

Analítica avanzada para detección de anomalías

Autor: Alan Cornejo – Esteban Marascio

Empresa: Transportadora de Gas del Norte S.A. (TGN)

Email: alan.cornejo@tgn.com.ar , esteban.marascio@tgn.com.ar

Sinopsis

Este proyecto presenta un caso de estudio aplicado a un operador de líneas de transmisión de gas, con el objetivo de aumentar la confiabilidad en la detección y clasificación de defectos en ductos mediante inteligencia artificial. La solución desarrollada se integra como una herramienta complementaria al sistema de inspección ILI (Inline Inspection), permitiendo validar y enriquecer los reportes generados por el proveedor de servicios ILI. El proceso comienza con la captura automatizada de imágenes de inspección, utilizando una aplicación de escritorio que registra pantallas a intervalos definidos. Estas imágenes se almacenan en una librería estructurada que sirve como base para el entrenamiento de modelos de IA. Para la detección de defectos no reportados, se aplica el algoritmo YOLO (You Only Look Once), que permite identificar anomalías en las imágenes con alta velocidad y precisión. Luego, los defectos detectados son dimensionados mediante un modelo de regresión basado en redes neuronales convolucionales (CNN), que estima parámetros como largo, ancho y profundidad, eliminando la subjetividad del análisis manual. Una vez dimensionados, los defectos se clasifican automáticamente según el estándar del Pipeline Operators Forum (POF), utilizando una herramienta que genera visualizaciones gráficas y reportes (Pipe tally) para todos los defectos detectados. Esta clasificación permite al operador de la línea de transmisión contrastar los resultados obtenidos por IA con los datos originales del pipe tally, identificando posibles omisiones o inconsistencias en el informe del proveedor ILI. El caso de estudio demuestra cómo esta herramienta puede integrarse en el flujo de trabajo del operador, proporcionando una segunda capa de validación técnica y facilitando la toma de decisiones en mantenimiento y gestión de integridad. La aplicación de modelos de inteligencia artificial en este contexto permite mejorar la eficiencia operativa, reducir el riesgo asociado a errores humanos, y optimizar los recursos destinados a la evaluación de integridad. Además, ofrece escalabilidad, adaptabilidad a distintos entornos operativos y la posibilidad de incorporar datos históricos y de campo para mejorar continuamente su desempeño. Este enfoque representa un avance significativo en la automatización del análisis ILI, con potencial para transformar los procesos de inspección en la industria del transporte de gas, promoviendo una gestión más proactiva y confiable de la infraestructura.

Introducción

Transportadora Gas del Norte S.A. (TGN) opera y mantiene la red de gasoductos más extensa de Argentina, transportando más del 40% del gas del país a través de una red de más 11.300 km de diversos diámetros. La Fisuración por Corrosión Bajo Tensión (SCC) axial es una amenaza de integridad confirmada que se gestiona principalmente mediante una combinación de inspección interna y evaluación directa.



En la industria del transporte de gas, garantizar la integridad de los ductos depende fundamentalmente de la información recabada por las herramientas de inspección interna (ILI). Típicamente, los resultados de estas inspecciones se entregan consolidados en dos formatos: un listado secuencial de eventos detectados a lo largo de la línea y un conjunto de registros de imágenes derivadas de los sensores de la herramienta (como perfiles de magnetización y C-Scan).

El procesamiento de estos entregables impone un desafío analítico monumental para los equipos de integridad. En primer lugar, exige una evaluación que debe ser simultáneamente independiente e integrada para ambos tipos de archivos. En segundo lugar, el volumen masivo de datos generados en cada corrida suele estar encapsulado en formatos propietarios y cerrados. A esta complejidad se suma una restricción adicional: las señales ILI se reciben con un preprocesamiento hermético realizado por el contratista, el cual no admite modificaciones.

