

SIX SIGMA EN LA ERA DIGITAL: INTEGRACIÓN CON INTELIGENCIA ARTIFICIAL Y BIG DATA PARA LA MEJORA DE PROCESOS

SIX SIGMA IN THE DIGITAL AGE: INTEGRATION WITH ARTIFICIAL INTELLIGENCE AND BIG DATA FOR PROCESS IMPROVEMENT

Trejo Muñoz Jesús Dolores

Tecnológico Nacional de México / IT de Ciudad Juárez
<https://orcid.org/0009-0007-2805-1319>

Jesus.tm01@cdjuarez.tecnm.mx

Pinto Santos Jorge Adolfo

Tecnológico Nacional de México / IT de Ciudad Juárez
<https://orcid.org/0000-0001-9614-2764>

jorge.ps@cdjuarez.tecnm.mx

Poblano Ojinaga Eduardo Rafael

Tecnológico Nacional de México / IT de Ciudad Juárez
<https://orcid.org/0000-0003-3482-7252>

eduardo.po@cdjuarez.tecnm.mx

Rodríguez Medina Manuel Arnoldo

Tecnológico Nacional de México / IT de Ciudad Juárez
<https://orcid.org/0000-0002-8922-4718>

manuel.rm1@cdjuarez.tecnm.mx

Gómez Zepeda Perla Ivette

Tecnológico Nacional de México / IT de Ciudad Juárez
<https://orcid.org/0000-0002-1767-5982>

perla.gz@cdjuarez.tecnm.mx

DOI: <https://doi.org/10.61273/neyart.v1i2.114>

| Recibido: 06/06/2025 | Aceptado: 20/07/2025 | Publicado: 03/09/2025

Esta obra está bajo
una licencia internacional
Creative Commons Atribución 4.0.



Resumen: En este artículo se investiga la integración de la metodología Six Sigma con Inteligencia Artificial (IA) y Big Data para optimizar procesos en la era digital. Six Sigma, desarrollada en la década de 1980, se ha consolidado como un enfoque sistemático para reducir la variabilidad y mejorar la calidad en procesos industriales y de servicios. Sin embargo, con el auge de herramientas como la IA y el Big Data, se ha abierto una nueva frontera para la optimización de procesos.

El estudio analiza cómo la combinación de estas tecnologías permite una reducción del tiempo de análisis, una disminución de defectos en manufactura, una optimización de la productividad operativa junto con un enfoque más sustentable en los procesos. Se destacan casos de estudio en industrias como la fabricación de jabones, semiconductores y textiles, donde la aplicación de IA y Big Data ha demostrado resultados significativos, como la reducción de defectos del 4.5% al 0.8% y la optimización del consumo de recursos.

A pesar de los beneficios, se identifican desafíos como los costos elevados y la falta de capacitación en IA y Big Data. El artículo concluye que la integración de estas tecnologías con Six Sigma representa una evolución significativa en la mejora de procesos, fomentando la innovación y la competitividad en la era de la Industria 4.0. Se recomienda invertir en formación y herramientas escalables para maximizar los beneficios de esta integración.

Palabras clave: Six Sigma, DMAIC, Inteligencia Artificial, Big Data, Control de calidad predictivo, Industria 4.0, Aprendizaje automático, Manufactura inteligente.

Abstract: This article investigates the integration of the Six Sigma methodology with Artificial Intelligence (AI) and Big Data to optimize processes in the digital era. Developed in the 1980s, Six Sigma has become a systematic approach to reducing variability and improving quality in industrial and service processes. However, with the rise of tools such as AI and Big Data, a new frontier for process optimization has emerged.

The study analyzes how the combination of these technologies enables a reduction in analysis time, a decrease in manufacturing defects, and an optimization of operational productivity, along with a more sustainable approach to processes. Case studies in industries such as soap manufacturing, semiconductors, and textiles are highlighted, demonstrating significant results from AI and Big Data applications, such as reducing defects from 4.5% to 0.8% and optimizing resource consumption.

Despite the benefits, challenges such as high costs and a lack of training in AI and Big Data are identified. The article concludes that integrating these technologies with Six Sigma represents a significant evolution in process improvement, fostering innovation and competitiveness in the Industry 4.0 era. Investing in training and scalable tools is recommended to maximize the benefits of this integration.

Keywords: Six Sigma, DMAIC, Artificial Intelligence, Big Data, Predictive Quality Control, Industry 4.0, Machine Learning, Smart Manufacturing.

INTRODUCCION

En la actualidad, la eficiencia operativa y la mejora continua se han convertido en temas importantes para las organizaciones que quieren conservar sus ventajas competitivas en el entorno digital. La metodología Six Sigma, desarrollada en la década de 1980 por Motorola, se ha consolidado como un enfoque sistemático para la reducción de la variabilidad y la mejora de la calidad en procesos industriales y de servicios (Navarro Albert et al., 2017). Su implementación se basa en la estructura DMAIC, compuesta por cinco fases secuenciales (Definición, Medición, Análisis, Mejoramiento y Control), la cual permite abordar problemas operativos de manera estructurada.

En los últimos años, el desarrollo acelerado de herramientas tecnológicas avanzadas, como la Inteligencia Artificial (IA) y el Big Data ha transformado múltiples sectores industriales. La combinación de Machine Learning con Six Sigma en estrategias de mantenimiento predictivo redujo la tasa de fallas en equipos, mejoró la Eficiencia Global del Equipo (OEE) y optimizó la estabilidad del proceso (C_p y C_{pk}) (Shivaramu, 2025). Estos avances han permitido a las empresas minimizar tiempos de inactividad, Reducir gastos operativos y elevar los estándares de calidad en la producción. Sin embargo, la integración de IA y Big Data con Six Sigma aún presenta desafíos, como la falta de modelos estandarizados, la adaptación a diferentes sectores industriales y la resistencia al cambio organizacional (Malta et al., 2023). A pesar de los avances en la digitalización y la mejora de procesos, aún existen vacíos en la literatura respecto a la aplicación de IA y Big Data en la toma de decisiones en tiempo real dentro del ciclo DMAIC. Si bien algunos estudios, han explorado la combinación de estas tecnologías, sigue siendo un reto su implementación efectiva debido a la falta de estándares, el manejo de grandes volúmenes de datos y la necesidad de modelos predictivos más precisos (Antony et al., 2020).

