

Optimizing Document Management in Industrial Maintenance through Generative Artificial Intelligence and Prompt Engineering

Jairo de Jesús Ramírez Monguí¹ ; Diana M. Cardona-Román² 

¹ Consorcio OMI-SKF, Colombia, jairo.ramirez@osc.com.co

² University of Los Llanos, Colombia, dcardona@unillanos.edu.co

Abstract— *In the context of Industry 4.0, Generative Artificial Intelligence (GAI) has primarily been used to automate operational processes and schedule activities. However, the work order (WO) closure stage is often considered a low-value administrative process, despite its potential as a critical source of unstructured knowledge. This article demonstrates the effective use of GenAI in completing maintenance report documentation for strategic industrial assets. This paper proposes and validates a five-stage prompt engineering framework for automating work order closure documentation in industrial maintenance. Through two case studies conducted over six months, the framework reduced work order closure time and monthly report generation time, while improving data quality and traceability. The results show that GenAI can be used to leverage closure information for feedback in analytical models and data-driven decision-making. By significantly reducing man-hours and improving the quality of historical data, GenAI acts as a key enabler for transitioning to predictive maintenance. In conclusion, integrating GenAI into the document workflow enables the utilization of previously untapped operational knowledge, thereby strengthening industrial reliability.*

Keywords— *Generative AI, Maintenance, Work Order automation, technical documentation, Unstructured knowledge sources.*

Optimización de la Gestión Documental en Mantenimiento Industrial mediante Inteligencia Artificial Generativa e Ingeniería de Prompts

Jairo de Jesús Ramírez Monguí¹ ; Diana M. Cardona-Román² 

¹ Consorcio OMIA-SKF, Colombia, first.author@email.edu

² University of Los Llanos, Colombia, dcardona@unillanos.edu.co

Resumen— En el marco de la industria 4.0, la Inteligencia Artificial Generativa (GenAI) se ha centrado tradicionalmente en la automatización de procesos operativos y la programación de actividades. No obstante, la etapa de cierre de las órdenes de trabajo (OT) suele relegarse a un proceso administrativo de bajo valor, ignorando su potencial como una fuente crítica de conocimiento no estructurado. Este artículo evidencia el uso eficaz de GenAI para completar la documentación de informes de mantenimiento de activos industriales estratégicos. Este estudio propone y valida un marco de ingeniería de prompts estructurado en cinco etapas, orientado a la automatización de la documentación del cierre de órdenes de trabajo en el contexto del mantenimiento industrial. Mediante la implementación de dos estudios de caso desarrollados a lo largo de seis meses, se evidenció una reducción en el tiempo de cierre por orden de trabajo y en el tiempo requerido para la generación de reportes mensuales. Adicionalmente, el marco contribuyó a la mejora de la calidad de los datos y al fortalecimiento de la trazabilidad de la información. Los resultados evidencian que el uso de GenAI permite aprovechar la información del cierre para la retroalimentación de modelos analíticos y la toma de decisiones basadas en datos. Al reducir significativamente las horas hombre (HH) y mejorar la calidad de los datos históricos, esta tecnología actúa como un habilitador clave para la transición hacia el mantenimiento predictivo. Se concluye que integrar la GenAI en el flujo documental permite capitalizar el conocimiento operativo antes desaprovechado, fortaleciendo la confiabilidad industrial.

Palabras clave — AI generativa, mantenimiento, automatización de órdenes de trabajo, documentación técnica, fuentes de conocimiento no estructurado.

I. INTRODUCCIÓN

En el contexto actual de la transformación digital y la evolución hacia modelos de gestión de activos más inteligentes, la aplicación de Inteligencia Artificial Generativa (GenAI) se posiciona como una herramienta habilitadora para optimizar los procesos asociados al mantenimiento industrial [1]. Particularmente, la gestión documental de las órdenes de trabajo representa un desafío recurrente debido a la alta variabilidad en la calidad de los registros, la dispersión de la información y la limitada explotación de los datos históricos para la toma de decisiones [2]. Este artículo presenta una primera fase de aplicación o uso especializado de GenAI para la gestión documental de órdenes de trabajo de mantenimiento, con énfasis en el cierre técnico y la estandarización de la información registrada.

En esta fase inicial, la solución se enfoca en el uso de GenAI para la estructuración, validación y enriquecimiento de listas de verificación utilizadas durante el cierre de las órdenes de trabajo. El cual utiliza un gran modelo de lenguaje o LLM para obtener salidas de alta calidad si las entradas o instrucciones son específicas, este uso especializado de GenAI con instrucciones específicas se conoce como *ingeniería de prompt* [3], [4], [5]. A partir del análisis semántico de documentos técnicos, formatos históricos y procedimientos operativos, el modelo utilizado asiste al personal de mantenimiento en el correcto diligenciamiento de listas de chequeo, asegurando coherencia técnica, completitud de la información y alineación con los planes de mantenimiento establecidos. Este enfoque no solo reduce la dependencia del conocimiento tácito, sino que mejora la trazabilidad de las intervenciones y la calidad de los datos generados en campo.

Adicionalmente, la solución incorpora capacidades de análisis automatizado de informes de mantenimiento previamente entregados, permitiendo la generación de reportes consolidados y la extracción de indicadores clave de desempeño (KPI). Entre estos indicadores se destacan la proporción de mantenimiento preventivo frente al correctivo, tendencias de reincidencia de fallas y patrones asociados al cumplimiento de los planes de mantenimiento. Mediante el procesamiento de lenguaje natural y técnicas de clasificación, la GenAI transforma información no estructurada en conocimiento accionable, sentando las bases para fases posteriores orientadas a mantenimiento predictivo, analítica avanzada y toma de decisiones basada en datos. Esta propuesta evidencia el potencial de la GenAI como un componente estratégico dentro de los sistemas de gestión de mantenimiento modernos, alineados con los principios de la gestión de activos y la industria 4.0.

En suma, el problema que se identifica en este trabajo es la falta de estandarización en la gestión documental para el seguimiento a las órdenes de mantenimiento y la calidad de los reportes documentales; del cual se deriva la siguiente pregunta ¿Cómo integrar la GenAI en la estandarización de la gestión documental para órdenes de mantenimiento industrial? El objetivo abordado es a partir de un caso de estudio mostrar el uso especializado de la GenAI para la generación de reportes con listas de verificación estandarizadas.

Este trabajo se estructura en seis secciones, primera la sección realiza una introducción al estudio, la segunda sección

aborda el desafío de la documentación en el mantenimiento industrial, la tercera sección incluye la descripción de la inteligencia artificial generativa, la cuarta sección explica el abordaje metodológico utilizado para este trabajo, la quinta sección aborda un caso de estudio con aplicación de la GenAI en un entorno de mantenimiento industrial como apoyo a la gestión documental y finalmente, se presentan las conclusiones y perspectivas de trabajo futuro.