Todo este panorama propicia la aparición del denominado 'gap de detección'. Al depender exclusivamente del análisis visual humano para escrutar grandes volúmenes de datos inalterables y altamente repetitivos, se introduce inevitablemente un sesgo por fatiga visual y cognitiva, elevando la tasa de error inherente a la evaluación.

Para comprender la verdadera magnitud de este "gap de detección", es fundamental analizar las limitaciones estadísticas inherentes a las propias herramientas ILI. De acuerdo con las especificaciones técnicas de los proveedores, estos equipos operan típicamente con una probabilidad de detección del 90%. No obstante, identificar la anomalía es solo la primera etapa del análisis; la capacidad intrínseca de la herramienta para dimensionar correctamente dicho defecto presenta una confiabilidad del 80%. En consecuencia, al evaluar el desempeño global del sistema, la tasa de éxito real conjunta —es decir, la certeza de detectar y a su vez dimensionar con precisión una anomalía— desciende significativamente hasta un 72%. Este margen de incertidumbre acumulada subraya la vulnerabilidad del proceso tradicional y justifica de manera concluyente la necesidad de implementar sistemas de validación independientes basados en analítica avanzada.

Para sortear este obstáculo, la integración de metodologías de Machine Learning y Deep Learning surge como una alternativa robusta. A diferencia de los métodos algorítmicos tradicionales y estáticos, estas redes "aprenden" de su entorno, detectando patrones complejos al evaluar miles de decisiones a nivel de píxel para comprender el panorama general. El presente trabajo detalla el diseño, entrenamiento y despliegue de un pipeline analítico secuencial que utiliza modelos de detección de imagen y redes neuronales para automatizar la extracción de datos, la detección de corrosión, su dimensionamiento y su categorización técnica, dotando al operador de una herramienta de validación independiente.

Desarrollo

El proceso de analítica avanzada se estructuró en cinco grandes etapas: captura de datos, extracción de texto (OCR), detección de objetos, dimensionamiento y clasificación.




Figura 2 - Pipeline aplicado

1. Captura de Datos y Extracción de Texto (OCR)

Dado que las señales ILI se visualizan en software propietario, el primer paso consistió en desarrollar una herramienta de captura automatizada que registra la pantalla fraccionando tramos de 100 km en segmentos manejables de 12 metros. Para correlacionar cada imagen capturada con su ubicación física exacta en el ducto, se implementó un proceso de Reconocimiento Óptico de Caracteres (OCR) utilizando el motor Tesseract.

El Reconocimiento Óptico de Caracteres (OCR, por sus siglas en inglés) es una tecnología de visión por computadora diseñada para identificar y extraer texto contenido en imágenes o documentos escaneados, transformándolo en secuencias de caracteres codificados y legibles por máquina. Para este proyecto, se seleccionó Tesseract, uno de los motores OCR de código abierto más potentes y robustos de la actualidad.

La incorporación de Tesseract en este pipeline analítico cumple un rol crítico: actúa como el puente necesario para 'traducir' la información visual (píxeles) que arroja el software propietario de la herramienta ILI en metadatos estructurados (texto y números). Sin embargo, los motores OCR son altamente sensibles a la calidad de la entrada. Dado que las capturas de pantalla de las inspecciones suelen incluir fondos con gradientes de color, ruido y tipografías superpuestas, el motor Tesseract no puede operar de manera óptima sobre la imagen cruda. Por este motivo, su implementación requiere ineludiblemente una etapa de preprocesamiento iterativo —que incluye técnicas de binarización, umbralización y filtrado de contraste— para aislar los caracteres y garantizar que el algoritmo pueda leer automáticamente las coordenadas del odómetro con una alta fiabilidad.