Objetivo general

Este artículo tiene como objetivo principal abordar los vacíos existentes en la literatura respecto a la aplicación de IA y Big Data en Six Sigma, específicamente en el proceso de decisiones en tiempo real dentro del ciclo DMAIC. A pesar de los avances en la digitalización, aún existen limitaciones en la implementación de estas tecnologías, como la falta de estándares, la gestión de grandes conjuntos de datos y la necesidad de modelos predictivos más precisos.

Objetivos específicos

- Realizar una revisión de literatura y analizar el impacto de la integración de Inteligencia Artificial (IA) y Big Data en cada fase del ciclo DMAIC de Six Sigma.
- Evaluar estudios de caso reales donde se haya implementado con éxito la combinación de Six Sigma, IA y Big Data.
- Proponer un marco conceptual que facilite la integración de IA y Big Data en proyectos Six Sigma orientados a la Industria 4.0.

Justificación

La integración de Six Sigma con IA y Big Data representa una oportunidad para mejorar para optimizar el rendimiento operativo y la calidad de los procesos en la Industria 4.0. Pese a ello, la escasez de investigaciones especializadas de su implementación limita su adopción generalizada. Esta revisión contribuirá al conocimiento sobre el tema, proporcionando un análisis detallado de su impacto y facilitando futuras investigaciones en la convergencia de estas metodologías.

DESARROLLO

Fundamentos de Six Sigma

El método Six Sigma fue desarrollado en los años 80 por Motorola, liderado por el ingeniero Mikel Harry. Su objetivo era reducir la variabilidad en los procesos mediante inteligencia de datos y la mejora continua, lo que llevó a su adopción en múltiples industrias. El resultado fue óptimo ya que mejoró la calidad, debido a estos resultados obtenidos el sector industrial empezó a desarrollar nuevas técnicas para ser más productivos y mejorar continuamente. El objetivo de la metodología es aumentar la capacidad de proceso, de tal forma que se reduzcan los defectos a tal nivel que estos sean imperceptibles para el cliente (Navarro Albert et al., 2017).

Una de las definiciones más completas de Six Sigma, que abarca tanto su propósito como su forma de aplicación. Definen a Six Sigma como una metodología estructurada que contribuye a minimizar la

variabilidad en los procesos organizacionales. Para lograrlo, se apoya en expertos en mejora continua, sigue un método bien definido y utiliza métricas de desempeño con el objetivo de alcanzar metas estratégicas (Prabhushankar et al., 2008).

Metodología DMAIC

DMAIC, constituye la metodología central de Six Sigma representando un enfoque sistemático para la mejora de procesos que se implementa de manera estructurada en las organizaciones. Esta serie de pasos consiste en definir el problema, medir, analizar, proponer mejoras y controlar los procesos involucrados (Malta et al., 2023). Se explorará los principios y etapas del DMAIC, y cómo puede ser aplicado Para alcanzar avances sustanciales en la eficiencia y calidad de los procesos. En la Figura 1 se presenta una representación del ciclo DMAIC y sus principales fases.




Figura 1. Metodología Six Sigma.
Fuente. Elaboración propia (2024).

Definir:

En esta primera fase es fundamental el objetivo y los alcances del proyecto priorizando por qué se realiza el proyecto, cuáles serán los beneficios esperados y cuáles serán las métricas del éxito. Es de suma importancia que la alta dirección apruebe el proyecto y apoye el desarrollo del proyecto (Gutiérrez Pulido & Vara Salazar, 2013).

Medir:

En esta segunda fase es fundamental alcanzar un conocimiento más detallado y exacto de la magnitud del problema o situación que se busca resolver a través del proyecto. Para lograr esto, se define el proceso de

manera más detallada, analizando los flujos operativos, los nodos de decisión y variables de ejecución. Además, se establecen indicadores específicos para evaluar el éxito del proyecto de manera objetiva. En esta etapa, se utilizan herramientas específicas para analizar y mejorar los procesos. Algunas de las herramientas más útiles incluyen:

- Mapeo de procesos detallado
- Análisis R&R (Repetibilidad y Reproducibilidad)
- Fundamentos estadísticos aplicados
- Análisis de capacidad de proceso
- AMEF: Método estructurado para anticipar y mitigar fallos potenciales
- Métricas de Six Sigma

Estas herramientas permiten evaluar y mejorar la eficiencia y la calidad de los procesos (Gutiérrez Pulido & Vara Salazar, 2013).

Analizar:

Tercera fase y es aquí donde es importante identificar la causa raíz del problema, se compraba y confirman las causas con datos, todas aquellas variables que tengan relevancia con posibilidad de intervenir en el problema son parte del desarrollo. En esta fase, se utilizan una variedad de herramientas para analizar y resolver problemas. Algunas de las herramientas más comunes incluyen:

- Técnicas de creatividad como la lluvia de ideas.
- Herramientas de análisis causal como el diagrama de Ishikawa (espina de pescado) y la técnica de los 5 porqués para identificación de raíces problema.
- Métodos de análisis de datos, incluyendo el diagrama de Pareto de segundo nivel y el gráfico de dispersión.
- Herramientas de control y monitoreo como las cartas de control.
- Técnicas de mapeo y diseño como el mapeo de procesos y el despliegue de la función de calidad.
- Métodos estadísticos como el diseño de experimentos y la prueba de hipótesis.

Estas herramientas permiten identificar y resolver problemas de manera efectiva y eficiente (Gutiérrez Pulido & Vara Salazar, 2013).

Mejorar:

En esta fase, se deben plantear y aplicar soluciones dirigidas a las causas raíz del problema. Su propósito principal es resolver los factores originarios que lo generan, en lugar de solo tratar sus síntomas. Para

lograr esto, es importante generar varias opciones de solución. Se deben explorar diversas soluciones mediante lluvia de ideas, métodos creativos y experimentación, asegurando la elección de la alternativa más efectiva.

