambiental	0.04

Claim file	Peso
Claim file	1
Total claim file	0.05

Figura 10: Pesos de los parámetros que utiliza el MID para el monitoreo del estado de condición de ductos.

Por otro lado, PAE ha desarrollado una serie de tableros de PBI (Power BI) de aplicación específica para el seguimiento de indicadores de confiabilidad en líneas de conducción. Para ello, se vale de algunos de los sistemas mencionados previamente y también de la base de datos de fallas. La **Figura 12** presenta su diagrama de flujo de información y algunos gráficos de visualización. Es importante mencionar que los gráficos respetan la estructura jerárquica de propuesta por la ISO 14224 [8] para la clasificación de fallas en el Upstream.




Figura 11: Diagrama de flujo de información e interacción entre sistemas para gestión de integridad. La flecha marrón se corresponde a una vinculación en desarrollo.





Figura 12: Diagrama de flujo de información e interacción entre sistemas para cálculo de indicadores de confiabilidad en líneas de conducción, basados en ISO 14224.




Figura 13: Diagrama futuro de flujo de información de integridad.

Actualmente, PAE está desarrollando un DWH (Data Warehouse) que integre la información de integridad de forma estructurada, permitiendo analizarla mediante procesos de Data Analytics. Particularmente, integramos historiales de Presión, temperatura y producción (Oil, Gas, Agua) de los pozos; historial de inyección de químicos, monitoreo de variables químicas, datos de fallas, down time, características de los ductos, costos de tratamientos químicos, de inspecciones y de reparaciones, entre otros. En la **Figura 13** se presenta el diagrama de flujo de información proyectado.

Un DWH es un sistema que agrega datos de diferentes fuentes a través de un proceso llamado ETL (extracción, transformación y carga) resultando en una base de datos estructurada, central y consistente. Se caracteriza por la calidad de sus datos, su escalabilidad y su capacidad de integración con otras herramientas. Se podría decir que es una de las alternativas necesarias, pero no suficientes para la gestión de datos ya que su objetivo es brindar soporte para el análisis de datos, la minería de datos, la inteligencia artificial (IA) y machine learning. Una aclaración importante en toda estrategia de modernización mediante uso de datos es que la confiabilidad de cualquier algoritmo es altamente dependiente de la calidad de los datos de entrada.

Machine learning o aprendizaje automático es una rama de IA que aprende de los datos y continuamente mejora su desempeño sin intervención humana. Existen modelos supervisados y

sin supervisión. Los primeros requieren datos correspondientes a especímenes con distintas condiciones de salud, para aprender de ellos las condiciones asociadas a cada estado. En otras palabras, estos modelos cuentan con una fase de entrenamiento, en la cual los modelos de clasificación para el diagnóstico de fallas aprenden las relaciones entre los datos de monitoreo de condición y la condición de salud correspondiente. Una práctica habitual consiste en utilizar aleatoriamente el 70% de los datos para el entrenamiento del modelo y el 30% restante para la validación. Los modelos sin supervisión utilizan la totalidad del conjunto de datos y los clasifican para identificar las condiciones normales y las condiciones que se desvían, anticipando las fallas. Estos modelos se basan en la idea de que distintos grupos corresponden a distintas condiciones del sistema. En cualquiera de los casos, no todas las condiciones de falla se conocen de manera anticipada, lo cual limita el grado de confiabilidad de los modelos.

La tecnología de machine learning podría optimizar procesos de confiabilidad/integridad mediante la simplificación de modelos. Por ejemplo, el método de filtrado mRMR (mínima redundancia, máxima relevancia) podría identificar las variables de riesgo más relevantes y penalizar las redundantes [9]. Tendría un gran impacto y provocaría un cambio de paradigma en los análisis de riesgo, dado que ponderan el efecto de muchas variables. La **Tabla 1** resume las variables que utiliza el modelo de análisis de riesgo de PAE [1]. Como se puede apreciar, se usa un total de 40 variables para la determinación del nivel de riesgo. Algunos de esos datos se utilizan más de una vez, en función de la amenaza a evaluar, por lo que el algoritmo de riesgo realiza 62 consultas sobre esas 40 variables.

