

From Obstacles to Strategies: Integrating Artificial Intelligence into the Software Development Life Cycle

Marcela Paladino ¹ Claudia Pons ^{1,2,3}

¹Lifia – Facultad de Informática, Universidad Nacional de La Plata, Argentina

²Centro CAETI, Universidad Abierta Interamericana (UAI), Argentina

³Comisión de Investigaciones Científicas (CIC-PBA), Argentina

claudia.pons@uai.edu.ar, marcelpaladino@yahoo.com.ar

Abstract. In this study, a narrative review was conducted on the integration of AI (artificial intelligence) in the SDLC (Software Development Life Cycle), analyzing both technological advancements and the obstacles preventing full adoption. Through a systematization of information extracted from recent studies, the main AI tools applied in each phase of the SDLC were identified and classified, along with the associated challenges, which are grouped into technical, organizational, and ethical dimensions. The findings reveal that, although the application of techniques such as deep learning, natural language processing, and intelligent agents offers opportunities to optimize key processes (such as planning, design, code generation, testing, and maintenance), significant barriers persist that limit the effectiveness of these strategies. Among the challenges highlighted are data quality and structuring, compatibility with legacy systems, organizational resistance, and the lack of transparency in AI models. Consequently, comprehensive strategies are proposed that combine technical improvements, extensive training programs, and robust ethical frameworks to promote a more sustainable and efficient integration of AI.

Keywords: Artificial Intelligence, Software Development Life Cycle, Integration Challenges, Technical, Organizational, and Ethical Dimensions.

Desde los Obstáculos hasta las Estrategias: Integración de la inteligencia artificial en el ciclo de vida del desarrollo del software

Resumen. En el presente estudio se realizó una revisión narrativa sobre la integración de la AI (inteligencia artificial) en el SDLC (Software Development Life Cycle), analizando tanto los avances tecnológicos como los obstáculos que impiden su adopción plena. A través de una sistematización de la información extraída de estudios recientes, se identificaron y clasificaron las principales herramientas de AI aplicadas en cada fase del SDLC, así como los desafíos asociados, que se agrupan en dimensiones técnicas, organizacionales y éticas. Los

hallazgos revelan que, aunque la aplicación de técnicas como el aprendizaje profundo, el procesamiento de lenguaje natural y los agentes inteligentes ofrecen oportunidades para optimizar procesos clave (como la planificación, el diseño, la generación de código, las pruebas y el mantenimiento), persisten barreras significativas que limitan la efectividad de estas estrategias. Entre los desafíos se destacan la calidad y la estructuración de datos, la compatibilidad con sistemas heredados, la resistencia organizacional y la falta de transparencia en los modelos de AI. En consecuencia, se proponen estrategias integrales que combinan mejoras técnicas, amplios programas de capacitación y marcos éticos robustos para favorecer una integración más sostenible y eficiente de la AI.

Palabras clave: Inteligencia Artificial, Ciclo de Vida del Desarrollo de Software, Desafíos de Integración, Dimensiones Técnicas, Organizacionales y Éticas.

1 Introducción

1.1 Contexto y Relevancia del Tema

La integración de la AI en el SDLC representa una de las tendencias más disruptivas en la ingeniería de software de la última década. Con el auge de técnicas como el aprendizaje profundo, el procesamiento de lenguaje natural y diversos algoritmos de optimización, la AI no solo ha permitido automatizar tareas rutinarias, sino que también ha posibilitado mejoras significativas en la eficiencia y precisión de procesos críticos, desde la planificación y el análisis hasta la implementación, las pruebas y el mantenimiento (Benitez & Serrano, 2023; Durrani et al., 2024).

En un contexto de creciente competitividad y transformación digital, la aplicación de la AI se ha convertido en un elemento estratégico para responder a la demanda del mercado global. La capacidad de interpretar grandes volúmenes de datos y transformar esa información en decisiones automatizadas está impulsando una nueva era en la que el desarrollo de software se orienta hacia modelos más ágiles y adaptativos. Esta tendencia ha generado un creciente interés tanto en la academia como en la industria, evidenciando la importancia de comprender el impacto y las implicaciones de la AI en cada fase del SDLC. Así, se plantea la necesidad de revisar y sintetizar el estado del arte, para consolidar las oportunidades que la AI ofrece y para identificar de manera clara los desafíos que persisten en su adopción.

1.2 Justificación

El abordaje de los desafíos en la integración de la AI en el SDLC es crucial, tanto para aprovechar las oportunidades de innovación como para garantizar el desarrollo de software de alta calidad, seguro y eficiente. La literatura es amplia, pero aún presenta una dispersión en el análisis de los factores técnicos, organizativos y éticos que inciden en la adopción de la AI (Pothukuchi et al., 2023; Russo, 2024). Este vacío en el conocimiento dificulta la formulación de estrategias integrales que permitan a las organizaciones transformar sus procesos de desarrollo de manera sostenible.

En cuanto a la delimitación del problema, este estudio se enfoca en la integración de soluciones de AI en entornos de desarrollo de software tradicionales, abarcando específicamente las fases de planificación, análisis, desarrollo, pruebas y mantenimiento. Este enfoque permite evitar una dispersión temática y concentrarse en los aspectos que tienen un impacto directo en la calidad, eficiencia y seguridad del software producido.

En resumen, atender de manera integral los retos que dificultan la plena adopción de la AI en el SDLC es esencial para maximizar sus beneficios. Este estudio busca ofrecer información relevante que permita tener una estrategia para la implementación responsable de tecnologías de AI, alineada con las exigencias contemporáneas de la industria del software.

