



Inteligencia Artificial en el análisis automático de imágenes aplicado a la inspección de líneas eléctricas aéreas y estaciones transformadoras

El uso de inteligencia artificial en el análisis automático de imágenes permite optimizar la inspección de líneas aéreas y estaciones transformadoras, reduciendo fallas, tiempos de respuesta y riesgos operativos.



Por **Martin Alejandro Themtham, Francisco Manuel Colombo, Miguel Moreno** (Pan American Energy)

*Este trabajo fue seleccionado en las
3ª Jornadas de Revolución Digital para Petróleo y Gas.*

Planteo del problema

Pan American Energy (PAE) presenta 4.600 km de líneas eléctricas de transmisión y distribución (T&D), en diversos niveles de tensión, siendo los principales 132 kV; 33 kV; 13,2 kV, y exhibe una continua expansión de su red eléctrica. Nuevos tendidos de electrificación en unidades de gestión (UG) como Neuquén (NQN) y Golfo San Jorge (GSJ) incrementará sostenidamente la cantidad de kilómetros a monitorear. Una red de estas dimensiones requiere de una estrecha vigilancia y una adecuada gestión de mantenimiento para garantizar su funcionamiento, su confiabilidad y disponibilidad. Aquí el reto, poder gestionar de manera acorde el mantenimiento de tal infraestructura a fin de evitar fallos y averías en el suministro eléctrico, interrupciones del servicio, pérdida de confiabilidad, impacto ambiental (contaminación por ciertas sustancias que equipos eléctricos dañados puedan liberar al medio ambiente), riesgos de seguridad (incendios, accidentes) e impactos en la infraestructura ya sea por degradaciones aceleradas, corrosión y/o daños estructurales que repercutan directamente en gastos operativos, en costos elevados de reparaciones no planificadas o por la detección tardía de problemas, como así también las interrupciones del suministro eléctrico que tengan consecuencia directa en las pérdidas de producción localizadas y no localizadas.

Para mitigar estos problemas, PAE planifica y ejecuta planes de inspección y mantenimiento regulares mediante el uso de técnicas predictivas y preventivas. Aplica, a una frecuencia fija recorridos sobre las líneas eléctricas aéreas y estaciones transformadoras, dicha inspección se efectúa tanto con patrullas a pie, como así también con vehículos aéreos no tripulados (VANT) y el uso de cámaras acústicas, termográficas y ultravioletas (UV). En dichas inspecciones se encuentran una gran cantidad de desvíos que son catalogados como fallas potenciales y luego son informados al área ejecutante de mantenimiento correctivo, con un nivel de criticidad asignado a dicho desvío (según el grado de avance de la falla y su impacto), a fin de corregir el hallazgo. Así mismo, las inspecciones sirven como soporte al área ejecutante para planificar con anticipación y programar los recursos necesarios (materiales y cuadrillas).

Conforme a los recursos que actualmente dispone PAE para realizar estas inspecciones, solo se logra cubrir 1.200 km de líneas eléctricas aéreas y alrededor de 50 estaciones transformadoras, todo en el plazo de 1 año, dejando así, una gran cantidad de activos sin inspeccionar.

Conjuntamente, la información generada bajo este esquema no es factible cumplir con el 100% del análisis en tiempo. Mes a mes se genera un backlog de imágenes pendientes de procesar, aproximadamente, solo se logra examinar el 10% de todo el volumen de información.

Hay que destacar que en promedio se capturan entre 3.000 a 5.000 fotos diarias, las cuales que son emitidas entre las patrullas a pie y cuadrillas de vuelos con VANT. Este gran volumen de imágenes debe ser correctamente clasificado, separados por etapa de vuelo, generando los logs de vuelo correspondientes, analizados los componentes de cada imagen en detalle, visualizando los desvíos que pueden encontrarse, etiquetar las imágenes y

asignarle una prioridad de acuerdo al nivel de degradación del elemento o grado de avance que tiene la falla potencial dentro de la curva P-F, generar un informe por cada anomalía o activo inspeccionado, matchear el impacto que puede generar la falla funcional, cargar la información en nuestro sistema computarizado de gestión de mantenimiento (CMMS), y, mediante un aviso en SAP notificar al área ejecutante.