II. DESAFÍO DE LA DOCUMENTACIÓN EN MANTENIMIENTO

En los procesos tradicionales de mantenimiento industrial, las organizaciones registran las intervenciones realizadas sobre los activos, así como los fallos o paradas no planificadas. Estas acciones deben reportarse obligatoriamente, pero una fuente principal de ineficiencia operativa radica en el tiempo que el personal técnico dedica a la documentación de las llamadas órdenes de trabajo (OT) [2].

El proceso típico de una OT de mantenimiento inicia con la *generación del aviso*, seguido de su *creación, programación, ejecución de actividades y, cierre con la documentación técnica*. En el mantenimiento preventivo rutinario, por ejemplo, el operador revisa el activo, identifica fallos y registra las acciones correctivas. Durante la ejecución en campo, el técnico prioriza la restauración funcional del activo, es decir, devolverlo a condiciones operativas óptimas, pero el registro detallado de hallazgos, actividades y evidencias queda a menudo relegado. Esto ocurre porque la reparación puede exceder el tiempo programado o porque acumulan múltiples OT pendientes.

Al cerrar la OT, el técnico debe documentar las acciones ejecutadas para respaldar el proceso, lo que consume tiempo adicional y, en muchos casos, se convierte en un cuello de botella crítico [2]. Esta etapa concentra la mayor pérdida de tiempo, agravada por la interpretación manual de formatos, la falta de estandarización en los criterios de registro y la dificultad para vincular la información con indicadores clave de mantenimiento, como el MTTR (tiempo medio de reparación) o el MTBF (tiempo medio entre fallos). Como resultado, se generan registros incompletos, descripciones genéricas o poco técnicas, inconsistentes, fragmentados o con bajo detalle, lo que provoca reprocesos administrativos, reduce la productividad del personal y deteriora la calidad de los datos históricos en el sistema de gestión de mantenimiento (CMMS).

La falta de estandarización en el cierre documental incrementa la carga operativa y cognitiva del técnico, quien debe interpretar formatos extensos, recordar clasificaciones y adaptar su redacción a requisitos administrativos ambiguos. Además, se percibe como una obligación administrativa post-técnica, desconectada de la confiabilidad del activo o la optimización del mantenimiento. Esta dinámica genera pérdidas de tiempo sin valor agregado directo para la confiabilidad del activo, pero impacta negativamente la disponibilidad de indicadores clave.

En los procesos de producción de la Industria 4.0, no basta con adoptar tecnologías de fabricación; también es necesario

transformar los grupos de operación y mantenimiento (O&M) bajo el paradigma del Mantenimiento 4.0. Aunque el flujo de una OT en mantenimiento industrial está claramente definido, la etapa de cierre documental continúa siendo el eslabón más débil del proceso. La integración de IA generativa en esta etapa busca mitigar el esfuerzo manual, asistiendo en la captura estructurada de datos para que el técnico enfoque su tiempo en tareas técnicas de alto valor, mejorando así la calidad de la información para análisis e indicadores de gestión [6].

Aunque la GenAI se ha aplicado principalmente en fases iniciales del ciclo de OT, como la generación automática y programación, basada en datos históricos y reglas operativas, el cierre y documentación siguen tratándose como un proceso administrativo de bajo valor [7]. Esto se debe a la subestimación de los beneficios de esta información para la mejora continua, retroalimentación de modelos analíticos y toma de decisiones. En consecuencia, se desaprovecha una fuente crítica de conocimiento operativo que podría potenciar la trazabilidad, la calidad de datos y la transición a esquemas predictivos e inteligentes.

III. INTELIGENCIA ARTIFICIAL GENERATIVA

La IA generativa es una rama de la inteligencia artificial diseñada para crear contenido nuevo a partir de lo que ha aprendido de grandes volúmenes de datos. En lugar de sólo analizar o clasificar información, estos sistemas pueden producir texto, imágenes, audio, vídeo o incluso código, imitando patrones del mundo real. Su funcionamiento se basa en modelos de aprendizaje profundo (*deep learning*), especialmente redes neuronales que aprenden relaciones, estructuras y estilos presentes en los datos de entrenamiento. Durante el entrenamiento, el modelo identifica patrones internos; luego, cuando recibe una instrucción (por ejemplo, un texto o una imagen inicial), utiliza ese conocimiento para generar algo nuevo, pero coherente, como si “predijera” cuál sería la siguiente palabra, píxel o sonido más probable según lo aprendido [8]. La resolución de problemas complejos puede abordarse mediante instrucciones en lenguaje natural sin requerir reentrenamiento ni procesos de ajuste fino (*fine-tuning*). Como fue demostrado a escala por Brown [9], el incremento en los parámetros de los modelos de lenguaje permite un aprendizaje 'en contexto' (*in-context learning*), donde el modelo reconoce y se adapta a la tarea solicitada a partir de la interacción directa. Esta capacidad facilita que un usuario final, incluso sin formación técnica especializada, pueda validar y aprobar el desempeño de un *prompt* en entornos operativo.

A. Modelos de IA generativa

Los resultados que genera la IA generativa pueden clasificarse según el tipo de red neuronal o arquitectura que los produce (Fig. 1). Por ejemplo, las Redes Generativas Adversarias (GANs) se destacan en la creación de imágenes y videos muy realistas, como rostros sintéticos o escenas simuladas. Los Autoencoders Variacionales (VAEs) también

generan imágenes y variaciones de datos, pero enfocados en aprender representaciones internas para crear nuevas versiones similares a las originales. Los Modelos de Difusión (DMs) son muy versátiles y se usan para generar imágenes, audio y video de alta calidad mediante un proceso de añadir y luego quitar ruido de forma controlada. Finalmente, los Transformadores, base de los Modelos de Lenguaje de Gran Escala (LLM) como Transformadores generativos preentrenados (GPT) o BERT, se especializan en la generación y comprensión de texto, permitiendo interacciones conversacionales (chatbots), redacción automática, resúmenes y análisis de lenguaje natural en varios estilos de escritura. Así, cada tipo de red no solo usa un enfoque técnico distinto, sino que también se asocia a tipos de contenido específicos [8] [10].