El presente trabajo se organiza en cinco secciones principales. En la Sección 1, se contextualiza el estudio, se exponen la justificación, los objetivos y la relevancia de investigar la integración de la AI en el SDLC. La Sección 2 detalla la metodología adoptada, describiendo el proceso riguroso de selección y análisis de la literatura, así como la sistematización de datos mediante la construcción de una matriz de extracción de datos (Paladino, 2025). La Sección 3 presenta los resultados, organizados en función de las fases del SDLC, donde se clasifican las herramientas de AI utilizadas y se identifican los desafíos recurrentes en cada etapa. En la Sección 4 se desarrolla el análisis y la discusión de los hallazgos, explorando sus implicaciones técnicas, organizacionales y éticas. Finalmente, la Sección 5 cierra el documento con una conclusión que sintetiza los aportes del estudio y ofrece recomendaciones estratégicas para potenciar la adopción sostenible de la AI en el desarrollo de software.

2 Metodología de la investigación

Este estudio adopta un enfoque de revisión narrativa para analizar la integración de la inteligencia artificial (AI) en el ciclo de vida del desarrollo de software (SDLC). Para garantizar una organización estructurada de los hallazgos, se establecieron criterios de selección rigurosos y un esquema de clasificación basado en estudios previos.

2.1 Definiciones conceptuales

Para asegurar precisión en la terminología empleada, se definen los siguientes conceptos clave:

- **Herramientas:** Aplicaciones o plataformas concretas que incorporan AI en distintas fases del SDLC. Ejemplos incluyen GitHub Copilot (asistencia en generación de código) y Selenium (automatización de pruebas).
- **Técnicas:** Métodos y algoritmos empleados dentro o fuera de herramientas para optimizar procesos. Ejemplos incluyen aprendizaje profundo (para generación de casos de prueba) y procesamiento de lenguaje natural (para estructuración de requisitos).
- **Tecnologías:** Paradigmas que engloban herramientas y técnicas dentro de un mismo marco conceptual. Por ejemplo, NLP como disciplina incluye técni-

cas como tokenización y embeddings, además de herramientas como spaCy y NLTK.

2.2 Criterios y proceso de selección

Para la identificación y selección de estudios relevantes, se siguieron los siguientes criterios:

- **Periodo de publicación:** 2022–2025.
- **Bases de datos:** IEEE Xplore, Scopus y Google Scholar.
- **Combinaciones de términos utilizados en la búsqueda:** ("artificial intelligence" OR AI) AND ("software lifecycle" OR "software development life-cycle") AND (challenges OR barriers OR obstacles) AND (integration OR adoption OR implementation)..
- **Filtrado:** Se consideraron estudios con un enfoque metodológico claro y una relación directa con la integración de AI en el SDLC.
- **Evaluación:** Se valoró la claridad, relevancia y rigor metodológico de cada estudio.

2.3 Extracción y clasificación de datos

Para organizar los hallazgos, se desarrolló una matriz de extracción estructurada en hoja de cálculo, siguiendo la metodología utilizada en **Paladino (2025)**, donde se presenta un proceso detallado de clasificación de información en el contexto de la integración de AI en el SDLC. La matriz incluyó las siguientes columnas:

- **Fase del SDLC:** Etapa en la que se aplica la AI.
- **Desafío identificado:** Barreras técnicas, organizativas o éticas reportadas en los estudios.
- **Factor contribuyente:** Elementos que favorecen o dificultan la integración de AI.
- **Estrategia sugerida:** Métodos o soluciones propuestas para abordar los desafíos.
- **Impacto en la eficiencia o calidad:** Efecto esperado de la estrategia en el desarrollo de software.
- **Referencia:** Fuente del estudio analizado.

A efectos de este artículo, el término Machine Learning (ML) se clasifica como técnica cuando hace referencia al método en sí (por ejemplo, ML supervisado para estimación de esfuerzo), y como herramienta/tecnología solo cuando se especifica el framework empleado (por ejemplo, TensorFlow para entrenamiento de modelos).

Para asegurar la trazabilidad de los hallazgos, se elaboró una matriz de extracción en hoja de cálculo, organizada en seis columnas: fase del SDLC, desafío identificado, factor contribuyente, estrategia sugerida, impacto en la eficiencia o calidad y referencia. Este esquema permitió consolidar los datos de forma estructurada y facilitó el análisis comparativo, habilitando la identificación de patrones recurrentes y relaciones entre dimensiones técnicas, organizacionales y éticas. Aunque el diseño metodológico

de la matriz se basa en una versión previa desarrollada en Paladino (2025), se lo ha adaptado específicamente al alcance de este estudio.

2.4 Análisis de datos

El análisis de los estudios recopilados se realizó empleando los siguientes enfoques metodológicos:

- **Síntesis narrativa:** Integración de hallazgos cualitativos para obtener una visión global de la integración de AI en el SDLC.
- **Matriz comparativa:** Contraste entre fases del SDLC, desafíos y estrategias para identificar tendencias.
- **Codificación temática:** Identificación de patrones recurrentes en los estudios para establecer relaciones entre los factores que influyen en la adopción de AI.

3 Resultados

En esta sección se presentan los hallazgos obtenidos del análisis de la literatura sobre la integración de AI en el SDLC. Se ha llevado a cabo una sistematización exhaustiva de las herramientas de AI utilizadas en cada fase del SDLC, clasificando su aplicación y relevancia para mejorar la eficiencia del desarrollo. Además, se identifican los desafíos recurrentes en la implementación de estas tecnologías, sus factores contribuyentes y las estrategias propuestas para abordarlos. Este análisis permite visualizar patrones y tendencias en la literatura reciente, facilitando una comprensión profunda sobre el impacto de la AI en el desarrollo de software. A partir de la matriz de extracción de datos (Paladino, 2025), se estructuraron los resultados en función de su aplicación en cada fase del SDLC, proporcionando una base sólida para la comparación y la discusión posterior.