Por último, dadas las condiciones climáticas de la zona, las cuales muchas veces resultan limitantes para efectuar los vuelos con VANT, se alcanza, en promedio, solo medio año de vuelo efectivo. Es decir, de 250 días hábiles en 2023, solo se consiguieron inspeccionar con VANT 125 días. Algo similar para el 2022 y 2021.

Son por estas razones, que, a pesar de contar con planes de mantenimiento sólidos que reportan resultados positivos, es crucial implementar programas aún más eficientes, utilizando tecnologías avanzadas como la inteligencia artificial y la visión por computadora para mejorar la eficiencia y precisión de las inspecciones.

Desarrollo técnico del trabajo

PAE lleva adelante con un RoadMap Digital dinámico como herramienta estratégica, en la que detalla su plan y dirección para conseguir la transformación digital de sus yacimientos, alcanzando una operación remota y eficiente, con planificación integrada, centralización de decisiones operativas, priorización y ejecución autónoma de tareas, que todo el conocimiento de la organización se encuentre disponible en el punto de ejecución y, con la reducción continua de la energía consumida y la exposición al riesgo de las personas.

Aquí se describen diversas iniciativas, metas, y pasos necesarios que contemplan la implementación de nuevas tecnologías y procesos digitales a lo largo del tiempo para optimizar.

Con el claro objetivo de dar solución al problema planteado, PAE incluyó el desarrollo técnico de una solución con el propósito de establecer una base sólida de análisis automático de imágenes en infraestructura eléctrica, para minimizar por un lado, el tiempo necesario en la detección de anomalías, al igual que los errores humanos, que consecuentemente deriven en fallos y averías en el suministro eléctrico y, acarren pérdidas económicas por downtime (DT), costos elevados de reparación, impacto en la infraestructura de T&D, como así también la pérdida de confiabilidad en el sistema eléctrico.

Para comenzar, se estableció la visión y los objetivos estratégicos que se pretenden alcanzar en la solución. Tal como indica el título del presente artículo, la solución radica en el uso de una plataforma que utiliza IA y mecanismos de ML en el análisis automático de imágenes aplicados específicamente a la inspección de líneas eléctricas aéreas y estaciones transformadoras.

Se detallaron las iniciativas claves, en la que se destacan 4 actividades:

1. Análisis preliminar de proveedores de solución, tanto a nivel local como internacional.
2. Armado del Caso de Negocios (CN).

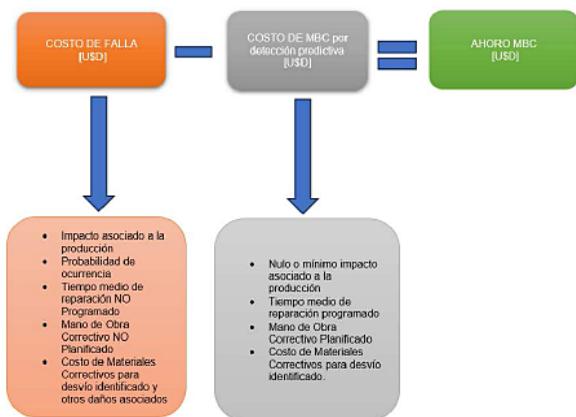
3. Desarrollo de pruebas de concepto (POC) con los proveedores seleccionados por un plazo de 4 meses y su consecuente evaluación.
4. Implementación y despliegue acelerado de la plataforma escogida en todas las UG's de PAE.

Conforme se desarrollaban las POC, se procedió a identificar los recursos necesarios (financieros, humanos, y tecnológicos) para llevar a cabo el plan, los cuales serían ajustados previo a la implementación y despliegue. Paralelamente se tomaba nota de las dependencias entre diferentes soluciones y los riesgos potenciales asociados con la implementación.