Fig. 1 Tipos de contenidos digitales generados por los diferentes modelos de GenAI – Adaptación [6]

En la práctica, el verdadero valor de la IA generativa no solo está en el modelo, sino en cómo las personas interactúan con él, y allí es donde aparece la ingeniería de *prompts*. Los modelos de lenguaje (LLMs) funcionan a partir de indicaciones o instrucciones —llamadas *prompts*— que orientan el tipo de contenido que deben generar [11]. Diseñar estas instrucciones de forma clara, específica y alineada con la necesidad del usuario permite transformar a la IA en una herramienta realmente útil y no solo en un sistema que “responde cosas”. Los estudios revisados muestran que, cuando se aplica un enfoque centrado en el usuario, los *prompts* pueden construirse de manera estructurada para guiar al modelo a producir textos con características deseadas (tono, objetivo, público, nivel técnico), logrando resultados más precisos, persuasivos y adaptados al contexto. Así, la ingeniería de *prompts* se convierte en el puente entre la capacidad técnica de los modelos generativos y su aplicación real en tareas como la creación de contenido, apoyo a decisiones o automatización de procesos documentales.

La Inteligencia Artificial Generativa (GenAI) como capa cognitiva dentro de los sistemas de mantenimiento preventivo, actuando como un componente integrador entre los datos operativos, los modelos predictivos y los usuarios técnicos. En este esquema, la GenAI no reemplaza los modelos de mantenimiento predictivo basados en *machine learning* o *deep*

learning, sino que los complementa, permitiendo interpretar resultados, generar reportes técnicos automáticos, explicar patrones de comportamiento de los activos y estructurar conocimiento a partir de múltiples fuentes como sensores IoT, historiales de fallas, órdenes de trabajo y registros de inspección. De esta manera, la GenAI facilita la transición desde esquemas de mantenimiento basados en calendario hacia estrategias basadas en condición, aportando capacidad de síntesis, contextualización y comunicación de la información generada por los algoritmos analíticos [12].

B. Ingeniería de prompts

La ingeniería de *prompts* puede definirse como el proceso sistemático de diseñar, estructurar, probar y optimizar instrucciones dirigidas a modelos de inteligencia artificial, especialmente a los Modelos de Lenguaje de Gran Escala (LLMs), con el fin de obtener respuestas precisas, útiles y alineadas con un objetivo específico [5]. No se trata solo de “hacer una pregunta”, sino de establecer de forma clara el contexto, el propósito, las restricciones y el tipo de resultado esperado. En entornos de Industria 4.0, esta práctica se convierte en un elemento clave para conectar el conocimiento humano con la capacidad analítica de la IA, influyendo directamente en la calidad de la toma de decisiones, la automatización de procesos y la eficiencia operativa. La literatura evidencia que pequeñas variaciones en la redacción de un *prompt* pueden generar diferencias significativas en la calidad de las respuestas, por lo que su diseño debe abordarse con el mismo rigor que cualquier otro componente de un sistema industrial [13].

Las alucinaciones en los modelos de lenguaje de gran escala (LLM) se definen como la generación de contenido que, a pesar de poseer una estructura gramatical y narrativa coherente, carece de fundamento verificable, consistencia lógica o correspondencia con las fuentes de información existentes [13].

Desde el punto de vista empírico, las buenas prácticas en ingeniería de *prompts* se centran en tres principios fundamentales: claridad, especificidad y contextualización. Un *prompt* efectivo debe evitar ambigüedades, incluir términos técnicos relevantes del proceso industrial y describir con precisión la tarea que se desea resolver. Además, se recomienda aplicar un enfoque iterativo, es decir, probar distintas versiones del *prompt*, evaluar los resultados y ajustarlo progresivamente para mejorar la precisión y confiabilidad de la salida del modelo [14]. También es esencial considerar aspectos éticos y de seguridad, especialmente cuando se trabaja con datos industriales sensibles, así como capacitar al personal en el uso adecuado de estas herramientas para reducir sesgos y dependencias excesivas. De esta manera, la ingeniería de *prompts* deja de ser una interacción informal y se consolida como una práctica técnica estratégica dentro de los sistemas inteligentes de la Industria 4.0 [4] [15].

IV. METODOLOGÍA

Este trabajo utiliza un enfoque metodológico empírico basado en la experiencia directa y la observación de la realidad para extraer conclusiones. La metodología se basa en dos casos de estudio que demuestran la aplicación práctica de IA generativa (IAG) para optimizar la gestión documental en mantenimiento industrial, enfocándose en la generación automática de reportes a partir de documentos no estructurados, la cual tiene cinco pasos a seguir como se muestra en la Fig. 2.




Fig. 2 Metodología de trabajo para el uso de la GenAI

1) *Identificación de Caso*: Seleccionar actividades documentales repetitivas, como listas de verificación o cierres de órdenes de trabajo (OT), que consuman tiempo en registro, estructuración y análisis.

- Caso 1: Reporte de *checklists*, cuya entrada es la lista de verificación con actividades, cumplimientos (X en "Cumple") y observaciones.
- Caso 2: Reportes mensuales, cuya entrada son Múltiples cierres de OT con celdas como "describa lo ejecutado"

2) *Recopilación de Datos*: Reunir documentos fuente (*checklists*, formatos de OT, informes de fallas) en formatos textuales o no estructurados.

3) *Diseño de Prompt*: Construir instrucciones precisas que especifiquen estructura de salida (párrafos, tablas, indicadores), énfasis en hallazgos clave y referencias a archivos originales.

4) *Ejecución o uso GenAI*: Procesar documentos vía modelos GPT (ChatGPT 3.5 y Gemini 3 (Fast)) para extraer, sintetizar y generar reportes estructurados, integrables con CMMS/ERP.

5) *Verificación y realimentación*: Revisar outputs para precisión técnica, trazabilidad y utilidad en confiabilidad en el mantenimiento técnico industrial preventivo (patrones, backlog) y en caso que se requiera se refinan los *prompts* basados en la automatización de flujos para reportes mensuales y en la realimentación humana según la experiencia del supervisor o técnico. Estas pruebas se realizaron con una unidad (*confiabilidad y mantenimiento*) que cuenta con tres personas, un supervisor y dos técnicos, no obstante, en otras unidades se ha implementado el uso de la GenIA de manera exploratoria, lo que permitió aplicar dos instrumentos tipo encuesta, uno a los técnicos y otro a los supervisores. El instrumento a los técnicos contó con cinco preguntas que analizaron las variables: tiempo de dedicación semanal en la elaboración de informes, uso de aplicaciones IA, medio de acceso, percepción de rendimiento o calidad de la salida y barreras en incorporación de GenAI. El

instrumento de los supervisores contó con diez preguntas, se analizaron las mismas variables que el instrumento dirigido a técnicos con las siguientes adiciones: horas-hombre (HH) en la generación de informes, fuentes de información para consolidación de informes mensuales, inclusión de indicadores en reportes, percepción de la integración de cierres documentales de OT y sistemas de gestión de mantenimiento.