3.1 Integración de Herramientas de AI en el SDLC

Los resultados de estudios destacaron cómo la AI se ha integrado de manera específica en procesos como la planificación, recolección de requisitos, análisis, diseño, desarrollo, pruebas, despliegue y mantenimiento. Además, se evidenciaron tendencias y enfoques diferenciados que responden a particularidades de cada fase.

Planificación: Las herramientas de AI en esta fase apuntan a optimizar la estimación de esfuerzo y la planificación de recursos mediante tecnologías como agentes inteligentes y aprendizaje profundo. Estas soluciones brindan soporte predictivo en la generación automática de cronogramas, coordinación de recursos en pipelines DevOps y elaboración de documentación inicial (Kambala, 2024; Quevedo-Tumaili et al., 2025). Diversos estudios sugieren el uso de modelos de ML entrenados con conjuntos

de datos especializados y el empleo de plataformas estandarizadas que favorezcan entornos de planificación consistentes, especialmente cuando se enfrentan restricciones de datos históricos confiables (Mohammad & Chirchir, 2024; Benítez & Serrano, 2023).

Recolección de Requisitos: Durante esta etapa, el procesamiento del lenguaje natural (por sus siglas en inglés, NLP) y las técnicas de ML permiten transformar descripciones en lenguaje natural en especificaciones técnicas estructuradas, mejorando la trazabilidad de los requisitos a lo largo del ciclo de vida. Investigaciones recientes proponen modelos entrenados en dominios específicos como estrategia para reducir la ambigüedad y la intervención humana en etapas posteriores (Chen et al., 2023; Lemos et al., 2022; Ricárdez et al., 2024; Keskar, 2023).

Análisis: Las herramientas aplicadas en esta fase incluyen OCR para extracción de texto, NLP para clasificación y ML para predicción de vulnerabilidades. Estas técnicas permiten una toma de decisiones basada en evidencia objetiva. Para mejorar la calidad de los datos procesados y adaptarse a distintos contextos organizacionales, se han propuesto pipelines de análisis combinados con validación cruzada y verificación automática de consistencia (Garg, 2023; Santos et al., 2024).

Diseño: En la fase de diseño, la AI permite automatizar diagramas de flujo, optimizar patrones arquitectónicos y convertir bocetos en código estructurado mediante el uso de redes neuronales y algoritmos de optimización. La literatura destaca el uso de técnicas de NLP y modelos predictivos como mecanismos estratégicos para reducir errores de diseño estructural y acelerar el proceso (Benítez & Serrano, 2023; Garg, 2023).

Desarrollo: Durante esta fase, la AI generativa, como GitHub Copilot, impulsa la escritura automática de código, mientras que otros sistemas ayudan a detectar vulnerabilidades en etapas tempranas (Özpolat et al., 2023; Ricárdez et al., 2024). Para mejorar la robustez del código, se propone la integración de algoritmos de ML entrenados específicamente para la detección temprana de errores y vulnerabilidades críticas (Durrani et al., 2024; Khan, Fatima & Ahmed, 2023).

Pruebas: En esta etapa, el uso de deep learning y NLP ha demostrado ser eficaz en la automatización de la generación y clasificación de casos de prueba, mejorando la cobertura y la eficiencia del aseguramiento de calidad (Keskar, 2023; Todorov, 2022). Como estrategia complementaria, se promueve el empleo de sistemas de validación basados en ML que reduzcan la carga manual y mitiguen los sesgos de pruebas tradicionales (Benítez & Serrano, 2023; Durrani et al., 2024).

Despliegue y Mantenimiento: Las herramientas de AI impulsan la automatización de pipelines CI/CD, así como el monitoreo predictivo y la reparación automática de erro-

res. Durante el mantenimiento, se han propuesto modelos de diagnóstico y corrección basados en ML, complementados por enfoques de AI explicable que aumentan la transparencia del sistema y su adaptabilidad a entornos complejos (Durrani et al., 2024; Mastropaolo et al., 2024).

Tabla 1. Resumen de ejemplos representativos de herramientas y técnicas de IA utilizadas en distintas fases del SDLC, junto con sus respectivas funciones e investigaciones asociadas.

Fase del SDLC	Herramienta o Técnica de IA	Función Principal	Referencias
Planificación	Agentes inteligentes, aprendizaje profundo	Estimación de esfuerzo, cronogramas, asignación de recursos	Kambala (2024); Quevedo-Tumaili et al. (2025)
Requisitos	NLP, extracción semántica, LLMs como ChatGPT	Conversión de requisitos en especificaciones técnicas	Ricárdez et al. (2024); Keskar (2023)
Análisis	OCR, NLP, ML para análisis de riesgos	Clasificación, predicción de vulnerabilidades	Garg (2023); Santos et al. (2024)
Diseño	Redes neuronales, modelos generativos	Generación de diagramas y código estructurado	Benítez & Serrano (2023); Garg (2023)
Desarrollo	GitHub Copilot, asistentes generativos de código	Codificación automática, detección de errores	Özpolat et al. (2023); Ricárdez et al. (2024)
Pruebas	Deep learning, NLP, clasificación automática	Generación y cobertura de casos de prueba	Keskar (2023); Todorov (2022)
Despliegue/Mantenimiento	ML para monitoreo predictivo, AI explicable	Integración CI/CD, detección de fallas, autorregulación	Durrani et al. (2024); Kambala (2024)