En la 1er etapa de estudio de mercado, se realizó el análisis de oferta de proveedores que prometían una solución eficaz, segura y adaptable a las necesidades de PAE. Para la selección de aquellos que participarían de las siguientes etapas, se tuvo en cuenta factores importantes tales como: capacidades técnicas, experiencia (historial, casos de éxito) y reputación en el mercado, flexibilidad, adaptabilidad y personalización, escalabilidad, soporte técnico, capacitación, cumplimiento normativo (regulaciones, normativas, seguridad del dato), innovación, mejoras y actualización, integración de la solución y facilidad de uso, además de otros aspectos técnicos y comerciales. Vale mencionar que muchos de estos puntos fueron analizados en mayor profundidad dentro de la etapa 3- Desarrollo de POC.

En la 2da etapa, para el armado del CN, se establecieron diferentes hipótesis, con asiento en los historiales de fallas registradas y catalogadas que exhibe PAE en sus bases de datos. Se analizaron bancos de datos de hasta 6 años atrás, que incluían listados de fallas en el sistema eléctrico, sus causas y los tiempos de DT directo asociado, las pérdidas post-corte, el impacto en la mano de obra ejecutante de las correcciones. También se entrevistó a personal operativo, cuadrillas, supervisores y líderes de área, con el objetivo de validar las hipótesis y minimizar los riesgos de errores estadísticos en los cálculos.

Con todo esto se establecieron 2 escenarios, uno de mínima y otro de máxima. En el primero, se contempló un porcentaje de asertividad menor, es decir un mínimo de anomalías detectadas/desvíos reales, mediante la plataforma. Además, un ahorro potencial anual que incluye los ahorros obtenidos de muestras promedio anuales de hallazgos con prioridad urgente, alta y media. También se consideró el costo actual de mantenimiento (cuadrillas y analistas), e igualmente se adicionó un factor de derrateo anual por reducción de ahorro estimado. En cambio, para el escenario de máxima, el porcentaje de asertividad considerado fue mayor, el ahorro potencial anual incluye, además de los ahorros indicados en el escenario de mínima, los obtenidos por hallazgos con prioridades baja y muy baja, un costo de mantenimiento bajo un cambio de estrategia, en el cual se planteó incrementar la cantidad de cuadrillas de inspección por VANT y expandir la inspección al 100% de las líneas eléctricas aéreas de 13,2 kV, como así también la optimización de recursos, mejora en los tiempos por misión de vuelo y la reducción de carga horaria de analistas. Conviene resaltar que hemos determinado el costo promedio anual de



• **Costo de Falla:** refiere al valor de costo una vez ocurrida la falla (falla funcional), sin haber sido detectada.

$$PO * \left\{ \left(IP \left[\frac{USD}{d} \right] \right) * MTTR[d] + MO_{FALLA}[USD] + MAT_{FALLA}[USD] \right\} = Costo de Falla [USD]$$

• **Costo MBC:** refiere al valor de costo de mantenimiento correctivo cuando el desvío es detectado y se evita la falla funcional.

$$\left(IP \left[\frac{USD}{d} \right] \right) * \frac{MTTR}{3} [d] + MO_{MBC}[USD] + MAT_{MBC}[USD] = Costo MBC [USD]$$

Siendo:

- **PO: Probabilidad de Ocurrencia** - Se basa en la asignación de una probabilidad promedio en caso de materializarse el fallo según el grado de prioridad previamente asignado al desvío detectado. Es un valor adimensional.
- **IP: Impacto en la producción** - Este valor se obtiene de la sumatoria de la producción efectuada en Gas [m3/d] y Petróleo Neto [m3/d]. Ambos considerados en hembras equivalentes [USD/d]
- **MTTR: Tiempo medio de Reparación** - Siendo este el tiempo medio de reparación entre el periodo que el equipo entra en parada programada por mantenimiento o parada por falla funcional, hasta que este es puesto nuevamente en servicio. Incluye el tiempo de búsqueda e identificación de la falla, tiempos varios (activación de cuadrilla, tiempo de viaje, el tiempo neto de reparación).
- **MO: Mano de Obra** - Considera el costo de Mano de Obra (es decir costo de cuadrilla/s) involucrada en el mantenimiento correctivo del desvío identificado.
- **MAT: Materiales** - Especifica el costo de los materiales asociados a cada tarea correctiva.