Tabla 1: Variables utilizadas en el modelo de riesgo de PAE [1].

Corrosión Interna	Corrosión externa	Daño por terceros	Fabricación y Construcción	Causas Naturales	Consecuencias
Diámetro	Diámetro	Diámetro	Espesor nominal	Espesor nominal	Diámetro
Espesor nominal	Espesor nominal	Espesor nominal	Antigüedad	Antigüedad	Presión
Espesor mínimo requerido	Espesor mínimo requerido	Clase de trazado	Presión de Prueba hidráulica	Unidad de Gestion	Temperatura
Antigüedad	Antigüedad	Profundidad de tapada	Clasificación de ducto		Tipo de suelo
Presión	Presión	Frecuencia de patrullaje			Unidad de Gestión
Temperatura	Temperatura	Loza de H°A°			Clasificación de ducto
Clase de trazado	Clase de trazado	Señalización			Distrito
Material	Material				Fluido
Puntos de inyección	Puntos de inyección				Disposición (enterrado/aéreo)
Efectividad inspección	Efectividad inspección				Caudal
Fecha última inspección	Fecha última inspección				Sistemas de detección/control
Piernas muertas	Tipo de suelo				Progresiva
Puntos de monitoreo Int.	Resistividad del suelo				Dentro/Fuera del yacimiento
Anomalías ILI Int.	Potencial de polarización				Sensibilidad ambiental
Cateos Ver. Int.	Tipo de revestimiento				
	Puntos de monitoreo Ext.				
	Anomalías ILI Ext.				
	Indicaciones DCVG				
	Cateos Ver. Ext.				

También se podría analizar la dependencia entre variables utilizando modelos de redes bayesianas (BN). Consisten en herramientas que observan distribuciones multivariadas basadas en el cálculo de la probabilidad de inferencia bayesiana utilizando un modelo gráfico acíclico para analizar las dependencias condicionales entre variables. Los gráficos acíclicos son los mapas entre observaciones inciertas y conclusiones ciertas que identifican la relación causa-efecto entre variables. El modelo se construye en tres pasos: determinando las dependencias entre las variables, prediciendo la distribución de probabilidad previa y calculando la distribución de probabilidad condicional [9].

Otra potencialidad del machine learning podría ser la implementación de métodos para clasificación aplicado específicamente a las fallas. Estos algoritmos, podrían analizar datos operativos y en lugar de utilizar una clasificación binaria falla/no falla, desarrollarían un sistema de clases múltiples que no se superponen [9]. Podrían aplicarse para la clasificación de fallas en líneas de conducción, de manera que se puedan identificar clases de mecanismos de daño activos (ej. corrosión por bacterias, por O_2 , CO_2 , H_2S , etc.).

Las redes neuronales artificiales (ANN) son algoritmos informáticos de aprendizaje profundo que imitan los principios de funcionamiento del cerebro humano. Consisten en 3 conjuntos de elementos de procesamiento llamados neuronas que tienen sesgos y ponderación. Un conjunto de entrada, un conjunto oculto y un conjunto de salida. En el modelo multicapa perceptrón (MLP) cada neurona cuenta con una función de activación que funciona como una puerta matemática entre la neurona de entrada y la neurona de salida. Como último paso, el modelo aprende el patrón de datos existente utilizando el algoritmo de retropropagación [9]. Los pesos y sesgos de la red son modificados hasta que se alcance una precisión apropiada. Podrían aplicarse este tipo de modelos para el aprendizaje de las condiciones de daño en líneas de conducción: dependiendo de la función de activación, algunas neuronas aprenderían el comportamiento de los ductos que fallan de manera prematura, mientras otras aprenderían el comportamiento de los ductos que fallan a edades intermedias y otras aprenderían de ductos que no han fallado. En suma, el aprendizaje permitiría realizar un diagnóstico de los patrones de falla y un pronóstico de las fallas futuras.