Una vez que se han generado varias opciones de solución, es importante evaluarlas objetivamente utilizando una matriz de prioridades. Esta matriz permite asignar pesos y jerarquizar las soluciones según diferentes criterios, como costo, facilidad de implementación y beneficios. La solución con la puntuación más alta será la mejor opción según los criterios establecidos (Gutiérrez Pulido & Vara Salazar, 2013).

Controlar:

La idea principal de esta etapa es Controlar y mantener las mejoras logradas en un proceso. Una vez que se han alcanzado las mejoras deseadas, es fundamental diseñar un sistema que mantenga y consolide los cambios realizados. Esto implica institucionalizar y generalizar las mejoras, lo que puede requerir la adaptación y tomar en cuenta a todos participantes en el proceso. El objetivo es revisar periódicamente de que las mejoras se mantengan en el tiempo y no se pierdan. Para lograr esto, es necesario seguir un procedimiento de control que prevenga la repetición de problemas, sostenga el proceso en buena forma y fomente el mejorar continuamente.

Para asegurar la sostenibilidad de las mejoras, es necesario establecer procesos de control en los 3 distintos niveles fundamentales: durante el proceso, la documentación y el monitoreo. Esto permitirá mantener la eficiencia y la calidad del proceso, garantizar la precisión y actualidad de la documentación, y realizar un seguimiento continuo del desempeño del proceso (Gutiérrez Pulido & Vara Salazar, 2013).

Limitaciones y tendencias de Six Sigma

Six Sigma ha sido una herramienta clave para muchas empresas, ayudando a reducir costos y defectos en sus procesos. Sin embargo, no siempre se garantiza el éxito. Se calcula que el 62% de las iniciativas de Six Sigma han fracasado. A menudo, estos proyectos comienzan con buen impulso, pero con el tiempo pierden fuerza, lo que desmotiva a las organizaciones y las hace volver a sus antiguas prácticas (Albliwi et al., 2014). En el sector salud, por ejemplo, más de la mitad de las empresas no tienen una verdadera intención de aplicar Six Sigma. Además, algunos expertos advierten que enfocarse demasiado en la eficiencia puede afectar el crecimiento a largo plazo de una empresa (Antony et al., 2020).

Hoy en día, la Cuarta Revolución Industrial que ha llegado, las empresas generan enormes volúmenes de datos que pueden aprovecharse de manera adecuada para tomar mejores decisiones en base a los análisis, pero esto cada vez es más complejo. Para que Six Sigma siga siendo una metodología efectiva, es clave

utilizar estos datos de manera inteligente. También es importante incorporar factores ambientales en los procesos y encontrar soluciones que permitan que las pequeñas y medianas empresas adopten esta metodología de manera más accesible y efectiva (Antony et al., 2020).

Inteligencia Artificial y Six Sigma

Por más de 60 años, científicos e ingenieros han trabajado continuamente en el desarrollo de la inteligencia artificial (IA). El propósito principal se basa en que las máquinas creadas por el ser humano no solo pueden realizar tareas mecánicas y/o repetitivas, sino también desarrollar una inteligencia comparable a la humana. La IA se ha integrado en nuestra vida diaria, asumiendo funciones clave en el ámbito de la industria, la salud, los medios de transporte y la educación.

La IA ha sido definida de diversas maneras a lo largo del tiempo. Por ejemplo, en el famoso Test de Turing, se plantea que una máquina puede considerarse inteligente si es capaz de interactuar con humanos a través de medios electrónicos sin que estos se den cuenta de que no están hablando con otra persona. Por su parte, Marvin Minsky, una persona primordial en el progreso de desarrollo de la IA, la describió como el poder de los dispositivos automatizados para ejecutar acciones o funciones específicas que, si fueran realizadas por personas, requerirían inteligencia. A pesar de estas diferencias en las definiciones, hay un consenso en que la IA se refiere a un conjunto de herramientas tecnológicas y aplicaciones diseñadas para complementar y mejorar las capacidades de la inteligencia humana (Jiang et al., 2022).

Las claves de IA en la industria está en el aprendizaje automático “ML” (machine learning) donde se pueden reconocer patrones en datos lineales y no lineales, datos no estructurados (Imágenes o texto), tiene una velocidad de cálculo rápida y una alta interpretabilidad lo que lo hace comprensible para los humanos, muchas veces la relación entre los parámetros de entrada (por ejemplo, temperatura, presión, velocidad) y los parámetros de salida (por ejemplo, calidad del producto) es muy compleja y no se entiende completamente, incluso bajo condiciones simplificadas. Por lo tanto, esta relación es desconocida debido a correlaciones extremadamente no lineales (Kim et al., 2022).

Aquí es donde entra en juego la IA, especialmente el Deep learning “DP” (aprendizaje profundo), que es una parte del machine learning “ML”. El papel del Aprendizaje Profundo está comenzando a reemplazar las técnicas tradicionales de análisis de datos porque es capaz de:

- Reconocer configuraciones elaboradas en los conjuntos de datos de entrenamiento.

En una fábrica, la relación entre la temperatura, la presión y la calidad del producto puede ser muy complicada y no seguir una fórmula matemática simple.

- Identificar diversas formas de estructuras complejas de datos, como videos, documentos y grabaciones.

El DP (Deep Learning) implementa ANN (Artificial Neural Networks) con múltiples capas para encontrar relaciones no lineales y patrones complejos. Estas redes son especialmente buenas para trabajar con datos estructurados de forma compleja, como texto, imágenes o sonido. El utilizar estas herramientas tiene como ventaja el aseguramiento de la calidad, así mismo, tanto el ML como el DP ofrecen herramientas para que los procesos mejoren gracias a un análisis de calidad basados en datos lo que nos guía a obtener una calidad predictiva (Tercan & Meisen, 2022).

Estas herramientas de IA están entrenadas para mejorar la calidad aprendiendo de los datos mediante técnicas de machine learning y Deep learning (Sood & Dhull, 2024). La base del entrenamiento de cualquier modelo de IA son los datos. Para mejorar la calidad, estos datos suelen incluir datos históricos de producción, lecturas de sensores de equipos, registros de control de calidad, comentarios de clientes e información sobre los parámetros del proceso (Bukhari & Akhtar, 2024; Sood & Dhull, 2024) . Estos datos deben recopilarse, limpiarse y prepararse en un formato adecuado para los algoritmos de IA (Parmar, 2022).