3.2 Identificación de las Etapas Críticas del SDLC en la Integración de Aml

El análisis de la matriz de extracción de datos (Paladino, 2025) revela que, aunque la integración de la AI tiene aplicaciones en todas las fases del SDLC, existen etapas en las cuales los desafíos y barreras son particularmente críticos dada la frecuencia con

que surgieron en los datos. A continuación, se destacan tres fases que, según la información recopilada, presentan los mayores obstáculos:

Planificación. La fase de planificación se muestra como una de las etapas más desafiantes para la integración de la AI. En la matriz se identifican problemas relacionados con la estimación del esfuerzo del proyecto y la complejidad en la integración de herramientas, señalados en diferentes estudios (Durrani et al., 2024; Benitez & Serrano, 2023; Khan, Fatima & Ahmed, 2023). Entre los factores contribuyentes se encuentran la falta de datos precisos y la ausencia de modelos predictivos sólidos, lo cual dificulta la optimización de recursos y la asignación adecuada de tiempos. Las estrategias sugeridas incluyen el uso de modelos de aprendizaje profundo para mejorar las estimaciones y la adopción de plataformas interoperables que faciliten la integración con sistemas heredados, aspectos resaltados en estudios como los de Kambala (2024).

Pruebas y Garantía de Calidad. La fase de pruebas es otra etapa crítica en donde los desafíos se vuelven significativos. Los datos recolectados evidencian que la cobertura insuficiente de casos de prueba, la dependencia de métodos tradicionales y la complejidad inherente a la automatización son barreras recurrentes (Durrani et al., 2024; Benitez & Serrano, 2023; Khan, Fatima & Ahmed, 2023). Los factores que dificultan la implementación de soluciones basadas en AI en esta fase incluyen la escasez de herramientas capaces de generar y clasificar dinámicamente casos de prueba, lo que a menudo se traduce en una validación menos robusta del software. Para contrarrestar estos problemas, se sugieren estrategias como el empleo de técnicas de aprendizaje profundo y NLP para automatizar la generación de escenarios de prueba, lo que ha mostrado aumentar tanto la cobertura como la precisión en la validación del software.

Despliegue y Mantenimiento. Las fases de despliegue y mantenimiento también se destacan por los desafíos técnicos y organizativos que afectan la integración de la AI. Según la matriz, la integración con sistemas heredados y la escalabilidad en entornos en constante cambio constituyen barreras importantes (Durrani et al., 2024; Kambala, 2024; Vadde & Munagandla, 2022). La dificultad para predecir y prevenir defectos, así como la falta de automatización en el mantenimiento, se presentan como retos relevantes. Estrategias basadas en sistemas predictivos, como el uso de algoritmos de aprendizaje reforzado y de métodos de monitoreo proactivo, se proponen para mejorar la estabilidad y sostenibilidad de los sistemas, lo que impacta directamente en la calidad y confiabilidad del software en producción.

En síntesis, los datos extraídos permite identificar que las fases de Planificación, Pruebas y Garantía de Calidad, y Despliegue y Mantenimiento son especialmente críticas y presentan los mayores desafíos y barreras para la integración de la AI en el SDLC. Estos hallazgos subrayan la necesidad de desarrollar modelos predictivos más robustos, automatizar de manera eficaz los procesos de validación y establecer estrategias que integren de forma organizada la tecnología de AI con los sistemas tradicionales.

3.3 Exploración de los Factores Técnicos, Organizacionales y Éticos que Dificultan la Adopción de AI en el SDLC

La adopción de la AI en el SDLC es un proceso complejo que se ve obstaculizado por diversos factores. A partir de la sistematización de la información extraída de los estudios analizados (Paladino, 2025), se identifican tres grandes grupos de factores: técnicos, organizacionales y éticos. Cada uno de estos conjuntos de factores incide de manera particular en las etapas del SDLC, afectando la implementación y el impacto de las herramientas de AI. A continuación, se detalla cada categoría:

Factores Técnicos. Los desafíos técnicos forman la base de muchas de las barreras para la integración de la AI. Entre los factores más destacados se encuentran:

Calidad de Datos y Modelos Predictivos. Varios estudios coinciden en que la precisión de los modelos de AI depende crucialmente de la disponibilidad de datos limpios y estructurados. La falta de datos precisos y modelos predictivos robustos afecta directamente la fase de planificación, dificultando la estimación de esfuerzo y recursos (Durrani et al., 2024; Benítez & Serrano, 2023). Asimismo, en etapas como el análisis y la validación, la presencia de datos fragmentados y la “caja negra” de los algoritmos limitan la capacidad de los sistemas para generar resultados confiables (Özpolat et al., 2023; Siddique, 2022).

Integración con Sistemas Existentes. La incompatibilidad entre las herramientas modernas de AI y las arquitecturas heredadas representa otro desafío técnico importante. En la fase de planificación y despliegue, la falta de estándares universales y el difícil acoplamiento con sistemas tradicionales requieren el uso de plataformas interoperables y soluciones modulares (Kambala, 2024; Haghsheno, 2020).

Automatización y Generación de Código. Durante el desarrollo, el uso de asistentes de código inteligente, como GitHub Copilot y otros generadores automáticos, ha sido una solución prometedora. Sin embargo, la dependencia excesiva de estos sistemas y la necesidad de grandes volúmenes de datos para su entrenamiento pueden introducir errores o vulnerabilidades, afectando la calidad final del código (Khan, Fatima & Ahmed, 2023; Upadhyaya, 2022). En consecuencia, se hace necesario combinar la automatización con revisiones humanas que aseguren la corrección y robustez del código.