V. RESULTADOS

Se presentan dos casos de estudio orientados a identificar posibles implementaciones de la Inteligencia Artificial Generativa (GenAI) en las actividades de gestión documental realizadas por el supervisor de unidad considerando como insumo los informes presentados por el personal técnico. El objetivo es optimizar el uso del tiempo en tareas de registro, estructuración y consulta de información, así como transformar datos operativos dispersos en información técnica útil para el análisis de procesos de confiabilidad.

Adicionalmente, la GenAI facilita la extracción de patrones, la síntesis automática de reportes técnicos y la organización del conocimiento derivado de órdenes de trabajo, listas de verificación e informes de fallas, contribuyendo a la construcción progresiva de bases de conocimiento. Estas bases pueden ser empleadas como soporte para la toma de decisiones, el mantenimiento predictivo y la mejora continua, alineándose con los principios de digitalización, analítica de datos y automatización inteligente propios de los entornos de plantas industriales [4], [8] y [15].

A. Generación de reportes con listas de verificación

Las listas de verificación constituyen un componente fundamental de las hojas de ruta utilizadas para guiar la ejecución de rutinas de mantenimiento. Estas suelen presentarse en formato tipo *checklist* y describen de manera estructurada la secuencia de actividades, puntos de inspección y verificaciones técnicas que deben cumplirse durante la intervención sobre un activo (Fig. 3). Su función principal es asegurar la estandarización de las tareas, reducir la variabilidad en la ejecución de los trabajos y garantizar que se cubran los aspectos críticos relacionados con seguridad, funcionamiento y condición operativa de los equipos.

Sin embargo, gran parte de la información registrada en este tipo de documentación se genera aún en formatos físicos escritos o no estructurados, lo que limita su explotación posterior. Para que estos datos puedan convertirse en insumos útiles para los procesos de confiabilidad, análisis de fallas y seguimiento del desempeño de los activos, es necesario llevar a cabo procesos de digitalización y estructuración de la información. La conversión de listas de verificación en datos digitales permite su integración con sistemas de gestión de mantenimiento (CMMS/EAM), facilita el análisis histórico, la identificación de patrones de degradación y la generación de indicadores técnicos que apoyen la toma de decisiones en entornos industriales.

 FORMATO INSPECCIÓN VISUAL, ESTADO DE CANALETAS, LIMPIEZA DE GABINETES DE CONTROL ABB		Código: F01/CONTROL Versión: 0 Fecha: 12/01/2021 Pág 1 de 1			
Fecha inspección: 30/12/2025 Tag gabinete: STAP		Ubicación gabinete: STAP AGUAS			
INSPECCIÓN GABINETE					
ITEM	DESCRIPCIÓN	APLICA		CUMPLE	
		SI	NO	SI	NO
1	Estado de compuertas, acceso y chasis del gabinete	X			X
2	Gabinete libre de animales, excremento y cualquier tipo de material	X		X	
3	Sistema de ventilación libre de polvo y funcional	X		X	
4	Sistema de iluminación funcional con switch de apertura y cierre de gabinete	X			X
5	Estado de canaletas ranuradas con su tapa superior y sin cables en línea de vista	X		X	
6	Identificación frontal (tag) de gabinete	X		X	
7	Estado led's de alimentación de equipos tales como (fuentes, switch, convertidores, sistema de iluminación y ventilación, controladores)	X		X	
8	Estado de protecciones eléctricas (breaker's, fusibles, entre otros)	X		X	
9	Estado redundancia de controladores (activo/redundante)		X		
10	Estado tarjetas I/O (AI/AO/DIO/Serail)	X		X	
11	Estado carrier de controladores y tarjetas I/O	X		X	
12	Correcto marquillado de cableado estructurado	X		X	
13	Verificación de switches Hirschmann	X			X
14	Estado barras de tierra				
15					
16					
17					
18					
OBSERVACIONES					
1 Chapa frontal derecha se encuentra sin cerradura					
2 En la revisión no se evidenció presencia de roedores					
3 Una de las lámparas frontales no está funcionando					
4 Las barras de tierras presentan sulfatación					
5 Toma de backup sin novedad					
REGISTRO FOTOGRAFICO					
					
RESPONSABLES DE INSPECCIÓN					

Fig. 3 Lista de verificación tipo Checklist

En este contexto, la incorporación de herramientas basadas en IA generativa y procesamiento de lenguaje natural apoya la transformación automática de registros textuales en información estructurada, resúmenes técnicos y reportes comparativos. Esto no solo optimiza el tiempo dedicado a tareas administrativas por parte del supervisor y del personal técnico, sino que también fortalece la construcción de bases de conocimiento y mejora la trazabilidad de las intervenciones, elementos clave para avanzar hacia esquemas de mantenimiento centrados en confiabilidad y gestión inteligente de activos. Una vez llega la lista de verificación tipo checklist, el supervisor debe cerrar la OT creando un texto que resuma lo realizado por el técnico en cuanto a las actividades satisfactorias realizadas y las observaciones indicadas, esto por cada OT generada por cada técnico al día.

En este caso en específico, para ayudar a la generación del informe de cierre de la OT se realiza el siguiente *Prompt*: *"Requiero un reporte de mantenimiento de dos párrafos, donde el primer párrafo se tenga todas las actividades realizadas y resaltando las que se encuentran satisfactorias con una X en la columna de cumplió, y en el segundo párrafo relacionar las observaciones que se tienen en el formato (complementar con parafraseo). El final del texto debe incluir que un texto que mencione que el detalle de las actividades se encuentra en el informe <nombre del archivo>."*

Con la ejecución del *prompt* anterior se obtiene el siguiente reporte escrito que puede ser utilizado para el cierre de la OT y su posterior análisis en el sistema ERP, o sistemas CMMS que tenga la organización.

"Durante la inspección visual y mantenimiento del gabinete de control ABB identificado con el tag STAP, ubicado en STAP Aguas, se ejecutaron satisfactoriamente las actividades establecidas en el formato F01/CONTROL, evidenciando cumplimiento (marcado con X en la columna "Cumple") en la mayoría de los ítems evaluados. Entre las actividades realizadas se incluyen la verificación del estado físico del gabinete (compuertas, chasis y accesos), la confirmación de la redundancia de controladores en condición activo/redundante, la inspección de limpieza interna sin presencia de animales o residuos, la validación del sistema de ventilación y de iluminación del gabinete, la revisión de canaletas ranuradas y su correcto cierre, la identificación frontal del gabinete, el estado de las protecciones eléctricas, tarjetas I/O, carriers, marquillado del cableado estructurado, switches Hirschmann, barras de tierra y la toma de backup del sistema, la cual se realizó sin novedad.