Las técnicas más comunes para resolver el problema de calidad se eligen entre diferentes algoritmos de IA:

Aprendizaje automático (ML):

Estos algoritmos permiten a la IA aprender de los datos y mejorar la precisión con el tiempo sin programación explícita (Sood & Dhull, 2024).

- Agrupamiento y reducción de dimensionalidad: Es utilizado para analizar grandes conjuntos de datos y encontrar automáticamente ineficiencias o descubrir problemas ocultos (Sood & Dhull, 2024).
- Árboles de decisión y regresión logística: se emplean para el modelado predictivo, como pronosticar la probabilidad de ocurrencia de un defecto basándose en datos históricos (Bukhari et al., 2024).
- Máquinas de vectores de soporte (SVM): se utilizan para mejorar la identificación de la causa raíz (Bukhari et al., 2024).
- Aprendizaje de reglas de asociación (algoritmo Apriori): ayuda a detectar patrones y tendencias ocultos en los datos (Bukhari et al., 2024).

- Pronóstico de series de tiempo (por ejemplo, ARIMA, LSTM): proporciona información predictiva para anticipar futuras ineficiencias del proceso (Bukhari et al., 2024).
- Aprendizaje de refuerzo: se puede utilizar para la optimización continua de procesos explorando una amplia gama de soluciones y seleccionando las más efectivas (Bukhari et al., 2024).

Aprendizaje profundo (DL):

Es una rama especializada del Machine Learning que emplea arquitecturas neuronales destacando en aplicaciones como identificación visual y procesamiento de sonido, así como el análisis de sentimientos de datos de texto (técnica de procesamiento de lenguaje natural). Algunos ejemplos incluyen:

- Transformadores y RNNs (redes neuronales recurrentes): se utilizan en la fase de definición para el procesamiento de como los clientes perciben, sus comentarios y valoraciones. Para identificar quejas recurrentes.
- Redes neuronales profundas: se pueden entrenar para modelado predictivo en la fase de control, como por ejemplo para pronosticar averías en equipos (Sood & Dhull, 2024).

Entrenamiento del modelo:

Una vez que se preparan los datos y se selecciona un algoritmo, el modelo de IA se entrena utilizando estos datos. Esto implica alimentar los datos al algoritmo, que luego aprende las relaciones y patrones ocultos. El rendimiento del modelo se evalúa en una porción separada de los datos (el conjunto de validación) y los parámetros del modelo se ajustan para mejorar su precisión y capacidad de generalización (Bukhari & Akhtar, 2024).

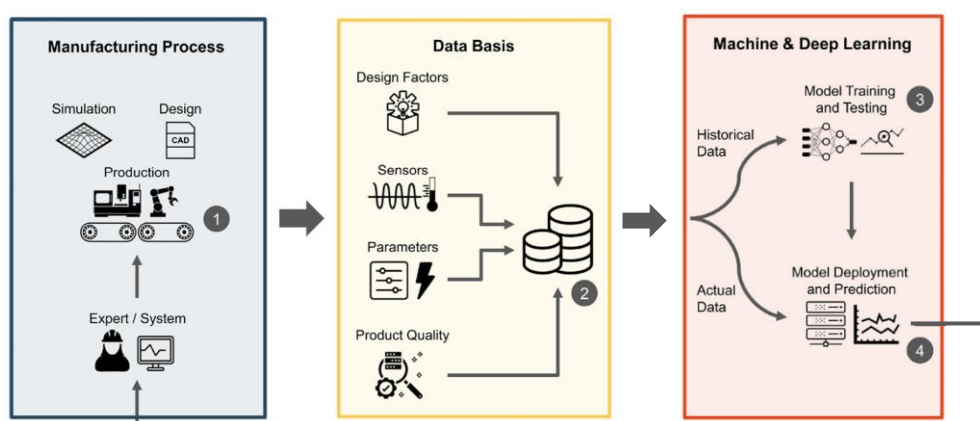


Figura 2. Inteligencia Artificial y Six Sigma.

Fuente. Enfoque de calidad predictiva (Tercan & Meisen, 2022).

En la Figura 2 se muestra un gráfico del enfoque de calidad predictiva:

1. Proceso de manufactura
2. Se recopilan datos relevantes del proceso y de calidad.
3. Se utilizan como base para entrenar un modelo de aprendizaje automático.
4. El modelo entrenado se emplea para realizar estimaciones de calidad como apoyo en la toma de decisiones.

Existen estudios que demuestran que la calidad predictiva es viable, se demostró en un proceso de fabricación de piezas de carrocería de automóviles específicamente en el proceso de embutición. De esta manera se predicen más del 94% de los fallos del proceso (Meyes et al., 2019).

Big data

Big Data se refiere a conjuntos de datos extremadamente grandes y complejos que no pueden ser procesados con herramientas tradicionales de análisis. Desde 2016, el volumen de información generada y almacenada se ha estado multiplicando, esto gracias a los avances tecnológicos y los menores costos asociados al almacenamiento de estos datos. Los macrodatos están transformando la manera en que se extrae conocimiento, permitiendo el descubrimiento de patrones ocultos y la toma de decisiones. Sin embargo, su análisis requiere métodos estadísticos avanzados, herramientas computacionales eficientes y arquitecturas diseñadas para manejar su complejidad (Fan et al., 2014).

El procesamiento de macrodatos en entornos industriales no solo identifica los fallos y la optimiza los procesos, sino se consolida como facilitador en decisiones estratégicas respaldadas por datos. Herramientas como el aprendizaje automático (machine learning) y el aprendizaje profundo (deep learning) están siendo utilizadas para extraer patrones complejos de grandes volúmenes de datos no estructurados, como imágenes, texto y sonido (Khan et al., 2017). En la automatización industrial se adquieren datos por medios de sistemas SCADA, las señales de sensores, PLC, actuadores son transformadas a señales visuales que puedan ser interpretadas por los usuarios, toda esa información debe ser recopilada e integrada a un modelo de datos.