Factores Organizacionales. Además de las limitaciones técnicas, existen barreras de carácter organizacional que dificultan la adopción efectiva de la AI:

Resistencia al Cambio y Falta de Capacitación. Varios estudios resaltan que la introducción de tecnologías de AI genera incertidumbre en los equipos de desarrollo, principalmente por el temor a la pérdida de roles o a la disminución de la relevancia de habilidades tradicionales (Haghsheno, 2020; Alenezi & Akour, 2025). La carencia de

programas de capacitación y actualización profesional genera una brecha que impide que el personal se adapte adecuadamente a las nuevas herramientas.

Soporte Gerencial y Necesidad Estratégica. La limitada percepción de necesidad organizacional y el apoyo insuficiente por parte de la alta dirección también son factores que frenan la integración de la AI. La adopción de tecnologías innovadoras requiere una visión estratégica clara y recursos asignados específicamente para su implementación, aspecto que no siempre está presente en los entornos tradicionales (Giffari et al., 2024; Ricárdez et al., 2024).

Factores Éticos. Finalmente, los aspectos éticos juegan un papel fundamental en la adopción de la AI, particularmente en lo que respecta a la confianza y la equidad:

Privacidad y Seguridad de los Datos. La preocupación por la privacidad es recurrente en diversas fases, especialmente cuando se trata de manejar grandes volúmenes de información sensible. La exposición de datos confidenciales y la gestión inadecuada de la seguridad pueden comprometer tanto la fiabilidad de los sistemas como la confianza de los usuarios (Todorov, 2022; Russo, 2024).

Transparencia y Explicabilidad. La falta de explicabilidad en muchos modelos de AI, que funcionan de manera similar a una “caja negra”, dificulta la comprensión de las decisiones automatizadas. Este problema ético impide que los desarrolladores y stakeholders confíen plenamente en las herramientas, limitando su adopción y su integración en procesos críticos (Todorov, 2022; Russo, 2024).

La revisión de la información extraída revela que, si bien la integración de la AI ofrece numerosas ventajas en el desarrollo de software, su adopción está significativamente condicionada por desafíos técnicos, organizacionales y éticos. Los problemas técnicos relacionados con la calidad de los datos y la integración con sistemas heredados, las barreras organizacionales como la resistencia al cambio y la falta de capacitación, y las preocupaciones éticas sobre la privacidad y la transparencia, conforman un entramado complejo que limita la plena aplicación de soluciones basadas en AI en el SDLC.

4 Análisis y discusión

La integración de la AI en el SDLC ha sido ampliamente estudiada, y la evidencia recopilada en esta revisión narrativa muestra un panorama complejo y, en ocasiones, contradictorio. Si bien múltiples estudios destacan el potencial transformador de la AI, también se evidencia una serie de desafíos que no solo se limitan a aspectos técnicos, sino que se entrelazan con barreras organizativas y consideraciones éticas.

4.1 Desafíos Técnicos: Entre el Potencial y las Limitaciones

Aunque es indudable que el uso de modelos de aprendizaje profundo y técnicas de NLP ha permitido avances en áreas como la planificación y la automatización de pruebas (Benitez & Serrano, 2023; Durrani et al., 2024), los datos extraídos revelan que la precisión y la fiabilidad de estos sistemas aún dependen en gran medida de la calidad de los datos.

Calidad de Datos y Modelos Predictivos. En teoría, la utilización de algoritmos de ML para predecir el esfuerzo en la planificación y detectar vulnerabilidades en el desarrollo sugiere un gran avance. No obstante, la falta de datos precisos y la persistente “caja negra” en muchos modelos generan incertidumbre. Esto pone en entredicho la escalabilidad de estas soluciones en entornos con datos fragmentados o en constante cambio. Aquí surge una controversia: ¿realmente se puede confiar ciegamente en estos modelos o es necesaria una revisión continua que combine la automatización con una supervisión humana intensa? Se plantea que, si bien los avances son prometedores, los modelos actuales aún tienen un largo camino para lograr la robustez exigida en entornos críticos.

Integración con Sistemas Existentes. Las estrategias técnicas propuestas, como la adopción de plataformas interoperables y arquitecturas modulares, son frecuentemente recomendadas (Kambala, 2024; Haghsheno, 2020). Sin embargo, la realidad es que las empresas a menudo implementan soluciones puntuales que no logran integrarse de forma holística con sus sistemas heredados. Esto sugiere una brecha significativa entre la teoría y la práctica: por un lado, los enfoques modulares son conceptualmente atractivos, pero la transición en sistemas reales, que han evolucionado durante años sin considerar la AI, sigue siendo un reto considerable y controversial.

4.2 Barreras Organizacionales y Transformación Cultural

El factor humano y organizacional se destaca como uno de los más críticos y también de mayor controversia en la literatura.

Resistencia al Cambio y Falta de Capacitación. Los estudios señalan que el temor al desplazamiento laboral y la pérdida de competencias tradicionales generan resistencia frente a la adopción de AI (Haghsheno, 2020; Alenezi & Akour, 2025). En este sentido, aunque muchos autores recomiendan programas de capacitación y actualización, en la práctica, la inversión en formación varía notablemente entre organizaciones. Esto refleja una disparidad: mientras algunos líderes tecnológicos ven en la AI un aliado indispensable, otros se muestran escépticos ante el costo y la curva de aprendizaje asociados. Esta división crea un terreno controversial donde la innovación tecnológica choca con la realidad organizacional y cultural.

