

Machine Learning and DMAIC to Improve the Production Process in the Industrial Sector: Systematic Literature Review

Peña Hernandez Marco Antonio, Estudiante Ingeniería Industrial¹; Leiva Piedra Jorge Luis, Magister en Protección de Cultivos²; Tenorio Ortiz Yenny Analí, Magister en Docencia Universitaria y Gestión Educativa³
^{1,2,3}Universidad Tecnológica del Perú, Perú, u20235499@utp.edu.pe, jleiva@utp.edu.pe, ytenorio@utp.edu.pe

Abstract- *The growing need to optimize processes in the industrial sector has driven the adoption of new approaches based on data analysis, systematization, and interpretation. This systematic literature review aims to analyze how machine learning and the DMAIC method have been developed to improve production processes in the industrial sector. To this end, the PICOC method was used to identify search keywords and questions for subsequent analysis. The search was conducted in Scopus and Web of Science, and inclusion and exclusion criteria were applied. The PRISMA method was used to systematize the screening system, and 42 articles were selected. The results show a decrease from 16,066 to 119 DPOM and an accuracy of 98.8% in the coefficient of determination (R^2) by the K-Nearest Neighbors (KNN) model. Advantages such as process standardization, fault prediction, and quality improvement were identified. Despite this, organizational, technical, and social challenges were also reported, such as organizational resistance to change, lack of trained personnel, and the need to ensure data security. It was concluded that the integration of Machine Learning with DMAIC is an effective strategy for continuous improvement, provided that it is accompanied by technologies such as IoT and sensors, as well as the proper use of tools such as FMEA, VSM, and control charts.*

Keywords- *Machine Learning, DMAIC, Industry, Production Process*

Machine Learning y DMAIC para mejorar el proceso productivo en el Sector Industrial: Revisión Sistemática del Literatura

Peña Hernandez Marco Antonio, Estudiante Ingeniería Industrial¹; Leiva Piedra Jorge Luis, Magister en Protección de Cultivos²; Tenorio Ortiz Yenny Analí, Magister en Docencia Universitaria y Gestión Educativa³
^{1,2,3}Universidad Tecnológica del Perú, Perú, u20235499@utp.edu.pe, ytenorio@utp.edu.pe, jleiva@utp.edu.pe

Resumen— La creciente necesidad de optimizar procesos en el sector industrial ha impulsado la adopción de nuevos enfoques basado en el análisis, sistematización e interpretación de datos. La presente revisión sistemática de literatura tiene como objetivo analizar como el Machine Learning y el método DMAIC, han venido desarrollándose para mejorar los procesos productivos en el sector industrial. Para ello, se utilizó el método PICOC, con el objetivo de identificar las palabras claves de búsqueda y las preguntas para el posterior análisis, la búsqueda se hizo en Scopus y Web of Science, y se aplicaron criterios de inclusión y exclusión, se utilizó el método PRISMA para sistematizar el sistema de cribado, seleccionándose 42 artículos. Los resultados muestran una disminución de 16066 a 119 DPOM y hasta una precisión en 98.8% del Coeficiente de Determinación (R^2) por parte del modelo K-Nearest Neighbors (KNN). Se identificaron ventajas como como la estandarización de procesos, la predicción de fallas y mejora de calidad. A pesar de ello, también se reportan desafíos organizacionales, técnicos y sociales, como la resistencia organizacional al cambio, la falta de personal capacitado y la necesidad de garantizar la seguridad de los datos. Se concluyó que la integración de Machine Learning con DMAIC es una estrategia eficaz para la mejora continua, siempre que se acompañe con tecnologías como IoT y sensores, así como del uso adecuado de herramientas como FMEA, VSM, y gráficos de control.

Palabras clave— Aprendizaje Automático, DMAIC, Industria, Proceso productivo

I. INTRODUCCIÓN

La creciente competencia global amenaza la competitividad de las empresas, pues muchas no logran cumplir con los estándares de calidad debido a procesos ineficientes [1]. Esta situación se ha intensificado con la Cuarta Revolución Industrial, que ha traído una mayor complejidad y un volumen masivo de datos, superando la capacidad de metodologías tradicionales como Lean Six Sigma (LSS) [2]. En este sentido, aunque la industria 4.0 promete mejoras significativas, su adopción se ve limitada por la falta de enfoques estandarizados, lo que dificulta su integración con marcos como LSS [3]. Estas limitaciones están directamente relacionadas con la estructura del enfoque DMAIC (Definir, Medir, Analizar, Mejorar, Controlar) que, si bien es sistemático, no responde con eficacia a los desafíos de entornos cambiantes y altamente exigentes [4]. Esto se hace aún más evidente con la creciente demanda de la