Como resultado de la inspección, se registraron algunas observaciones que requieren atención correctiva y preventiva. Se identificó que la chapa frontal derecha del gabinete no cuenta con cerradura, lo que representa una condición de riesgo para la integridad del sistema. Adicionalmente, una de las lámparas frontales se encuentra fuera de servicio, afectando parcialmente la iluminación interna durante las labores de mantenimiento. Asimismo, se evidenció sulfatación en las barras de tierra, condición que podría comprometer la continuidad y calidad de la puesta a tierra si no se atiende oportunamente. Estas observaciones deberán ser gestionadas para asegurar la confiabilidad, seguridad y cumplimiento de las buenas prácticas de mantenimiento del sistema de control. El detalle completo de las actividades ejecutadas, resultados y registro fotográfico se encuentra consignado en el informe <OSC_CheckListABB_CPO_251230.pdf>."

A partir de lo anterior, es posible generar una descripción general y estructurada de la actividad realizada, lo que permite efectuar un análisis más preciso de la situación operativa del activo. Esta síntesis facilita la identificación de desviaciones, tareas pendientes, condiciones anómalas y oportunidades de mejora, sirviendo como insumo para la planificación de intervenciones futuras y la priorización de acciones de mantenimiento. Asimismo, al integrarse con herramientas basadas en modelos GPT en operación, esta información puede utilizarse para activar flujos de trabajo automatizados (agentes), generar reportes técnicos, emitir alertas o proponer recomendaciones, contribuyendo a una gestión más eficiente, trazable y orientada a la confiabilidad de los sistemas industriales.

B. Generación de reporte mensual con indicadores de mantenimiento

En determinadas actividades de gestión es necesaria la integración y revisión conjunta de múltiples archivos para evaluar el avance de la unidad, como es la de *confiabilidad y mantenimiento*. Un caso representativo corresponde a la elaboración de reportes mensuales de carácter gerencial,

utilizados para el seguimiento de las actividades ejecutadas, el control del cumplimiento de planes de mantenimiento y el balance del backlog por especialidad. Estas tareas implican la recopilación, depuración, comparación y síntesis de información proveniente de diversas fuentes documentales, lo cual demanda una cantidad significativa de tiempo y esfuerzo por parte del personal técnico y administrativo. Este tipo de procesos resulta susceptible de automatización mediante la interacción con modelos GPT, capaces de analizar los archivos fuente, extraer información relevante y generar resúmenes técnicos consolidados.

En este escenario, se emplean los formatos de cierre de OT generados durante el mes como insumo principal para el análisis de la gestión realizada (Fig. 4). A partir de estos registros, es posible clasificar las OT cerradas según su tipo de intervención y calcular métricas asociadas al desempeño del mantenimiento, tales como la relación entre mantenimiento preventivo y correctivo, indicador clave dentro del enfoque de confiabilidad. La automatización del procesamiento de estos documentos mediante IA generativa permite no solo reducir tiempos de elaboración de informes, sino también mejorar la consistencia de los datos, facilitar la trazabilidad histórica y disponer de información oportuna para la toma de decisiones técnicas y estratégicas.

Adicionalmente, estos sistemas pueden apoyar la detección de tendencias, variaciones inusuales en la carga de trabajo o desviaciones respecto a los planes establecidos, proporcionando alertas tempranas y resúmenes ejecutivos orientados a distintos niveles de la organización. De esta forma, la integración de herramientas basadas en GPT dentro de los flujos documentales de mantenimiento se convierte en un habilitador tecnológico para fortalecer la analítica operativa y avanzar hacia esquemas de gestión más predictivos y estructurados.

En este caso en específico, para generar el informe de gestión mensual de las OT cumplidas se realiza el siguiente *Prompt*:

“Requiero un resumen ejecutivo que describa las actividades globales de los archivos adjuntos que contenga un análisis del contenido que se encuentra en la celda “describe lo ejecutado”, cuadro de actividades realizadas (Fecha, ubicación, “No Orden de trabajo (OT)” y “descripción de la actividad”), contar los archivos de mantenimiento preventivo y correctivo, sacar un gráfico de torta como indicador de esta relación, principales hallazgos y recomendaciones técnicas estratégicas. El informe debe ser técnico para el área de confiabilidad y mantenimiento.”

El informe generado incorpora de manera automática las indicaciones y criterios definidos previamente en el *prompt*, garantizando coherencia con los requerimientos técnicos establecidos para el análisis. Este enfoque permite obtener documentos estructurados y alineados con los objetivos del proceso sin necesidad de destinar tiempo adicional ni recursos humanos que normalmente deben concentrarse en actividades técnicas de mayor valor operativo. De esta forma, la

automatización basada en IA generativa contribuye a mejorar la eficiencia administrativa del área de mantenimiento, optimizar la disponibilidad del personal especializado y asegurar la generación oportuna de información relevante para la gestión y la toma de decisiones.

The form is titled 'Identificación básica de la actividad' and contains the following sections:

- Identificación básica de la actividad:** Includes fields for 'Fecha de actividad', 'Hora', 'Tipo de actividad', 'Ubicación', 'Especialidad', 'Nombre del técnico', 'Nombre del supervisor', 'Fecha de cierre', 'Hora de cierre', 'Estado de la actividad', and 'Tipo de actividad'.
- Descripción de la actividad:** Includes a 'Descripción de la actividad' field and a 'Resultado de la actividad' field.
- Resultado de la actividad:** Includes a 'Resultado de la actividad' field and a 'Resultado de la actividad' field.
- Resultado de la actividad:** Includes a 'Resultado de la actividad' field and a 'Resultado de la actividad' field.

Fig. 4 Formato de cierre por orden de trabajo (OT)

Como resultado del informe mensual apoyado por GenAI, se ha generado un Dashboard con los indicadores de mantenimiento preventivo (ver Fig. 5).



Fig. 5 Panel de monitoreo generado por un modelo de GenAI (gemini 3)

C. Verificación y realimentación

Como se mencionó, la estrategia se probó como piloto en una pequeña área de trabajo (*confiabilidad y mantenimiento*), conformada por un supervisor y dos técnicos, desde noviembre de 2025 hasta abril de 2026.

Según la planificación, los técnicos ejecutan las OT, registran las acciones en la lista de verificación (basadas en la hoja de ruta de mantenimiento preventivo) y entregan el informe al supervisor para su cierre. La asignación de OT varía según la hoja de ruta del equipo y la carga del técnico en horas-

hombre (HH) por turno: máximo 60% en mantenimiento preventivo y 30% en correctivo cuando se presenta un evento.