Soporte Gerencial y Estrategia de Innovación. La falta de un compromiso estratégico claro y la limitada asignación de recursos impiden la creación de un entorno favorable para la integración de la AI. Este aspecto es particularmente polémico, ya que algunas organizaciones han logrado implementaciones exitosas mediante la creación de equipos interdisciplinarios y un fuerte soporte gerencial, mientras que en otras, la adopción se ha visto obstaculizada por una cultura organizacional poco propensa al cambio. La controversia reside en determinar si la resistencia es inherente a la naturaleza humana o si se trata, además, de una falla en la comunicación y en la estrategia de liderazgo.

4.3 Consideraciones Éticas y el Desafío de la Transparencia

Los aspectos éticos surgen como otra dimensión crítica y a menudo polémica en la integración de la AI.

Privacidad y Seguridad de los Datos. La preocupación por la privacidad es recurrente en múltiples estudios (Todorov, 2022; Russo, 2024). La utilización de grandes volúmenes de información sensible expone a las organizaciones a riesgos significativos, y, en este campo, la falta de normativas claras y la ausencia de auditorías rigurosas generan debates acalorados acerca de hasta qué punto es seguro implementar la automatización basada en AI sin comprometer la confidencialidad de los datos.

Transparencia y Explicabilidad. La transparencia de los modelos de AI es otro punto de crítica. La dificultad para interpretar las decisiones automatizadas genera desconfianza entre los usuarios y desarrolla una percepción negativa respecto a la "inteligencia" real de estos sistemas. Aunque se proponen soluciones como la implementación de modelos explicables, muchos expertos consideran que estas técnicas todavía son incipientes y no ofrecen la claridad necesaria para cumplir con estándares regulatorios y éticos, lo que plantea un área controvertida que requiere más investigación y consenso.

4.4 Síntesis de la Controversia

Si bien la literatura ofrece numerosas estrategias para mitigar estos desafíos, como el uso de sistemas predictivos, la adopción de arquitecturas modulares, la implementación de programas de capacitación y la generación de modelos explicables, la implementación práctica de estas soluciones aún presenta dificultades. La disparidad entre la teoría y la práctica se muestra en la diversidad de enfoques y la falta de consenso en la comunidad sobre las mejores prácticas. Esto sugiere que, para lograr una integración exitosa de la AI en el SDLC, es necesaria una visión multidimensional que combine los aspectos técnicos con una transformación cultural y el establecimiento de marcos éticos sólidos.

En conclusión, la integración de la AI en el desarrollo de software enfrenta desafíos complejos y multidimensionales, que requieren una respuesta integrada. La

evidencia analizada destaca que, a pesar de las mejoras introducidas por modelos avanzados y herramientas automatizadas, la problemática se extiende a aspectos organizativos y éticos que continúan siendo fuente de controversia. Este escenario pone de manifiesto la necesidad de adoptar estrategias que no solo se enfoquen en superar barreras técnicas, sino que también fomenten un cambio cultural y la implementación de políticas éticas claras. La convergencia de estos elementos es esencial para maximizar el potencial transformador de la AI en el SDLC y sentar las bases para futuras investigaciones que aborden los retos desde una perspectiva holística.

Cabe destacar que los hallazgos presentados se basan en estudios que documentan experiencias de aplicación real o propuestas experimentales publicadas en la literatura científica revisada. No se trata de conjeturas hipotéticas, sino de evidencia reportada en fuentes académicas reconocidas entre 2022 y 2025.

A partir del corpus analizado, es posible identificar un punto de inflexión marcado por la irrupción de los modelos de lenguaje de gran escala (por sus siglas en inglés, LLMs), cuya masificación se evidencia a partir de 2023. Estos modelos han ampliado significativamente el alcance de las herramientas de IA en el desarrollo de software, especialmente en tareas de generación automática de código, análisis semántico de requisitos y automatización de pruebas (Quevedo-Tumaili et al., 2025). Aunque el presente estudio no realiza una comparación explícita entre enfoques previos y posteriores, la presencia de estudios representativos de ambos períodos permite reconocer una evolución progresiva: desde soluciones centradas en automatizar tareas acotadas hacia estrategias más integrales, basadas en modelos generativos y sistemas adaptativos. Esta transición subraya la necesidad de seguir explorando los efectos transformadores de los LLMs en el SDLC, tanto desde una perspectiva técnica como organizacional y ética.

4.5 Recomendaciones: Propuesta de Estrategias para Superar los Desafíos en la Integración de AI en el SDLC

A partir del análisis y la revisión de la literatura, se han identificado barreras recurrentes en diversas fases del SDLC para la integración de la AI. Para promover una adopción exitosa de la AI, se proponen estrategias fundamentadas que aborden de forma integrada los desafíos técnicos, organizativos y éticos:

Estrategias Técnicas.

Proceso de Curación de Datos. Implementar procesos de preprocesamiento y curación de datos que aseguren la calidad y la integridad de la información utilizada para entrenar modelos predictivos. Estos procesos deben incluir técnicas de limpieza, validación y estructuración que ayuden a mitigar la fragmentación de los datos (Benitez & Serrano, 2023; Durrani et al., 2024).

Modelos de AI Explicables. Desarrollar o incorporar técnicas de AI explicable (por ejemplo, mapas de atención y modelos basados en reglas) para reducir la opacidad de

los modelos y facilitar la interpretación de sus decisiones, aumentando así la confianza tanto de los desarrolladores como de los usuarios (Özpolat et al., 2023; Todorov, 2022).

Plataformas Interoperables. Adoptar herramientas y plataformas estandarizadas que aseguren la interoperabilidad entre los sistemas tradicionales y las soluciones basadas en AI, lo que facilitará la integración y reducirá los costos de adaptación (Kambala, 2024).