Las técnicas de análisis de big data que pueden adaptarse e integrarse para metodología de Six sigma, en las fases de DMAIC son las siguientes (Al-Rifai, 2025; Baiochi et al., 2025).

Medir: Los análisis de series temporales, se utilizan para analizar tendencias de datos históricos y en esta fase permite detectar patrones y ubicar los posibles problemas.

Analizar: La minería de datos (Data Mining), permite descubrir relaciones ocultas en grandes cantidades de conjuntos de datos, por lo tanto, apoya directamente a identificar causas raíz de defectos.

Controlar: La implementación de un sistema de monitoreo donde se reúne la información de un proceso, ejemplo; datos sobre temperatura, presión y vibraciones. Como resultado se obtiene un análisis prescriptivo. Este tipo de aplicación evita defectos y mejora la estabilidad del proceso mediante la detección temprana de fallos.

Big data, Inteligencia Artificial y Six Sigma

La combinación de algoritmos inteligentes (IA) y el análisis de grandes volúmenes de información (big data) se han aplicado en las diversas fases de la metodología DMAIC de Six Sigma para mejorar la optimización de procesos y el control de calidad predictivo (Bukhari et al., 2024; Sood & Dhull, 2024). A continuación, se detalla cómo se han integrado estas tecnologías en cada fase:

Definir:

La IA puede ayudar a identificar problemas y obtener información sobre los clientes. Esto puede implicar el uso de modelos de machine learning para analizar los comentarios de los clientes, identificar indicadores clave de rendimiento (KPI) y definir los objetivos del proyecto con mayor precisión (Bukhari et al., 2024). La IA puede procesar grandes conjuntos de datos para detectar zonas críticas de mejora que podrían no ser obvias a través del análisis tradicional (Bukhari & Akhtar, 2024).

Medir:

Las herramientas de IA pueden utilizarse para analizar datos históricos e identificar factores que contribuyen significativamente a los problemas de calidad (Bukhari et al., 2024). La recopilación de información en tiempo real de múltiples orígenes, como dispositivos IoT y softwares de gestión empresarial ERP (Enterprise Resource Planning), junto con la detección de anomalías impulsada por IA, permite obtener información más precisa y oportuna sobre las métricas de los procesos. La IA puede supervisar continuamente los procesos, proporcionando información actualizada para la medición (Bukhari & Akhtar, 2024).

Analizar: Se utilizan algoritmos de machine learning para identificar causas raíz. Aplicación de deep learning para analizar datos no estructurados, como imágenes o videos, y detectar defectos en productos (Bukhari & Akhtar, 2024).

En esta fase, la IA tiene la responsabilidad principal de identificar las causas de los problemas. El análisis basado en IA, como los modelos de machine learning, puede detectar factores clave que contribuyen a los defectos.

Estos modelos pueden identificar relaciones ocultas entre las variables de producción y los resultados de calidad. La IA y Big Data puede analizar automáticamente grandes volúmenes de datos, reconocer patrones complejos y realizar análisis predictivos para detectar los principales factores que generan desperdicio y fallos. Además, el análisis de causa raíz puede complementarse con IA para ofrecer información más detallada (Bukhari et al., 2024).

Mejorar: La IA facilita el diseño, las pruebas y la forma de implementar las soluciones. Los modelos predictivos de IA pueden anticipar la probabilidad de que ocurran defectos en lotes específicos utilizando datos previos, permitiendo identificar y revisar con anticipación (Bukhari et al., 2024). Los digital twins (gemelos digitales) de IA permiten simular procesos físicos para probar posibles cambios sin afectar las operaciones reales. El Aprendizaje por Refuerzo y los Algoritmos Evolutivos pueden utilizarse para optimizar procesos explorando diversas soluciones y eligiendo las más eficaces. Por ejemplo, las Redes Neuronales pueden mejorar la programación de la producción y la logística de la cadena de suministro (Sood & Dhull, 2024).

Controlar: La AI es fundamental para mantener las mejoras y prevenir la recurrencia de problemas. Los gráficos de Statistical Process Control (SPC) pueden mejorarse con AI para la detección de anomalías, permitiendo que los sistemas reconozcan cuando el rendimiento está disminuyendo y se realicen acciones tempranas (Bukhari & Akhtar, 2024). Los sistemas de alerta basados en IA pueden monitorear el proceso de producción en tiempo real e identificar cualquier desviación (Bukhari et al., 2024). La IA también puede crear circuitos de retroalimentación donde los parámetros del proceso se ajustan según las condiciones en tiempo real. Los algoritmos de mantenimiento preventivo, impulsados por IA, pueden rastrear el estado del equipo para prevenir tiempos de inactividad y mejorar la estabilidad del proceso (Bukhari & Akhtar, 2024).




Figura 3. Crecimiento IA.

Fuente. Gasto en Infraestructura de Inteligencia Artificial (Bloomberg, 2024).

En síntesis, la inteligencia artificial actúa como un apoyo clave a lo largo del ciclo DMAIC, como resultado identifica y da resolución a los problemas, proporcionando análisis más profundos, respaldando el desarrollo de soluciones más óptimas y de la misma forma aporta en la sostenibilidad, gracias al monitoreo y control continuo (Bukhari & Akhtar, 2024; Sood & Dhull, 2024). Esta integración está enfocada con los principios de la industria 4.0, aprovechando datos en tiempo real y sistemas inteligentes para optimizar procesos y mejorar el control de calidad predictivo.

En años recientes, la inversión en infraestructura de inteligencia artificial (IA) ha crecido exponencialmente, impulsada por grandes empresas tecnológicas. Se proyecta que el gasto en infraestructura de IA se duplicará entre 2023 y 2025, alcanzando los \$274 mil millones Figura 3. Esta tendencia sugiere que la inteligencia artificial será un pilar clave en la transformación digital en la industria.

Six Sigma tradicional vs. con IA y Big Data.

Tradicionalmente, Six Sigma se basa en herramientas estadísticas y principios de gestión de calidad aplicados a los datos recopilados para identificar y eliminar fuentes de errores e ineficiencias (Bukhari & Akhtar, 2024). La fase de medición a menudo implica la recopilación e interpretación de datos físicos, lo que puede llevar mucho tiempo y ser propenso a errores humanos. La fase de análisis utiliza métodos estadísticos para encontrar las causas fundamentales de los problemas, lo que puede ser un desafío con grandes conjuntos de datos (Parmar, 2022). La fase de control se centra en supervisar el rendimiento del proceso utilizando herramientas como gráficos de control estadístico de procesos (CEP) para garantizar la consistencia (Sood & Dhull, 2024).