Figura 1. Cálculo de ahorros potenciales por la aplicación de estrategias de mantenimiento basado en condición (MBC).

DT directo por fallas posibles de detectar bajo inspección por VANT, en las líneas eléctricas que actualmente no están siendo inspeccionadas.

Así también, resulta notable que el ahorro potencial anual es una métrica que se obtuvo de analizar una muestra representativa de una población de 2 años de hallazgos (3.267 avisos) con diferentes prioridades. Este ahorro se calculó por desvío detectado y acción ejecutada en campo para su normalización. Para cada detección se tiene:

En la etapa 3, Desarrollo de POC, se contrató a los 3 mejores proveedores surgidos de la primera instancia y durante un plazo de 4 meses, se los sometió a las mismas condiciones de pruebas bajo datasets previamente armados que contemplaban imágenes con los 4 casos de uso presentes más frecuentes en nuestras operaciones (fallas por burlonería, ataduras sueltas, puntos calientes, fallas superficiales en aisladores cerámicos y poliméricos). Para el cumplimiento de las POC, PAE dispuso 1,98 TB de imágenes en alta resolución (5184 x 3888 pixeles). Se incluyeron fotos en Zoom; Wide; Thermal, y cada imagen con su metadata correspondiente. De este total de imágenes solo se cargaron 415 Gb (~ 40.000 fotos) en las plataformas por cuestiones de tiempo y configuraciones. También se puso a disposición informes tipo de anomalías, procedimientos utilizados en la captura imágenes y

una dedicación promedio de Analista 3hs/día por proveedor a lo largo del periodo de la POC.

En paralelo se realizaron pruebas de navegación, de carga de imágenes, de feedback para el reentrenamiento. Se visualizó la confección de dashboards a medida. Se asistió técnicamente a cada uno de los proveedores y se lograron significativos avances con todos ellos. Al finalizar las POC, fueron evaluados mediante un análisis FODA, una comparativa de cualidades entre plataformas y, por último, en base una matriz de valorización con diferentes pesos asignados a cada línea. Los ítems evaluados son listados a continuación:

- Por cada modo de falla y dataset de testeo cargado: Exactitud (Accuracy); Exhaustividad (Recall); F1 SCORE; Tasa Falsos Positivos (FPR); Precisión.
- Facilidad de carga de imágenes y tiempo de análisis.
- Experiencia Usuario y plataforma (navegación, interfaz, gestión - reconocimiento de anomalías + historia, etc.).
- Soporte y Capacitación.
- Visualización de la anomalía identificada y asignación de la severidad de la anomalía.
- Gestión KPI.
- Identificación del piquete.
- Exportación de datos (Excel o CSV).