Sistemas Modulares y Auto-Adaptativos. Diseñar arquitecturas modulares que permitan la integración gradual de la AI, adaptándose a las particularidades de cada entorno y posibilitando escalabilidad dinámica a través de algoritmos de aprendizaje reforzado (Müller, 2024; Vadde & Munagandla, 2022).

Estrategias Organizacionales.

Programas de Formación Continua. Implementar programas de capacitación y actualización dirigidos a los equipos de desarrollo, orientados a fortalecer tanto el conocimiento técnico en AI como el manejo de herramientas automatizadas. Esto ayudará a superar la resistencia al cambio y a reducir la brecha de habilidades (Haghsheno, 2020; Alenezi & Akour, 2025).

Equipos Interdisciplinarios. Promover la formación de equipos que integren especialistas en AI, desarrolladores de software y gestores de proyectos. La sinergia entre estos perfiles facilitará la adopción de soluciones híbridas y la implementación de prácticas innovadoras.

Compromiso de la Alta Dirección. Sensibilizar a la alta dirección sobre la importancia estratégica de la AI, respaldando la asignación de recursos y la definición de políticas de innovación que favorezcan la adopción de tecnologías emergentes.

Cultura Organizacional Abierta. Fomentar una cultura de aprendizaje y adaptabilidad que valore el uso de nuevas tecnologías y promueva la experimentación controlada, reduciendo la resistencia organizacional al cambio.

Estrategias Éticas.

Auditorías y Políticas de Privacidad. Establecer un marco regulatorio que incluya políticas de privacidad y seguridad de datos, junto con auditorías periódicas para detectar y mitigar riesgos éticos y de sesgos en los modelos de AI (Todorov, 2022; Russo, 2024).

Transparencia en la Toma de Decisiones. Implementar mecanismos que aseguren la explicabilidad de los resultados generados por la AI, fortaleciendo la confianza de todos los stakeholders y garantizando el cumplimiento de normativas éticas.

4.6 Comparación con estudios relacionados recientes

En línea con estudios recientes que han abordado desafíos similares, se identifican coincidencias que refuerzan los hallazgos de este trabajo. Por ejemplo, Mohammad y Chirchir (2024) clasifican barreras para la integración de la IA en la planificación de proyectos utilizando el marco TOE (tecnología–organización–entorno), coincidiendo con el enfoque multidimensional adoptado aquí. Li et al. (2024) exploran factores organizacionales que afectan la adopción de herramientas de IA, destacando tensiones en la cultura de innovación y la resistencia al cambio que también aparecen reflejadas en esta revisión. Singh (2024) y Mastropaolo et al. (2024) discuten el impacto transformador de la IA generativa sobre el SDLC, subrayando la necesidad de redefinir marcos metodológicos y éticos. Estas convergencias fortalecen la validez del análisis y consolidan la contribución del presente estudio dentro del estado del arte actual.

4.7 Limitaciones del Estudio

Este estudio adopta una revisión narrativa como enfoque metodológico, lo que implica una posible omisión de estudios relevantes, ya que no sigue un protocolo sistemático de revisión. Además, la selección de artículos depende de criterios definidos por el autor, lo que podría introducir cierto sesgo en los resultados y conclusiones obtenidas. Pese a esta limitación, el análisis realizado contribuye a la comprensión de los factores técnicos, organizativos y éticos que impactan la adopción de IA en el desarrollo de software, ofreciendo una visión estructurada basada en tendencias recientes y estudios clave del período 2022–2025.

5 Conclusión

Esta revisión narrativa ha permitido analizar de forma exhaustiva los retos y obstáculos que impiden una adopción plena y efectiva de la AI en el SDLC. La sistematización de la información y la clasificación de herramientas de AI por etapas, ha revelado que, a pesar de los avances notables en áreas como la automatización y la generación de código, siguen persistiendo desafíos críticos.

En el ámbito técnico, se evidencia que la precisión y robustez de los modelos dependen fuertemente de la calidad de los datos utilizados. La ausencia de datos consistentes y los problemas de “caja negra” en muchos algoritmos generan incertidumbre sobre la validez de los resultados, lo que limita su aplicación en entornos reales. Por ello, es imperativo mejorar los procesos de curación y validación de datos para fortalecer los modelos predictivos.

Desde la perspectiva organizacional, la resistencia al cambio y la falta de capacitación constituyen barreras significativas. Mientras algunas organizaciones logran

incorporar con éxito la AI mediante el fortalecimiento de equipos interdisciplinarios y un sólido soporte gerencial, otras enfrentan dificultades debido a la limitada inversión en formación técnica y a la falta de una cultura de innovación. Esta disparidad destaca la importancia de desarrollar estrategias que promuevan la adaptación cultural y el compromiso de todos los niveles de la organización.

En cuanto a los aspectos éticos, la privacidad, seguridad y transparencia son temas recurrentes. La preocupación por el manejo de información sensible y la falta de mecanismos claros que expliquen el funcionamiento de los modelos de AI dificultan la confianza de los usuarios y desarrolladores. Es esencial que las organizaciones implementen marcos regulatorios y políticas de gobernanza que garanticen una adopción ética y responsable de estas tecnologías.

La evidencia recopilada, junto con los estudios de caso presentados, sugiere que las áreas de planificación, pruebas y despliegue/mantenimiento son especialmente críticas. La aplicación exitosa de la AI en estas fases depende de la capacidad para integrar soluciones técnicas innovadoras con un sólido soporte organizacional y marcos éticos claros.