Six Sigma integrado con Inteligencia Artificial (IA) y Big Data representa una evolución que mejora significativamente las capacidades y la eficacia de la metodología tradicional (Bukhari et al., 2024; Bukhari & Akhtar, 2024). Big Data proporciona grandes cantidades de datos en tiempo real de diversas fuentes, incluidos dispositivos IoT y sistemas de gestión empresarial (Diaz, 2024). La IA, en particular el machine learning y el deep learning, ofrece herramientas avanzadas para analizar estos datos, predecir resultados y automatizar acciones en todo el ciclo DMAIC.

Ahora bien, los beneficios clave de la integración son:

- Mayor rapidez y precisión en la detección de problemas (Bukhari & Akhtar, 2024; Sood & Dhull, 2024).

- Capacidades predictivas para reducir defectos y desperdicios (Bukhari et al., 2024).
- Escalabilidad y monitoreo continuo en toda la organización (Sood & Dhull, 2024).
- Optimización de recursos y sostenibilidad mediante analítica avanzada (Bukhari & Akhtar, 2024; Diaz, 2024).

En conclusión, si bien la metodología de Six Sigma tradicional proporciona un marco sólido para la mejora de procesos, la integración de IA y Big Data lo revoluciona al proporcionar herramientas potentes para gestionar grandes conjuntos de datos, obtener información más profunda, predecir resultados futuros y automatizar pasos importantes en el ciclo DMAIC. Esto se traduce en mejoras de calidad más rápidas, eficientes, precisas y sostenibles en comparación con el enfoque tradicional.

Six Sigma y su enfoque tradicional tiene una gran diferencia a cuando se aplica con IA. Cuando se aplican simultáneamente se obtiene una reducción significativa de defectos y mejora la eficiencia del proceso. La Figura 4 muestra cómo la implementación de IA ha incrementado la efectividad del mantenimiento predictivo, logrando una reducción de costos y tiempos de inactividad.

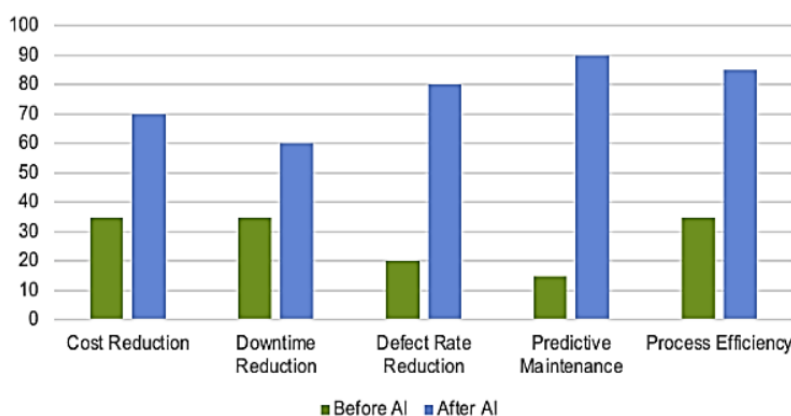


Figura 4. Six Sigma tradicional vs. con IA y Big Data.

Fuente. Comparación del impacto de la implementación de Inteligencia Artificial (Sood & Dhull, 2024).

Casos de Estudio y Aplicaciones Prácticas

Industria de jabón

Estudio de Shakir Bukhari en 2024 un caso de integración de Six Sigma e IA para mejorar la calidad y reducir el desperdicio en una industria de fabricación de jabones.

Problema: Defectos de calidad y alto desperdicio de materiales.

Solución: Se aplicó Six Sigma con herramientas de IA (aprendizaje automático) para identificar causas de defectos y predecir fallas.

Resultados: Reducción del 4.5% al 0.8% en defectos y 22% menos desperdicio (Bukhari et al., 2024).

Mantenimiento Predictivo con TensorFlow

Estudio de Anitej Chander Sood 1 y Konika Singh Dhull 2024, revisaron como TensorFlow, una herramienta de IA mejoro sus prácticas de mantenimiento.

Problema: Tiempo de inactividad por fallas en máquinas.

Solución: Uso de TensorFlow en el marco DMAIC de Six Sigma para predecir fallas mediante la revisión detallada de datos de sensores.

Resultados: Mantenimiento proactivo y reducción de paradas no planificadas.

Optimización de Cadena de Suministro

Estudio de Anitej Chander Sood 1 y Konika Singh Dhull 2024 revisaron como una organización abordo tecnologías de IA, en la arquitectura DMAIC de Six Sigma para abordar dificultades en su cadena de suministro, incluidos envíos retrasados y utilización ineficiente del almacén.

Problema: Retrasos en envíos y uso ineficiente de almacenes.

Solución: Integración de IA para analizar y optimizar datos de la cadena de suministro al instante.

Resultados: Mejoras en la entrega a tiempo y gestión de inventarios.

Fabricación de Semiconductores

Estudio de Tarun Parmar 2022 reviso como una fábrica de semiconductores mantenía rendimientos bajos.

Problema: Bajos rendimientos en nuevos diseños de chips.

Solución: Fusión de Six Sigma, modelos estadísticos e IA para optimizar el procesamiento de big data en entornos industriales.

Resultados: Aumento del 15% en el rendimiento de producción.

Fabricación Textil

Estudio de Rahaman, Md Saidur reviso los estudios de caso del fabricante.

Problema: Ineficiencias en procesos y alto consumo de recursos.

Solución: Implementación de IoT y IA junto con Lean Manufacturing y Six Sigma para optimizar procesos.

Resultados: Reducción del 20% en consumo de agua, 12% en energía y 18% en emisiones de carbono.

DISCUSIÓN Y ANÁLISIS DE RESULTADOS

1. Reducción del Tiempo de Análisis

La implementación de herramientas de IA, como el machine learning y el deep learning, permitió una reducción del tiempo de análisis en un 50%. Esto facilita una toma de decisiones más rápida y eficiente, alineándose con el objetivo de optimizar procesos y mejorar la eficiencia operativa.