Figura 3 - Proceso de detección de texto

2. Detección de Defectos mediante YOLO

Para la etapa de identificación espacial de las anomalías dentro de las imágenes provenientes de las herramientas de inspección interna, se implementó el modelo de detección de objetos YOLO (You Only Look Once). A diferencia de los clasificadores tradicionales que aplican ventanas deslizantes a lo largo de la imagen, YOLO procesa la imagen completa en una única evaluación de la red neuronal. El algoritmo divide la imagen de entrada en una cuadrícula de $N \times N$. Cada una de estas celdas es responsable de predecir simultáneamente recuadros delimitadores (bounding boxes), niveles de confianza de que exista un objeto en dicho recuadro y un mapa de probabilidad de clases.




Figura 4 - Funcionamiento de modelo YOLO

En el contexto del presente proyecto, El objetivo principal para YOLO fue enseñarle a ignorar el "ruido" de fondo inherente a las señales ILI (como variaciones de espesor de pared, soldaduras o cambios en magnetización no atribuibles a anomalías) y trazar una caja delimitadora exclusivamente donde el modelo reconoce patrones cromáticos y morfológicos que se asemejan a la corrosión. El gran valor agregado de este enfoque radica en que el modelo no se limita a clasificar si la imagen contiene o no un defecto, sino que arroja las coordenadas espaciales exactas del mismo. Esta localización precisa es el insumo indispensable para la posterior etapa de recorte y dimensionamiento.

La precisión algorítmica de YOLO está directamente subordinada a la calidad y robustez de su fase de entrenamiento, la cual se estructuró en las siguientes etapas críticas:

- **Etiquetado de Datos (Labeling):** Constituye la fase fundamental y más demandante en términos de tiempo. Consiste en enseñar al modelo a identificar y ubicar lo que debe buscar mediante la creación de la "verdad fundamental" (ground truth). Para llevar a cabo esta tarea se trazaron manualmente cajas delimitadoras sobre cientos de anomalías reales para generar el conjunto de datos de entrenamiento




Figura 5 - Detección de imágenes

- Volumen y Calidad del Dataset:** Se determinó que, para alcanzar un mínimo funcional que permita a la red neuronal superar el sobreajuste (overfitting) y arrojar métricas de prueba confiables, se requiere un piso de entre 300 a 500 imágenes etiquetadas. Sin embargo, para garantizar una robustez que permita al modelo generalizar y operar con alta precisión en escenarios reales con diversas morfologías de corrosión, el objetivo óptimo escaló a un volumen de entre 1.500 y más de 3.000 imágenes.
- Aumentación de Datos (Data Augmentation):** Para maximizar la exposición del modelo a diferentes escenarios sin requerir nuevas inspecciones físicas, se aplicaron transformaciones geométricas y de color aleatorias (tales como rotaciones, fluctuaciones de brillo, zoom y rotaciones). Esto generó "nuevos ejemplos" artificiales, incrementando drásticamente la variabilidad del conjunto de entrenamiento.
- Transferencia de Aprendizaje (Transfer Learning):** En lugar de iniciar el entrenamiento desde cero, los pesos iniciales de la red se inicializaron cargando un modelo YOLO pre-entrenado. Este proceso iterativo acelera significativamente la convergencia del modelo, permitiendo que la red utilice el conocimiento previo de formas y bordes básicos, enfocando los recursos computacionales en aprender las características específicas de las anomalías.
- Iteración y Minimización de la Función de Pérdida (Loss):** Durante la fase de aprendizaje, el modelo evalúa el conjunto de datos completo a lo largo de múltiples ciclos, denominados "épocas". En cada iteración, el algoritmo compara sus predicciones de bounding boxes contra el ground truth establecido en el etiquetado. El objetivo matemático del entrenamiento es minimizar el error o función de pérdida (loss), ajustando internamente los pesos sinápticos de la red para que sus predicciones sean cada vez más exactas frente a imágenes que nunca ha procesado previamente.