En resumen, aunque la integración de la AI ofrece la posibilidad de transformar radicalmente los procesos de desarrollo de software, su implementación efectiva exige superar desafíos que son, a su vez, técnicos, organizativos y éticos. Las estrategias recomendadas, que abarcan la mejora de la calidad de los datos, el diseño de arquitecturas modulares, la capacitación continua y el establecimiento de normativas éticas, forman la base para una adopción más robusta y sostenible de la AI en el SDLC.

Esta investigación busca ofrecer un enfoque holístico que puede orientar en la transición hacia procesos de desarrollo más inteligentes y adaptables. No obstante, resulta crucial que futuros estudios profundicen en la validación empírica de estas estrategias y desarrollen marcos integrales que aborden de forma simultánea los desafíos técnicos, organizacionales y éticos.

Referencias

- Alenezi, M., & Akour, M. (2025). AI-Driven Innovations in Software Engineering: A Review of Current Practices and Future Directions. *Applied Sciences*, 15(3), 1344.
- Benitez, C. D., & Serrano, M. (2023). The Integration and Impact of Artificial Intelligence in Software Engineering. *Integration*, 3(2).
- Durrani, U. K., Akpinar, M., Adak, M. F., Kabakus, A. T., Ozturk, M. M., & Saleh, M. (2024). A decade of progress: A systematic literature review on the integration of AI in software engineering phases and activities (2013-2023). *IEEE Access*.
- Garg, K. (2023). Impact of Artificial Intelligence on software development: Challenges and Opportunities. *International Journal of Software & Hardware Research in Engineering*, 11(8).
- Giffari, R., Ridho, M. M., Sensuse, D. I., Hidayat, D. S., & Purwaningsih, E. H. (2024). Analyst's Perception on the Use of AI-based Tools in the Software Development Life Cycle. *Jurnal Sistem Informasi*, 20(1), 73-87.
- Haghsheno, S. (2020). Revolutionizing Software Engineering: Leveraging AI for Enhanced Development Lifecycle. *International Journal of Innovative Research in Modern Physics and Software (IJRMPS)*, 8(1), January-February.

- Kambala, G. (2024). Intelligent Software Agents for Continuous Delivery: Leveraging AI and Machine Learning for Fully Automated DevOps Pipelines.
- Keskar, A. (2023). Revolutionizing Software Engineering with Generative AI: Transforming Development Processes, Automation, and Quality Assurance. *TIJER - International Research Journal*, 10(6), 830–844.
- Khan, A. R., Fatima, J., & Ahmed, S. (2023). Crossover of Artificial Intelligence and Software Development Lifecycle. *International Journal of Computing and Related Technologies*, 4(1), 35-42.
- Müller, C. (2020). Transparency challenges in AI models: Overcoming the black-box problem. *Journal of AI Research*, 15(7), 134-145.
- Müller, M. (2024). Advancements in Software Engineering through Artificial Intelligence.
- Özpolat, Z., Yıldırım, Ö., & Karabatak, M. (2023). Artificial intelligence-based tools in software development processes: Application of chatgpt. *European Journal of Technique (EJT)*, 13(2), 229-240.
- Paladino, M. (2025). "Trabajo Final de Especialista en Ingeniería de Software". "Desde los Obstáculos hasta las Estrategias: Integración de la inteligencia artificial en el ciclo de vida del desarrollo del software". Universidad Nacional de La Plata. Accesible en [<https://drive.google.com/file/d/1txBx75L21DmHY5mg4-bu5obg6pP7hgmU/view?usp=sharing>]
- Pothukuchi, A. S., Kota, L. V., & Mallikarjunaradhya, V. (2023). Impact of generative AI on the software development lifecycle (SDLC). *International Journal of Creative Research Thoughts*, 11(8).
- Ricárdez, J. J. U., Vasconcelos, M. P., Domínguez, R. G., & Romero, F. C. (2024). Integration of Generative AI with ChatGPT in Software Development.
- Russo, D. (2024). Navigating the complexity of generative AI adoption in software engineering. *ACM Transactions on Software Engineering and Methodology*, 33(5), 1-50.
- Siddique, I. (2022). Harnessing artificial intelligence for systems engineering: Promises and pitfalls. *European Journal of Advances in Engineering and Technology*, 9(9), 67-72.
- Todorov, P. G. (2022). The Application of Artificial Intelligence in Software Engineering. Available at SSRN.
- Upadhyaya, N. (2022). The Role of Artificial Intelligence in Software Development: A Literature Review. ResearchGate.
- Quevedo-Tumailli, V. F., Arias Calderón, S. E., Ortega Manjarrez, V. A., & Ortega-Tenezaca, B. (2025). Impacto de modelos de lenguaje de gran tamaño en calidad y eficiencia de generación de código: Revisión sistemática de literatura. *Revista Digital Novasinergia*, 8(1).
- Mohammad, Abdulghafour & Chirchir, Brian. (2024). Challenges of Integrating Artificial Intelligence in Software Project Planning: A Systematic Literature Review. *Digital*, 4(3), 555–571. DOI: 10.3390/digital4030028
- Li, Ze; Arony, Nowshin; Awon, Ahmed; Damian, Daniela; Xu, Bowen. (2024). AI Tool Use and Adoption in Software Development by Individuals and Organizations: A Grounded Theory Study. *arXiv preprint*. DOI: 10.48550/arXiv.2406.17325
- Manpreet Singh. (2024). The Impact of Artificial Intelligence on Software Development. *International Journal of Computer Artificial Intelligence*, 5(2), 192–198.
- Antonio Mastropaolo, Camilo Escobar-Velásquez, Mario Linares-Vásquez. (2024). From Triumph to Uncertainty: The Journey of Software Engineering in the AI Era. *ACM Transactions on Software Engineering and Methodology*. DOI: 10.1145/3709360