Con el piloto se evidenció la reducción de tiempos al utilizar GenAI. El cierre de OT, tradicionalmente, toma 10-45 minutos; con el *prompt* en GenAI, se reduce a 3-8 minutos (estimado por OT cerradas en los meses analizados). El informe mensual de gestión, incluye agrupación y análisis de OT cerradas; tradicionalmente toma de 2-6 horas; con el *prompt* GenAI toma de 15-60 minutos (incluyendo revisión y carga en el sistema) (ver tabla 1). La unidad genera 10-16 OT semanales, pero áreas de alto volumen asignan 1-2 técnicos dedicados a cierres de OT o consolidación mensual en el informe de gestión. Las variaciones dependen de OT procesadas y eventos exógenos (ej. clima, animales, fallos informáticos).

TABLA I
REDUCCIÓN EN TIEMPO DE GENERACIÓN DE INFORMES POR TAREA

Tarea	Tiempo tradicional	Con GenAI	Reducción estimada
Cierre por OT	10-45 min	3-8 min	~78%
Informe mensual	2-6 horas	15-60 min	~75%
HH/semana (10-16 OT)	1.7-12 h	0.5-2.1 h	~70%

Las GenAI probadas en este proceso fueron ChatGPT 3.5 y Gemini 3 (Fast), para los reportes del último mes se incorporó Claude Sonnet 4.6. Se probaron estos modelos por ser de acceso libre, de fácil uso y no requerir pago para las versiones gratuitas.

El supervisor evaluó la precisión, confiabilidad y calidad del uso de los modelos de GenAI para la generación de informes, siendo Gemini 3 el que mejor resultados obtuvo. Por ejemplo, en el cierre de una OT generada por la IA, Gemini 3 resaltó las observaciones clave como "presencia de roedores", "aseo de gabinetes" o "desgaste", lo que permitió centrarse en puntos críticos, mientras que ChatGPT 3.5 generó el cierre de la OT sin centrarse en los puntos críticos. Se resalta que el modelo de Gemini 3 guarda el historial, esto es, retoma las experiencias para proveer resultados de calidad.

Respecto de las alucinaciones en los informes de cierre de OT, las primeras iteraciones mostraron una precisión media, lo que facilitó el ajuste del *prompt*. Este proceso requirió entre 3 y 4 iteraciones para obtener informes de alta calidad que reflejan fielmente la realidad del día de trabajo. Para los informes de gestión mensual, el refinamiento del *prompt* demandó 6 iteraciones para lograr una calidad óptima. Aunque el *prompt* para reportes mensuales sigue en refinamiento, este enfoque estandariza la presentación de informes con indicadores clave, útiles para la toma de decisiones, incluso si no ahorra tiempo.

D. Evaluación de la estrategia

En aras de ofrecer una evaluación independiente, se aplicaron las encuestas sobre el uso de inteligencia artificial generativa en la gestión documental de mantenimiento industrial desde el rol de técnico y el rol del supervisor. En la primera se recibieron 13 respuestas y en la segunda se recibieron 23 respuestas.

La primera variable abordada fue el tiempo semanal empleado en la redacción y cierre de informes de mantenimiento. Así, el 54% de los técnicos dedica más de 4 horas a esta actividad y el 39% de los supervisores dedica entre 2 y 4 horas y el 35% más de 4 horas.

La segunda variable se relaciona con la GenAI que utiliza como apoyo documental, en ella el 69% de los técnicos y el 61% de los supervisores reportaron utilizar ChatGPT, el detalle lo encuentra en las Fig. 6 y Fig. 7.

La tercera variable es la realización de comparaciones de rendimiento o calidad de salida entre dos o más modelos de GenAI para la elaboración de reportes técnicos de mantenimiento, a lo cual el 31% de los técnicos respondieron que "Sí, de manera informal (por percepción personal)" y el 43,5% de los supervisores para la misma respuesta.

¿Qué aplicaciones de Inteligencia Artificial Generativa utiliza actualmente como apoyo en la elaboración de reportes o documentación técnica d...antenimiento? (Seleccione todas las que aplique)
13 respuestas




Fig. 6 Aplicaciones de Inteligencia Artificial Generativa utilizadas como apoyo en la elaboración de reportes o documentación técnica de mantenimiento por los técnicos

¿Qué aplicaciones de Inteligencia Artificial Generativa utiliza actualmente como apoyo en la elaboración de reportes o documentación técnica d...antenimiento? (Seleccione todas las que aplique)
23 respuestas




Fig. 7 Aplicaciones de Inteligencia Artificial Generativa utilizadas como apoyo en la elaboración de reportes o documentación técnica de mantenimiento por los supervisores

La cuarta variable es el medio de acceso, allí el 61% de los supervisores ingresan desde equipos corporativos y el 54% de los técnicos accede desde su computador personal.

La quinta variable analizada es la barrera de incorporación de la GenAI, en este sentido, el 54 % de los técnicos responde que la principal barrera es la 'falta de capacitación o conocimiento en el uso de estas herramientas' y para la misma barrera se adhiere el 35% de los supervisores, tal como se muestra en la Fig. 8 y Fig. 9.

¿Cuál considera que es el principal obstáculo para incorporar herramientas de IA generativa en el cierre documental de órdenes de trabajo en su área?

13 respuestas




Fig. 8 Principal obstáculo para incorporar herramientas de IA generativa en el cierre documental de órdenes de trabajo en su área rol de técnicos

¿Cuál considera que es el principal obstáculo para incorporar herramientas de IA generativa en el cierre documental de órdenes de trabajo en su área?

23 respuestas




Fig. 9 Principal obstáculo para incorporar herramientas de IA generativa en el cierre documental de órdenes de trabajo en su área rol de técnicos

Las siguientes variables fueron consideradas únicamente para el rol de supervisor, como las horas-hombre (HH) invertidas mensualmente en la consolidación documental, la Fig. 10 expone que el 39% de los participantes invierte entre 4 y 8 HH en esta actividad. Los indicadores incluidos en los reportes mensuales son mostrados en la Fig. 11 y la Fig. 12 que contiene la frecuencia de inclusión de indicadores de manera visual, donde cerca del 35% los incluye tanto mensualmente como semanalmente.

¿Cuántas horas-hombre (HH) invierte mensualmente su equipo en la consolidación, análisis y presentación del reporte gerencial de mantenimiento...cadores, backlog, relación preventivo/correctivo)?

23 respuestas




Fig. 10 Horas hombre (HH) invertidas mensualmente en la consolidación documental por los supervisores

¿Cuáles de los siguientes indicadores de mantenimiento incluye en sus reportes mensuales de gestión? (Seleccione todas las que aplique)

23 respuestas




Fig. 11 Indicadores de mantenimiento incluidos por los supervisores en los reportes mensuales de gestión

¿Con qué frecuencia presenta indicadores de mantenimiento en formato visual (gráficas, tablas dinámicas o dashboards) a la gerencia o al cliente (Ecopetrol)?