Figura 6 – Delimitado de cajas

Para poder definir si el modelo YOLO trabaja de forma correcta se deben analizar en profundidad sus métricas, para evaluar el desempeño las métricas de estudio son:

- **Precisión:** Mide la exactitud de las predicciones positivas realizadas por el modelo. En términos prácticos, responde a la pregunta: De todas las indicaciones que YOLO detectó y encerró en un recuadro (bounding box) afirmando que son corrosión, ¿cuántas eran realmente defectos verdaderos?

$$Precisión = \frac{Verdaderos\ positivos}{Verdaderos\ positivos + Falsos\ positivos}$$

Un valor más cercano a 1 significa que el modelo no indicó falsas alarmas.

- **Recall** (sensibilidad): Mide la capacidad del modelo para localizar todos los objetos reales presentes en la imagen. Responde a la pregunta: De todas las anomalías por corrosión que realmente existen en el ducto (ground truth), ¿qué porcentaje logró encontrar el algoritmo?

$$Recall = \frac{Verdaderos\ positivos}{Verdaderos\ positivos + Falsos\ negativos}$$

Un valor más cercano a 1 significa que el modelo no omitió ningún defecto real.

- **mAP@50** (Mean Average Precision at IoU 0.50): Evalúa de forma simultánea qué tan bien clasifica el modelo (combinando Precision y Recall) y qué tan precisa es su localización espacial. Para esto, introduce el concepto de IoU (Intersection over Union), que mide qué tanto se superpone el área del recuadro predicho por YOLO con el área del recuadro dibujado manualmente por el especialista durante el etiquetado.

3. Dimensionamiento mediante Redes Neuronales Convolucionales (CNN-R)

Una vez que YOLO aísla la región de interés (el defecto individualizado por recortes), es necesario determinar sus medidas geométricas. Para esto se desarrolló un modelo de regresión basado en una Red Neuronal Convolucional (CNN).

Las capas convolucionales actúan como filtros que extraen características espaciales de la imagen (bordes, gradientes térmicos) y las capas de agrupación (pooling) reducen la dimensionalidad. El modelo fue entrenado para correlacionar la intensidad de la señal magnética (representada mediante un mapa de colores) con la profundidad física del defecto reportada en campo.




Figura 7 - Proceso de dimensionamiento

El entrenamiento buscó minimizar la función de pérdida (loss) entre el valor real y la profundidad predicha, logrando un acierto del 81% dentro de los márgenes de tolerancia de la industria.




Figura 8 - Comparación de resultados dimensionales

4. Clasificación, Generación de Pipe Tally y Validación

Con las dimensiones ya calculadas por la red neuronal regresora, es decir, el largo, el ancho y la profundidad estimada del defecto, el último paso del pipeline es la categorización automática de cada indicación. Para

garantizar la estandarización del diagnóstico, el sistema clasifica las anomalías estrictamente bajo las normativas internacionales definidas por el Pipeline Operators Forum (POF).

Para determinar a qué categoría morfológica pertenece cada defecto, el sistema no evalúa las dimensiones de forma aislada, sino que analiza sus proporciones geométricas en relación con el espesor nominal de la pared de la cañería (representado como el parámetro "A"). El algoritmo calcula automáticamente dos relaciones adimensionales para cada hallazgo: la relación Largo/A (mapeada en el eje de las abscisas) y la relación Ancho/A (mapeada en el eje de las ordenadas). Dependiendo de la región matemática en la que intersecten estas coordenadas dentro del gráfico de clasificación, el modelo asigna el defecto a una de las siguientes tipologías:

- **Pitting (Picaduras):** Corrosión localizada donde las dimensiones de largo y ancho son reducidas en proporción al espesor.
- **General (Patch):** Pérdida de material extendida, donde tanto el largo como el ancho superan los umbrales de la corrosión localizada.
- **Axial grooving (Ranurado axial):** Pérdida de metal alargada y orientada paralelamente al eje longitudinal del ducto.
- **Circumferential grooving / slotting (Ranurado circunferencial):** Defectos alargados orientados a lo largo de la circunferencia del caño.