Un caso de éxito en la aplicación de modelos de machine learning para desarrollo de estrategias de mantenimiento predictivo basado en datos fue implementado sobre un sistema de distribución de gas en el sudeste de Alemania. Esos sistemas de activos están enterrados bajo tierra y el estado actual de la tubería, así como las propiedades del suelo circundante son inciertos y no existen modelos de deterioro adecuados. Por lo tanto, se desarrolló un modelo basado en el método de optimización “gradient boosting” de la librería Python “scikit-learn”. El proceso consiste en generar un vector x de características para cada tramo S de ducto, conteniendo su longitud, antigüedad, diámetro, tipo de material, todos los defectos ocurridos en el pasado e incluso datos geoespaciales. El vector x no solamente depende del tramo de cañería, sino que también es una función del tiempo (año y), es decir $x(S,y)$. Luego, el objetivo consiste en determinar la probabilidad de desarrollo de un defecto para los años siguientes $y+1$, $y+2$, etc. En este caso particular, el conjunto de datos de aprendizaje y el conjunto de datos de validación no fueron seleccionados aleatoriamente, sino que fueron separados en función del año calendario. Los resultados del modelo lograron una confiabilidad tal que **si se reemplazaran el 1% de los tramos de ductos más críticos identificados, se hubiera alcanzado una reducción del 25% en la cantidad de fallas**. Por otro lado, se realizó un análisis de sensibilidad que permitió identificar la influencia que tiene cada característica en el modelo de predicción (ver **Figura 12**) [10].




Figura 12: Análisis de sensibilidad obtenido para los parámetros utilizados en el modelo de predicción de fallas en un sistema de distribución de gas al sureste de Alemania [10].

En términos generales, **el procesamiento de datos por lotes fuera de línea tiene como objetivo descubrir información valiosa a partir de datos acumulados**, ya que se centra principalmente en la precisión y exhaustividad del análisis en lugar de centrarse en la detección y el diagnóstico de fallas en tiempo real. Por otro lado, **el procesamiento de transmisión en tiempo real es necesario en condiciones operativas variables y complejas para realizar un diagnóstico en tiempo real y garantizar un mantenimiento oportuno** [11].

PAE tiene en marcha proyectos de procesamiento fuera de línea y también en tiempo real. Por un lado, tenemos en marcha 2 protocolos de prueba con tecnologías de IA supervisada. Uno de ellos asociado a la toma de decisiones basada en el análisis de datos de inspección interna instrumentada (ILI) que permite determinar tasas de corrosión y optimizar cateos basándose en una base de datos históricas de inspecciones. El otro está asociado a la identificación de correlaciones entre las condiciones operativas de líneas de conducción y sus fallas.

A su vez, estamos digitalizando activos clave mediante un plan que abarca el monitoreo permanente online de:

- Polarización catódica
- Variables eléctricas de rectificadores de protección catódica
- Espesores de ductos
- Corrosión interna
- Espesores de accesorios y tramos para evaluar procesos de desgaste por erosión
- Vibraciones

Las variables que tendremos monitoreadas ingresarán al DWH y podrán ser visualizadas a través del MID (Sistema de monitoreo de integridad de ductos). Además, formaran parte de un sistema de alarmas que dará un aviso por mail y/o por SAP cuando se detecta un desvío respecto a una condición previamente establecida (ej.: una tasa de corrosión máxima, un potencial de polarización mínimo, un espesor mínimo, etc.). Es decir, que esta tecnología nos va a permitir establecer ventanas operativas de integridad (IOW).