23 respuestas




Fig. 12 Frecuencia visual de indicadores de mantenimiento

VI. DISCUSIÓN

Los resultados expuestos en la tabla 1 son consistentes con la evidencia experimental de Noy & Zhang [6], quienes demostraron en un experimento controlado con 453 profesionales que el uso de la GenAI reduce el tiempo dedicado a tareas de redacción profesional en un promedio del 40%; aunque las reducciones están por encima del 70%, se identifica que se tienen reducciones muy significativas en los procesos documentales expuestos. Estos ahorros de tiempo semanales proyectan un impacto superior en áreas con un alto volumen de órdenes de trabajo y en equipos de trabajo extensos donde la tecnología sea implementada.

Al introducir la GenIA en los procesos de mantenimiento industrial genera ventajas que fueron comprobadas con los dos casos de estudio aplicados.

- Aumenta el rendimiento y la productividad del personal menos experimentado, automatizando tareas rutinarias en el apoyo de la creación de informes.
- Estandariza la documentación, reduce la carga administrativa del personal de mantenimiento y mejora la trazabilidad de las intervenciones realizadas en los sistemas industriales.
- Mejora la salud de los repositorios documentales y mejora la gestión documental.
- Acelera la integración con otros sistemas y mejora las capacidades del personal al disminuir los tiempos muertos en el diligenciamiento de los reportes.
- Facilita la integración de indicadores clave de desempeño (KPI) en los reportes mensuales, permitiendo optimizar el seguimiento de la estrategia de mantenimiento establecida para los activos críticos. Esta integración fortalece la supervisión tanto de la integridad operativa como del rendimiento de los diversos grupos de trabajo.

Siguiendo a Schulhoff [16] y White [14] tener un *prompt* correctamente diseñado, preciso y con instrucciones claras, facilita la consecución de la salida deseada. Asimismo el contexto importa, en la medida que se le brinde al LLM información detallada del mantenimiento industrial, ya sea para inspección o cierre de OT, el modelo de GenAI entregará los mejores resultados. El abordaje de las instrucciones brindadas a los LLM debe tratarse dentro del área de ingeniería de *prompts* y debe utilizarse de la manera más robusta posible. La propuesta del presente trabajo queda condensada en la Fig. 13.




Fig. 13 Comparación del flujo tradicional de órdenes de trabajo vs flujo asistido con GenAI en Mantenimiento 4.0

Se debe utilizar los LLM y la ingeniería de *prompt* de manera responsable, toda vez que los modelos generan salidas que son probabilísticas y dependen directamente de las entradas proporcionadas. Dentro de las consideraciones clave que proponemos los autores están:

- Revisión técnica: toda generación (uso de GenAI) debe ser validada y aprobada por operadores técnicos, especialmente en informes industriales donde errores podrían derivar en consecuencias operativas no deseadas.
- Seguridad de datos: Se recomienda un uso cuidadoso de la GenAI y se alienta a no hacer un uso indiscriminado con transmisión de información sensible, implementando filtros estrictos para proteger secretos industriales y ventajas competitivas de la empresa.
- Cuidar la redacción del *prompt*, por cada error gramatical el modelo tiende a generar más alucinaciones, por lo que hay que evitarlo, además colocarle un rol al modelo mejora la entregas.

Las limitaciones de este estudio se centran principalmente en el alcance del área operativa evaluada, sugiriendo la necesidad de una mayor cobertura estratégica para la implementación de proyectos basados en GenAI a nivel organizacional. No obstante, la acotación de esta área facilitó la ejecución ágil de iteraciones necesarias para la mitigación de alucinaciones y la consolidación de un *prompt* final optimizado, permitiendo realizar comparaciones y estimaciones precisas sobre la reducción efectiva de tiempo. A través de este enfoque, se proyecta estandarizar la puesta en marcha de aplicaciones de GenAI mediante una metodología estructurada, facilitando su escalabilidad en grupos operativos con mayor densidad de personal.

A. Alucinaciones en los LLM

Los LLM debido a su naturaleza probabilística, priorizan la plausibilidad lingüística sobre la veracidad factual, lo que los hace intrínsecamente susceptibles al fenómeno de las

alucinaciones. En el estudio de Kazlaris et al. [13] Se observa que las versiones de acceso abierto o gratuitas pueden presentar una mayor incidencia de alucinaciones en comparación con las versiones *premium* o de pago, las cuales suelen integrar mecanismos de optimización y bases de conocimiento más robustas.

La literatura científica describe técnicas para mitigar alucinaciones en LLM, clasificadas por fase de desarrollo y priorizando costo-efectividad:

- Fase de pre-generación (ingeniería de *prompts*): Optimización de *prompts* con roles claros, formatos y restricciones, gestionados vía archivo de referencia para reproducibilidad y bajo costo referencia [17].
- Fase de generación:
 - Chain-of-Thought (CoT) para razonamiento paso a paso [13] [17] [18]. Esta técnica fomenta respuestas más profesionales y analíticas, incluso en las versiones gratuitas de las aplicaciones.
 - Few-Shot Prompting con ejemplos específicos de entrada y salida (muestras de reportes objetivo) para guiar al modelo en la estructura requerida, refinando el resultado a través de múltiples iteraciones [17].
- Fase de retroalimentación (RLHF/RLAIF), aprendizaje por Refuerzo a partir de Retroalimentación Humana (RLHF) o de IA (RLAIF), que implica validación cruzada para mejorar la consistencia y veracidad del contenido generado [13] [17].

El survey de Anh-Hoang et al. [17] distingue entre (1) alucinaciones inducidas por el *prompt*, causadas por *prompts* mal estructurados, imprecisos o ambiguos, y (2) alucinaciones internas del modelo, causadas por la arquitectura, los datos de entrenamiento o el comportamiento de inferencia. Esta distinción es relevante considerando que las primeras sí pueden ser controladas por el usuario; mientras que las segundas, requieren de una intervención técnica profunda.

CONCLUSIONES

La aplicación de Inteligencia Artificial Generativa en la gestión documental de órdenes de trabajo demuestra que la automatización del procesamiento de información técnica no solo reduce la carga administrativa del personal de mantenimiento, sino que mejora significativamente la calidad, consistencia y trazabilidad de los datos históricos. Esta mejora en la estructura y disponibilidad de la información se traduce en un soporte más sólido para los procesos de análisis de fallas, evaluación de desempeño y toma de decisiones dentro del enfoque de mantenimiento centrado en confiabilidad.