2. Disminución de Defectos en Manufactura

El análisis predictivo basado en IA demostró ser efectivo para reducir defectos en manufactura. En el caso de la industria de jabones, la tasa de defectos disminuyó del 4.5% al 0.8%, mejorando significativamente la calidad del producto y reduciendo costos asociados.

3. Mejora en la Eficiencia Operativa

La automatización de tareas repetitivas mediante IA mejoró la eficiencia operativa. Por ejemplo, en el mantenimiento predictivo con TensorFlow, se redujo el tiempo de inactividad y se optimizaron recursos, generando ahorros en costos operativos.

4. Capacidad Predictiva y Sostenibilidad

La integración de IA y Big Data permitió anticipar fallos y reducir tiempos de inactividad. En la fabricación textil, el monitoreo en tiempo real redujo el consumo de agua en 20%, el uso de energía en 12% y las emisiones de carbono en 18%, fomentando la sostenibilidad.

5. Limitaciones y Desafíos

A pesar de los beneficios, se identificaron barreras como los costos elevados y la falta de capacitación en IA, Big Data con Six Sigma. Esto resalta la necesidad de invertir en formación para maximizar los beneficios de esta integración.

Al comparar el enfoque tradicional de Six Sigma con el integrado con Inteligencia Artificial y Big Data, se evidencian mejoras significativas en cada fase del ciclo DMAIC. En la fase Definir, la IA facilita la identificación rápida y precisa de problemas críticos mediante análisis avanzado de grandes conjuntos de datos provenientes de comentarios de clientes y procesos internos, algo que manualmente requeriría mucho más tiempo y recursos. Durante la fase Medir, la integración con IoT y análisis predictivo, permite la recolección y monitoreo de datos en tiempo real, mejorando sustancialmente la precisión y velocidad de las mediciones frente al método tradicional basado en muestreos periódicos. La fase Analizar se beneficia enormemente del uso de algoritmos de aprendizaje automático para descubrir patrones complejos y causas raíz en conjuntos de datos masivos, superando con creces las limitaciones de los métodos estadísticos convencionales. Asimismo, en la fase Mejorar, los modelos predictivos y los gemelos digitales impulsados por IA permiten evaluar múltiples escenarios potenciales de manera

virtual y anticipada, optimizando recursos y reduciendo riesgos operativos que el método tradicional, basado principalmente en prueba y error o pruebas piloto físicas, no puede igualar en eficiencia. Finalmente, en la fase de Controlar, los sistemas inteligentes facilitan la supervisión proactiva y la automatización del control de procesos mediante alertas tempranas y mantenimiento predictivo, reduciendo significativamente el riesgo de retrocesos o pérdida de mejoras, en comparación con los sistemas manuales o reactivos tradicionalmente empleados en Six Sigma.

CONCLUSIONES

La integración de Inteligencia Artificial (IA) y Big Data con la estrategia de Six Sigma figura una evolución importante en la mejora de procesos, permitiendo a las organizaciones alcanzar niveles más altos de eficiencia, calidad y sostenibilidad.

Sin embargo, la implementación de estas tecnologías no está libre de desafíos. Los costos elevados de infraestructura y la falta de capacitación son barreras que deben superarse para adquirir los beneficios de esta integración. Se recomienda a las organizaciones invertir en formación.

En conclusión, la combinación de Six Sigma con IA y Big Data no solo mejora la calidad y eficiencia de los procesos, sino que también fomenta la innovación y la sostenibilidad, posicionándose como una estrategia clave para la competitividad en la era de la Industria 4.0. Futuras investigaciones podrían explorar la aplicación de estas herramientas tecnológicas en pequeñas y medianas empresas (PYMES) y el uso de digital twins para la simulación y optimización de procesos.

A diferencia del enfoque tradicional, que depende en gran medida del análisis estadístico manual y supervisión humana, la integración con IA y Big Data permite una mejora continua automatizada, predictiva y escalable. Esta capacidad transforma Six Sigma en una herramienta clave para enfrentar los retos dinámicos de la Industria 4.0.

TRABAJO A FUTURO

A futuro, se espera un campo de trabajo amplio, enfocado en el desarrollo de modelos de IA que integren la lógica estructural de Six Sigma con algoritmos de aprendizaje automático (Machine Learning) y sistemas de análisis masivo de datos (Big Data Analytics). Este campo incluirá:

- Automatización del ciclo DMAIC mediante sistemas de IA capaces de ejecutar fases completas (definir, medir, analizar, mejorar y controlar) con mínima intervención humana.
- Desarrollo de plataformas digitales integradas (basadas en IoT, ERP y sensores inteligentes) que recopilen, analicen y optimicen datos en tiempo real en entornos industriales.

- Implementación de gemelos digitales y simulaciones avanzadas para probar cambios de procesos antes de su ejecución física.

Para este estudio de trabajo se requiere la colaboración entre ingenieros multidisciplinarios de procesos, de datos y en relacionados con la inteligencia artificial, así como una inversión continua en formación profesional y desarrollo tecnológico.