Conclusiones

PAE está transitando un camino de modernización basado en las nuevas tecnologías de procesamiento de datos y digitalización. El objetivo es optimizar la operación y particularmente alcanzar un salto en la confiabilidad, es decir una reducción en la tasa de falla de los activos. La integración de los sistemas de información simplifica los procesos de cálculo y dinamiza los

resultados. Particularmente, nos permitirá conocer la dinámica del riesgo de los activos. El desarrollo del DWH nos brindará las bases para integrar la información y los protocolos de prueba de IA son los primeros pasos para seleccionar los modelos que mejores predicciones nos otorguen. Por último, el monitoreo en tiempo real de variables de integridad nos permitirá tomar decisiones de manera rápida.

Bibliografía

- [1] Pipeline Integrity Management System (PIMS), PAE-CTO-MN-006 (2021).
- [2] M. Nessim, W. Zhou, Guidelines for reliability based design and assessment of onshore natural gas pipelines, GRI-04/0229 (2005).
- [3] The International Organization for Standardization, Petroleum, petrochemical and natural gas industries – Collection and exchange of reliability and maintenance data for equipment, ISO 14224:2016 (2016).
- [4] The American Society of Mechanical Engineers, Manual for determining the remaining strength of corroded pipelines, ASME B31.G-2023 (2023).
- [5] G. D. Goodfellow, J. V. Haswell, C. J. Lyons, UKOPA Pipeline Product Loss Incidents and Faults Report (1962 – 2020), UKOPA/RP/22/001 (2022).
- [6] R. Ferrer, La revolución de los datos: competencia y uso responsable, <https://www.caixabankresearch.com/es/economia-y-mercados/actividad-y-crecimiento/revolucion-datos-competencia-y-uso-responsable> (2019).
- [7] M. Spelman, G. Davidson, B. Weinelt, L. Joseph, R. Siyam, J. E. Lichtenstein, R. Bartels, D. Cameron, W. Popp, A. Shah, F. Keppler, S. Shroff, World Economic Forum Digital Transformation Initiative: mining and Metals Industry (2017).
- [8] The International Organization for Standardization, ISO 14224: Petroleum, petrochemical and natural gas industries – Collection and exchange of reliability and maintenance data for equipment (2016).
- [9] O. Surucu, S. A. Gadsden, J. Yawney, Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances, Expert Systems With Applications (2023).
- [10] W. Betza, I. Papaioannou, T. Zehc, D. Hespina, T. Krauss, D. Straub, Data-Driven Predictive Maintenance for Gas Distribution Networks, ASCE-ASME J. Risk Uncertainty Eng. Syst (2022).
- [11] F. Calabrese, A. Regattieri, M. Bortolini, F. G. Galizia, Data-Driven Fault Detection and Diagnosis: Challenges and Opportunities in Real-World Scenarios, MDPI(2022).

Cv Diego Sebastián López

Título y lugar de estudio: Ingeniero en Materiales – Universidad Nacional de Mar del Plata

Trayectoria: 8 años de experiencia en el campo de integridad de activos en PAE (2024), en Camuzzi Gas Pampeana y Camuzzi Gas del Sur (2018-2023) y en Grupo GTL (2017). Experiencia en el desarrollo de planes de inspección de recipientes a presión, análisis de riesgo y gestión de integridad del sistema de aproximadamente 8000 km de gasoductos.

Cargo actual en la empresa: Ingeniero de integridad corporativa de ductos en PAE. Responsable del análisis de estrategias para la gestión de integridad en líneas de conducción y de la

implementación de estrategias de modernización mediante el monitoreo remoto de espesores en activos clave.

Cv Rodolfo Eduardo Rodriguez

Título y lugar de estudio: Ingeniero Electrónico – Universidad Nacional de la Patagonia San Juan Bosco.

Trayectoria: Inspector en recipientes a presión API 510, Inspector en protección catódica NACE CP1/CP2 e Inspector en recubrimientos NACE CIP. Cuenta con 16 de años de experiencia en Integridad de instalaciones de superficie en PAE como Ing. de Integridad en plantas de gas (2007-2012), Coordinador de Corrosión (2012-2014) y Líder en Ingeniería de Integridad en la UGGSJ (2014-2020)

Cargo actual en la empresa: Líder Integridad de Ductos para el Upstream de PAE.