Figura 9 - Clasificación de anomalías

Una vez clasificada la totalidad de las indicaciones detectadas, la información se consolida y se exporta de manera automatizada en un formato estructurado tipo "Pipe tally". Este registro tabular es el entregable final que habilita la fase de validación cruzada. En esta instancia, los hallazgos generados por el modelo de Inteligencia Artificial de la operadora se contrastan de forma directa y rigurosa contra el listado de defectos

provisto por el contratista ILI.

Al contrastar la salida de este proceso con los datos de la inspección interna se generan métricas de desempeño las cuales son utilizadas para retroalimentar los modelos y generar mejores resultados.

Los resultados obtenidos en los casos de prueba demostraron el alto valor agregado de la herramienta analítica. La IA evidenció la capacidad de detectar e individualizar anomalías concurrentes, adyacentes o enmascaradas que el reporte original del proveedor había omitido o subclasificado (frecuentemente por agrupar múltiples defectos en uno solo de manera conservadora). A modo empírico, en la evaluación de un tramo específico, el modelo propio de TGN logró detectar e individualizar 30 anomalías, frente a las 29 reportadas por la empresa de inspección. Esta capacidad de discriminación superior ratifica que el uso de IA como segunda capa de control no solo mitiga el error humano y la incertidumbre del proveedor, sino que incrementa significativamente la resolución y confiabilidad del diagnóstico de integridad estructural de la línea.

Conclusiones

El objetivo principal de este proyecto fue la generación de una solución que nos permita tener un resultado de una calidad similar a la tarea de detección y delimitación de anomalías por parte del personal de evaluación. Lo que se busca con esta herramienta es generar una etapa de control la cual permita de antemano conocer las anomalías presentes a lo largo de la cañería antes de realizar las evaluaciones de campo.

El desarrollo e implementación de este pipeline analítico corrobora que la inteligencia artificial es una solución madura y escalable para la gestión de integridad de ductos. El modelo YOLO demostró una excepcional capacidad para discriminar el ruido de fondo y detectar anomalías de corrosión, mientras que las arquitecturas CNN permitieron dimensionar probabilísticamente los defectos basándose en la asimilación del mapa de colores de las señales de inspección.

El flujo de trabajo iterativo es fundamental; la mejora continua del modelo exige alimentación constante con datos de campo verificados (excavaciones) para refinar los pesos neuronales y reducir la brecha de error empírico.

Como pasos futuros de productización, se prevé la migración íntegra del pipeline a un entorno de producción, lo que unificará el almacenamiento, el análisis y la ejecución automática en la nube. Asimismo, la metodología establecida sienta las bases metodológicas para expandir el entrenamiento hacia la detección de tipos de anomalías más complejas, como fisuras y abolladuras, maximizando la confiabilidad del sistema de transporte de gas.

BIBLIOGRAFÍA

1. API STD 1163: In-line Inspection Systems Qualification

BREVE CV

Alan Cornejo

Ingeniero Mecánico, graduado de la Universidad Tecnológica Nacional (UTN FRBA), con más de 11 años de experiencia en la industria del petróleo y gas. Desde 2015, me he dedicado a tareas relacionadas con la gestión de inspecciones internas, la definición de verificaciones en campo, el análisis de aptitud para el servicio y la implementación de medidas de mitigación.

Esteban Marascio

Ingeniero Químico especializado en integridad y corrosión con vasta experiencia en la operación de gasoductos troncales. Posee certificaciones NACE/AMPP CP2 y CIP 1, complementadas con habilidades en Python, Power BI y Machine Learning para la optimización de procesos. Su formación en la Universidad Nacional de Mar del Plata se suma a un nivel de inglés B2 First y total disponibilidad para viajar. Finalmente, cuenta con experiencia previa en análisis de riesgo API 580/581 y ejecución de ensayos no destructivos.