	ANOMALIAS BURLONERIA SUELTA / FALTANTE			ANOMALIAS PUNTOS CALIENTES			ANOMALIAS AISLADOR CERAMICO		
	SOLUCION 1	SOLUCION 2	SOLUCION 3	SOLUCION 1	SOLUCION 2	SOLUCION 3	SOLUCION 1	SOLUCION 2	SOLUCION 3
Exactitud	20.18%	78.97%	17.69%	N/A	25.84%	7.69%	57.14%	56.56%	18.75%
Precisión	52.04%	51.30%	8.54%	N/A	33.33%	33.33%	33.73%	80.00%	14.47%
Recall (sensibilidad, exhaustividad)	18.95%	82.29%	17.95%	N/A	13.64%	2.86%	62.22%	57.14%	14.47%
Tasa FP	74.60%	24.24%	82.42%	N/A	62.50%	50.00%	44.72%	50.00%	77.38%
Medida F1	27.79%	63.20%	11.57%	N/A	19.35%	5.26%	43.75%	66.67%	14.47%
	ANOMALIAS AISLADOR POLIMERICO			SIN FALLAS			IDENTIFICACION DE COMPONENTES		
	SOLUCION 1	SOLUCION 2	SOLUCION 3	SOLUCION 1	SOLUCION 2	SOLUCION 3	SOLUCION 1	SOLUCION 2	SOLUCION 3
Exactitud	20.31%	N/A	27.27%	81.63%	58.39%	N/A	65.16%	59.84%	N/A
Precisión	23.67%	N/A	33.33%	15.94%	2.13%	N/A	91.48%	93.75%	N/A
Recall (sensibilidad, exhaustividad)	41.61%	N/A	43.59%	84.62%	8.33%	N/A	68.99%	52.50%	N/A
Tasa FP	94.74%	N/A	89.47%	18.49%	36.80%	N/A	60.53%	12.96%	N/A
Medida F1	30.18%	N/A	37.78%	26.83%	3.39%	N/A	78.66%	67.31%	N/A
	ALEATORIO								
	SOLUCION 1	SOLUCION 2	SOLUCION 3						
Exactitud	85.03%	89.03%	42.86%	Mide cuánto se aproximan los resultados al valor verdadero (Proximidad entre un valor medido y un valor verdadero del mensurando)					
Precisión	41.51%	23.57%	9.62%	¿Qué proporción de los clasificados como positivos lo son realmente?					
Recall (sensibilidad, exhaustividad)	62.86%	89.19%	41.67%	Mide la habilidad del modelo para detectar valores positivos verdaderos					
Tasa FP	11.97%	10.97%	56.97%	¿Qué proporción de todos los positivos se clasifican como tal?					
Medida F1	50.00%	37.29%	15.63%	Los buenos modelos tienen FPR muy bajo					
				Cuanto mayor sea el valor de F1, mejor será el rendimiento del modelo					

Tabla 1. Valores de asertividad obtenidos para diferentes proveedores en función de los dataset cargados.

- Facilidad de configuración de nuevos MDF.
- Reentrenamiento.
- Flexibilidad de la plataforma ante cambios visuales.

La POC resultó una etapa crucial de cara a la implementación, ya que permitió la validación de la viabilidad técnica, la identificación de problemas antes de la implementación a gran escala, la mitigación de riesgos por pruebas en un entorno controlado. Fue concluyente para determinar si esta nueva tecnología optimizaría el uso de recursos frente al proceso actual, incluyendo el tiempo de análisis. Determinó la sería la facilitación de una integración fluida, evaluando la compatibilidad de la nueva tecnología con los sistemas y procesos existentes y cuanto admiten de customización o soluciones personalizadas, con el fin de adaptar mejor la solución a las necesidades y circunstancias específicas de PAE. Otro factor no menor, que posibilitó la POC, fue la evaluación de la aceleración del proceso de implementación, mediante la reducción del tiempo de despliegue. Por último, la POC impactó en la medición de beneficios potenciales de la tecnología, como mejoras en la eficiencia, reducción de costos y aumento de la cantidad de hallazgos, como así también en el análisis de desempeño de la solución en condiciones reales, asegurando que cumple con las expectativas y objetivos establecidos.

Previa a pasar a la siguiente fase, etapa 4- Implementación y despliegue acelerado de la plataforma escogida, se elaboró un anexo técnico (AT) que incluyó mejoras requeridas respecto de la POC, se añadió lo mejor de cada plataforma testeada. Se solicitó la adición de todos los modos de fallos catalogados en nuestro sistema SAP, el armado de dashboards y KPI's customizados, la facilidad de realizar una planificación centralizada desde plataforma, la conectividad con SAP y otras aplicaciones, la asignación de severidad según estándar PAE, el cumplimiento de un plan de despliegue agresivo para dar cobertura en todas las UG's de PAE.