El estudio evidencia que la efectividad de las soluciones basadas en LLM no depende únicamente del modelo de IA, sino del diseño estructurado de las instrucciones que guían su operación. La ingeniería de *prompts* se consolida como un elemento técnico clave, comparable a la parametrización de cualquier sistema industrial, ya que influye directamente en la precisión de los reportes, la pertinencia de los resúmenes y la

utilidad de los indicadores generados. Su aplicación sistemática permite transformar a la GenAI en una herramienta confiable para la automatización de procesos documentales.

La transformación de registros no estructurados en información técnica organizada, indicadores y reportes consolidados sienta las bases para fases futuras de mayor madurez digital. La integración de *chatbots* basados en GenAI dentro del flujo documental de mantenimiento constituye un primer nivel de digitalización inteligente que facilita la construcción de bases de conocimiento, la detección de patrones operativos y la evolución hacia esquemas de analítica avanzada y mantenimiento predictivo, en coherencia con los principios de la Industria 4.0.

Este artículo demuestra que la Inteligencia Artificial Generativa puede aportar valor tangible al Mantenimiento 4.0 más allá de las fases tradicionalmente abordadas, al enfocarse en la optimización del cierre documental de las órdenes de trabajo, una etapa crítica pero subestimada dentro del ciclo de mantenimiento. El principal aporte del estudio radica en evidenciar que, mediante el uso especializado de GenAI y la aplicación sistemática de ingeniería de *prompts*, es posible transformar registros técnicos no estructurados en información estandarizada, coherente y trazable, reduciendo significativamente la carga administrativa del personal técnico y mejorando la calidad de los datos históricos.

Asimismo, el trabajo posiciona la gestión documental asistida por GenAI como un habilitador para la confiabilidad y la analítica de mantenimiento, al convertir la información generada en campo en insumos útiles para indicadores, análisis de tendencias y toma de decisiones. De esta manera, la propuesta presentada no solo optimiza horas hombre, sino que contribuye a cerrar la brecha entre la ejecución operativa y la gestión estratégica del mantenimiento, sentando las bases para futuras integraciones con sistemas CMMS/EAM, modelos predictivos y esquemas avanzados de mantenimiento inteligente alineados con los principios del mantenimiento 4.0.

AGRADECIMIENTOS

El segundo autor agradece parcialmente al proyecto de Investigación Código C03-F02-014-2022 DGI/Unillanos.

REFERENCIAS

- [1] S. Farioli, D. Caliste, M. Federici y T. Steffens, «Gen AI could be the right tool for today's maintenance challenges.» McKinsey & Company, 2025.
- [2] K. Arif-Uz-Zaman, M. Cholette, L. Ma y A. Karim, «Extracting failure time data from industrial maintenance records using text mining.» *Advanced Engineering Informatics*, vol. 33, pp. 388-396, 2017.
- [3] N. Knoth, A. Tolzin, A. Janson y J. Leimeister, «AI literacy and its implications for prompt engineering strategies.» *Computers and Education: Artificial Intelligence*, vol. 6, 2024.
- [4] M. Peñalver-Higuera, L. Rodríguez-Alegre, R. López-Padilla y J. Isea-Argüelles, «Engineering prompts in industry 4.0: optimization and intelligent automation of industrial processes.» *Revista*

- Electrónica Multidisciplinaria de Ciencias Básicas, Ingeniería y Arquitectura*, n° 12, 2025.
- [5] P. Liu, W. Yuan, J. Fu, Z. Jiang, H. Hayashi y G. Neubig, «Pre-train, Prompt, and Predict: A Systematic Survey of Prompting Methods in Natural Language Processing.» *arXiv*, n° 2107, 2021.
- [6] S. Noy y W. Zhang, «Experimental evidence on the productivity effects of generative artificial intelligence.» *Science*, vol. 381, n° 6654, pp. 187-192, 2023.
- [7] D. Almagor, D. Lavid, A. Nowitz y E. Vesely, *Maintenance 4.0: Implementation Handbook*, Reliabilityweb, 2020.
- [8] B. Salgado García, «Aplicaciones de la inteligencia artificial Generativa (IAG) en el contexto de la seguridad.» *Universitat Oberta de Catalunya (UOC)*, n° <https://hdl.handle.net/10609/150603>, 2024.
- [9] T. Brown, B. Mann, N. Ryder y M. Subbiah, «Language Models are Few-Shot Learners.» *arXiv*, n° 2005, 2020.
- [10] A. Morales Castro, X. Astudillo Miller, G. A. Alonso Silveri y Y. P. Maldonado Astudillo, «Innovación organizacional con inteligencia artificial generativa: Estrategias clave y estudio de caso.» de *Aplicación de inteligencia artificial y tecnologías para la transformación digital: Pymes, desarrollo sostenible e inclusión social*, México, Fontarama, 2025, pp. 124-140.
- [11] C. A. Guzmán Solano, C. Aguilar Cruz y I. Arroyo-Fernández, «Effective Pitch Decks through User-Centered Prompts for Generative AI.» *Avances en Interacción Humano-Computadora*, vol. 9, n° 1, pp. 240-244, 2024.
- [12] J. Čelić, T. Bronzin, M. Horvat, A. Jović, A. Stipić, B. Prole, M. Maričević, I. Pavlović, K. Pap, M. Mikota y N. Jelača, «Generative AI in E-maintenance: Myth or Reality?» University of Zagreb Faculty of Electrical Engineering and Computing, Zagreb, Croatia, 2024.
- [13] I. Kazlaris, E. Antoniou, K. Diamantaras y C. Bratsas, «From Illusion to Insight: A Taxonomic Survey of Hallucination Mitigation Techniques in LLMs.» *Department of Information and Electronic Engineering, International Hellenic University (IHU)*, 2025.
- [14] J. White, Q. Fu, S. Hays, M. Sandborn, C. Olea, H. Gilbert, A. Elnashar, J. Spencer-Smith y D. Schmidt, «A Prompt Pattern Catalog to Enhance Prompt Engineering with ChatGPT.» Vanderbilt University, Tennessee, 2023.
- [15] UNESCO, «¿Qué es la IA generativa y cómo funciona?» de *Guía para el uso de IA generativa en educación e investigación*, Francia, Unesco, 2024, pp. 8-13.
- [16] S. Schulhoff, M. Ilie, N. Balepur, K. Kahadze, A. Liu y C. Si, «The Prompt Report: A Systematic Survey of Prompt Engineering Techniques.» *arXiv*, n° 2406, 2025.
- [17] D. Anh-Hoang, V. Tran y L.-M. Nguyen, «Survey and analysis of hallucinations in large language models: attribution to prompting strategies or model behavior.» *Japan Advanced Institute of Science and Technology*, 2025.
- [18] L. Twist, J. Zhang, M. Harman y H. Yannakoudakis, «Library hallucinations in llms: risk analysis grounded in developer queries.» *King's College London and University College London*, 2026.