REFERENCIAS

- Albliwi, S., Antony, J., Lim, S. A. H., & van der Wiele, T. (2014). Critical failure factors of Lean Six Sigma: A systematic literature review. *International Journal of Quality & Reliability Management*, 31(9), 1012–1030. <https://doi.org/10.1108/ijqrm-09-2013-0147>
- Al-Rifai, M. (2025). Application of the DMAIC methodology and Lean Six Sigma (LSS) tools to improve recruitment cycle time. *Measuring Business Excellence*. <https://doi.org/10.1108/mbe-09-2024-0142>
- Antony, J., Sony, M., & Gutierrez, L. (2020). An empirical study into the limitations and emerging trends of Six Sigma: Findings from a global survey. *IEEE Transactions on Engineering Management*, 69(5), 2088–2101. <https://doi.org/10.1109/TEM.2020.2995168>
- Baiocchi, R., Lizot, M., & Santos, E. A. P. (2025). A review of quality improvement framework for Industry 4.0. *Procedia CIRP*, 132, 13–18. <https://doi.org/10.1016/j.procir.2025.01.003>
- Bloomberg. (2024). *AI infrastructure spending*. Bloomberg. <https://www.bloomberg.com>
- Bukhari, S. M. S., & Akhtar, R. (2024). Leveraging artificial intelligence to revolutionize Six Sigma: Enhancing process optimization and predictive quality control. *Contemporary Journal of Social Science Review*, 2(4), 1932–1948.
- Bukhari, S. M. S., Akhtar, R., ul Haq, I., & Saleem, M. A. (2024). Improvement of quality defects and wastage control in the ATN Soap Industry Peshawar through Six Sigma and artificial intelligence (AI). *Bulletin of Management Review*, 1(4), 126–143.
- Díaz, C. A. E. (2024). Beyond DMAIC: Leveraging AI and Quality 4.0 for manufacturing innovation in the Fourth Industrial Revolution. *Quality*, 63(12), 29–30.
- Fan, J., Han, F., & Liu, H. (2014). Challenges of big data analysis. *National Science Review*, 1(2), 293–314. <https://doi.org/10.1093/nsr/nwt032>

- Gutiérrez Pulido, H., & Vara Salazar, R. (2013). *Control estadístico de la calidad y Seis Sigma*. McGraw-Hill Education.
- Jiang, Y., Li, X., Luo, H., Yin, S., & Kaynak, O. (2022). Quo vadis artificial intelligence? *Discover Artificial Intelligence*, 2(1), 4. <https://doi.org/10.1007/s44163-022-00022-8>
- Khan, M., Wu, X., Xu, X., & Dou, W. (2017). Big data challenges and opportunities in the hype of Industry 4.0. En *2017 IEEE International Conference on Communications (ICC)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICC.2017.7996801>
- Kim, S. W., Kong, J. H., Lee, S. W., & Lee, S. (2022). Recent advances of artificial intelligence in manufacturing industrial sectors: A review. *International Journal of Precision Engineering and Manufacturing*, 23(1), 111–129. <https://doi.org/10.1007/s12541-021-00600-3>
- Malta, A. A. P., Santos, C. C. R., Santos, J. S., Silva, I. C., & Lopes, J. M. (2023). Lean Six Sigma: Aplicação de um roteiro DMAIC como ferramenta para redução do sobrepeso do pacote em uma indústria de biscoitos. *Observatorio de la Economía Latinoamericana*, 21(4), 2080–2100. <https://doi.org/10.55905/oelv21n4-019>
- Meyes, R., Donauer, J., Schmeing, A., & Meisen, T. (2019). A recurrent neural network architecture for failure prediction in deep drawing sensory time series data. *Procedia Manufacturing*, 34, 789–797. <https://doi.org/10.1016/j.promfg.2019.06.205>
- Navarro Albert, E., Gisbert Soler, V., & Pérez Molina, A. I. (2017). Metodología e implementación de Six Sigma. *3C Empresa: Investigación y Pensamiento Crítico*, 6(5), 73–80. <https://doi.org/10.17993/3cemp.2017.especial.73-80>
- Parmar, T. (2022). Structured problem-solving techniques for manufacturing datasets to enhance yield. *Journal of Artificial Intelligence, Machine Learning & Data Science*, 1(1), 2161–2166. <https://doi.org/10.51219/jaimld/tarun-parmar/473>
- Prabhushankar, G. V., Devadasan, S. R., Shalij, P. R., & Thirunavukkarasu, V. (2008). The origin, history and definition of Six Sigma: A literature review. *International Journal of Six Sigma and Competitive Advantage*, 4(2), 133–150. <https://doi.org/10.1504/ijssca.2008.020279>
- Shivaramu, P. (2025). *Optimizing manufacturing processes with predictive maintenance using machine learning and Lean Six Sigma*. [Manuscrito no publicado].

Sood, A. C., & Dhull, K. S. (2024). The future of Six Sigma—Integrating AI for continuous improvement. *International Journal of Innovative Research in Engineering & Management*, 11(5), 12–21. <https://doi.org/10.55524/ijirem.2024.11.5.2>

Tercan, H., & Meisen, T. (2022). Machine learning and deep learning based predictive quality in manufacturing: A systematic review. *Journal of Intelligent Manufacturing*, 33(7), 1879–1905. <https://doi.org/10.1007/s10845-022-01963-8>

TABLA TRABAJO COLABORATIVO

Rol	Autor (es)
Conceptualización	Trejo Muñoz Jesús Dolores, Pinto Santos Jorge Adolfo
Metodología	Trejo Muñoz Jesús Dolores, Pinto Santos Jorge Adolfo, Poblano Ojinaga Eduardo Rafael, Rodríguez Medina Manuel Arnoldo
Software	Trejo Muñoz Jesús Dolores, Gómez Zepeda Perla Ivette
Validación	Trejo Muñoz Jesús Dolores
Análisis Formal	Trejo Muñoz Jesús Dolores, Pinto Santos Jorge Adolfo
Investigación	Trejo Muñoz Jesús Dolores, Rodríguez Medina Manuel Arnoldo, Pinto Santos Jorge Adolfo
Recursos	Trejo Muñoz Jesús Dolores, Pinto Santos Jorge Adolfo
Curación de datos	Trejo Muñoz Jesús Dolores, Poblano Ojinaga Eduardo Rafael
Escritura - Preparación del borrador original	Trejo Muñoz Jesús Dolores, Rodríguez Medina Manuel Arnoldo
Escritura - Revisión y edición	Trejo Muñoz Jesús Dolores, Rodríguez Medina Manuel Arnoldo
Visualización	Trejo Muñoz Jesús Dolores, Gómez Zepeda Perla Ivette, Pinto Santos Jorge Adolfo
Supervisión	Trejo Muñoz Jesús Dolores, Gómez Zepeda Perla Ivette, Pinto Santos Jorge Adolfo
Administración de Proyectos	Trejo Muñoz Jesús Dolores, Gómez Zepeda Perla Ivette
Adquisición de fondos	Trejo Muñoz Jesús Dolores, Poblano Ojinaga Eduardo Rafael, Pinto Santos Jorge Adolfo