Para comparar las ofertas técnicas, se utilizó la misma metodología que en la POC, se confeccionó una matriz de valoración, se asignó un peso a cada línea evaluada y se procedió con el análisis. Los ítems técnicos evaluados fueron:

- Velocidad de Despliegue / Seguimiento del cronograma propuesto.
- Analítica de Imágenes y Videos.
- Catálogo de Fallos (Inclusión de todos los MDF).
- Dashboards customizables / Tablero de Gestión de alarmas (considera calidad, funcionalidad y tiempo de respuesta).
- Herramienta de Inspección (relinqueo, vistas, asignaciones de estados, planificación de misiones, identificación de componentes, kpi's, feedback, visualización y comparación de históricos).
- Facilidad de carga de datasets.
- Disponibilidad y recursos comprometidos en el proyecto.
- Alcance Funcional (escalabilidad, flexibilidad, velocidad, correcciones, visualización cartográfica de red eléctrica).
- Alcance de activos de inspección.

- Conectividad bidireccional con SAP.
- Conectividad con otras herramientas y aplicaciones.
- Utilización de inputs externos a PAE para entrenamiento de modelos.
- Generalidades (incluye navegación, interfaz, entregables comprometidos; soporte y capacitación; experiencia Customer Success Manager; experiencias anteriores y knowhow del servicio; HDR a futura).
- MDF primarios y secundarios – Asertividad esperada en función de inputs.
- Informe y registros solicitados por PAE - Exportación de datos.
- Reentrenamiento / Etiquetado.
- Cantidad de Usuarios / Perfiles y Roles definidos.
- Flexibilidad y respuesta ante cambios visuales de la plataforma.
- Seguridad de información - Requisitos IT.
- IA Generativa.
- Tiempo establecido y carga HH requerida para cumplimiento de objetivo proyecto al 100% (análisis automático de imágenes); Nivel de dependencia de PAE (HH requeridos).

Resultados obtenidos

En general, los modelos de IA obtuvieron buenos resultados en la identificación de componentes y defectos, teniendo en cuenta que algunos modelos de IA de los proveedores nunca habían sido entrenados en estos activos. Aquellos modelos que fueron armados y entrenados con datasets de fallas provistos por PAE lograron excelentes resultados a pesar de no superar las 1.200 imágenes con fallas por cada caso de uso. En algunos modos de fallos superaron el 80% de asertividad.

Se consiguió validar técnicamente la aplicación de más de una plataforma funcional para optimizar las inspecciones en PAE y realizar un escalamiento de la solución.

Los logros más destacables en comparación con el proceso actual son:

- 95% mejora del proceso integral.
- 3X más defectos detectados que el método actual.
- 100% imágenes analizadas.
- 4X veces más veloz el análisis de imágenes.
- Disminución del tiempo de registro y calificación a 1/3 del utilizado en la actualidad.
- Comparación inmediata de datos históricos para evaluar la evolución de un defecto en el tiempo.
- Aprovechamiento de los datos para planificar el mantenimiento.
- Visión más amplia del ciclo de vida de los activos.

Es preciso mencionar que el CN fue actualizado con la oferta económica del despliegue del proyecto, que contempló el valor real del licenciamiento e implementación de la plataforma funcional. El VAN del proyecto es positivo, su TIR es de 240% y el valor de repago del proyecto es de 1,4 años.

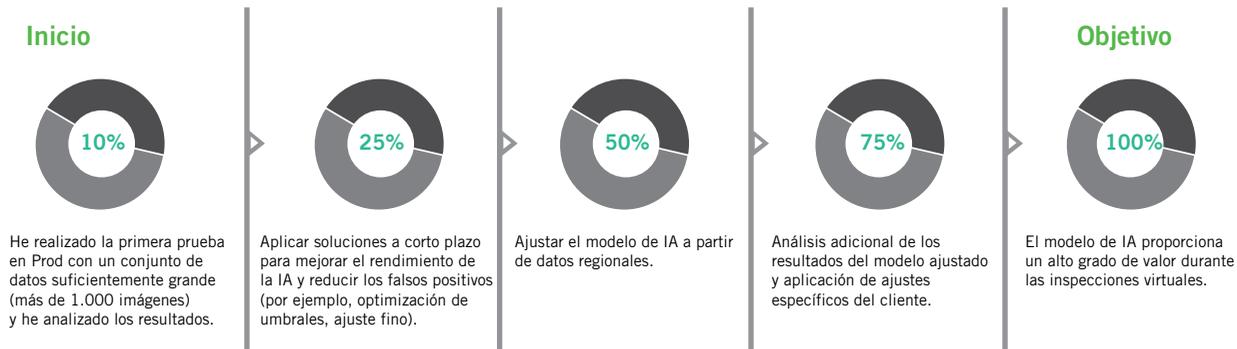


Gráfico 2. Ejemplo de viaje del modelo de IA.

Conclusiones

Las inspecciones virtuales con el uso de IA suponen un paso evolutivo en el viaje de digitalización. El primer objetivo del proyecto debe buscar la aceleración de las inspecciones virtuales y la detección de defectos al utilizar una IA colaborativa, es decir que no reemplazar en su totalidad la intervención humana, sino que hacer de esta última más eficiente y precisa.

En general, hay múltiples factores que influyen en el rendimiento de la IA, estos factores críticos incluyen la captura de imágenes, la calidad de la imagen, el reentrenamiento, el ajuste de umbrales, la definición de defectos y la entrada de datos estándar. Por tal razón, es preciso aplicar una metodología probada para establecer las bases para la mejora continua de la IA.

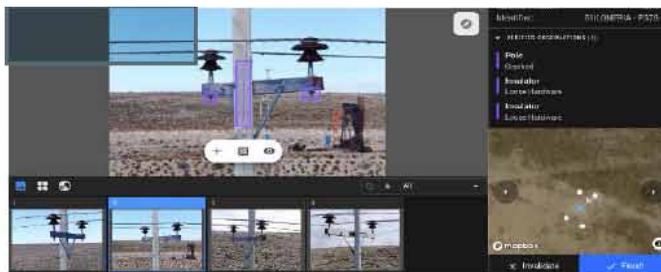
Se recomienda que la plataforma abarque la mayor parte del proceso, permitiendo al cliente planificar la captura de imágenes y las inspecciones en una sola herramienta.

La evaluación de los proveedores debe ser exhaustiva y considerar tanto las capacidades técnicas como los aspectos comerciales y operativos. Todos estos puntos favorecerán a un despliegue rápido, efectivo y con el menor nivel de dependencia por parte del cliente.

Otro punto relevante refiere a que, para medir eficazmente el aumento de la eficiencia, es necesaria una métrica que tenga en cuenta el tiempo ahorrado al aceptar las sugerencias correctas de la IA y el tiempo perdido en revisar y rechazar las sugerencias de la IA. Muchas veces el esforzarse por conseguir una precisión perfecta podría obligar a la IA a ignorar sugerencias cuando no está segura, con el riesgo de perder automatización y requerir el registro manual de defectos. Del mismo modo, aspirar a un recall perfecto podría abrumar a los analistas con demasiadas sugerencias, lo que mermaría la eficacia. En cambio, optimizar la eficiencia permitiría a la IA sugerir un número razonable de casos para su inspección, dando prioridad a un ahorro de tiempo significativo frente a una precisión y exhaustividad perfectas. Encontrar el equilibrio adecuado entre automatización y dedicación del analista es clave. Aunque la automatización de la detección de defectos puede parecer beneficiosa, puede suponer una pérdida de tiempo para los inspectores si tienen que revisar numerosas sugerencias. Por lo tanto, lo mejor es encontrar un equilibrio que dé prioridad al aumento de la eficacia y al ahorro de tiempo.

Por último, hay que destacar que la implementación de la IA en el análisis automático de imágenes para la inspección de líneas eléctricas aéreas y estaciones transformadoras representa un avance significativo en la gestión y mantenimiento de infraestructuras eléctricas.

Este enfoque innovador ofrece numerosos beneficios, entre los que destacan la mejora en la precisión y eficiencia de las inspecciones, la reducción de costos operativos y la mitigación de riesgos.



Capturas de casos de usos identificados en la plataforma.