transformación digital, que exige productos más personalizados, de mayor calidad y en menos tiempo [5]. Por ejemplo, en la industria manufacturera, este panorama es aún más crítico, a pesar de representar entre el 10% y el 30% del PIB y en países industrializados, enfrenta una marcada falta de innovación y pese a que el 66% de las empresas reconoce el impacto potencial de herramientas de la industria 4.0, donde solo el 16% ha iniciado su implementación, el 20% apenas la planifica y un 63% ni siquiera ha comenzado, lo que refleja una falta generalizada de visión y preparación [4], [6].

DMAIC es una metodología que permite a las empresas ser más competitivas al mejorar la capacidad de los procesos, incrementar la calidad de procesos y aumentar la satisfacción del cliente [7]. Como parte de ello se centrada en la mejora de la calidad de procesos existentes, definir el problema a mejorar, medir el proceso para generar una base de datos, analizar la información recopilada para identificar oportunidades de mejora, aplicar las mejoras que correspondan y establecer un método de eficaz de control [8]. Por otra parte, Machine Learning (ML) es una herramienta facilita el análisis de datos, por medio de la identificación de patrones de forma automatizada [9]. Además, puede ser utilizado como una herramienta predictiva de la calidad de un producto, que en combinación con la metodología DMAIC permite identificar las causas de problemas de producción [10]. Aun que se destaca la posibilidad de utilizar dicha metodología para incrementar la calidad de los procesos, también puede ser utilizada con el fin de reevaluar la calidad necesaria para evitar pérdidas económicas, por los altos costes que pueden implicar mantener cierto nivel de calidad para una empresa [11].

Por ello la revisión sistemática de tiene como objetivo analizar el impacto de la integración de Machine Learning con la metodología DMAIC en la mejora de proceso productivo en el sector industrial, identificando las dificultades del control de procesos, determinar ventajas y desventajas de los enfoques y dar a conocer los desafíos que enfrenta la industria para la implementación.

II. METODOLOGÍA

En la elaboración del presente trabajo de investigación se desarrolló una metodología basada en una Revisión Sistemática

de Literatura el cual consiste en la aplicación del método PICOC con la finalidad de plantear la siguiente pregunta de revisión: ¿Cuál es el impacto de la integración de Machine Learning con la metodología DMAIC en la mejora de procesos productivos dentro del sector industrial?, pregunta asociada a los componentes tal como se muestra en la tabla 1.

TABLA I
ESTRUCTURA PICOC

Estructura PICOC	Preguntas
P	¿Cuáles son las dificultades de controlar los procesos productivos en el sector industrial en la actualidad?
I	¿Cómo Machine Learning y/o la metodología DMAIC permite la mejora de procesos productivos?
C	-
O	¿Qué ventajas y desventajas genera Machine Learning, la metodología DMAIC y su integración en la mejora de procesos productivos?
C	¿Qué desafíos enfrenta el sector industrial para la integración de Machine Learning con la metodología DMAIC para la mejora de procesos productivos?

A continuación, en la tabla II se mostrará de manera resumida la metodología utilizada para el desarrollo de la RSL.

TABLA II
METODOLOGÍA DE BÚSQUEDA UTILIZADA

Criterios de búsqueda	Parámetros para la búsqueda de información
Pregunta de investigación	¿Cuál es el impacto y el nivel de eficacia de la integración de Machine Learning con la metodología DMAIC en la mejora de procesos productivos dentro del sector industrial, y cómo ha sido definido y observado su éxito en diversas organizaciones?
Palabras claves empleadas para la búsqueda	Control, “production process”, “machine learning”, DMAIC, enhanced, “process improvement”, integration, industry.
Base de datos	Scopus y Web of Science.
Periodo de selección	2020 – 2024.
Idioma	Inglés.
Área	Ingeniería.
Tipo de documento	Artículo científico.
Accesibilidad	Acceso abierto.

Se seleccionó términos clave para limitar los resultados de búsqueda de artículos. La tabla 3 presenta las fórmulas de búsqueda.

TABLA III
FÓRMULAS DE BÚSQUEDA EN SCOPUS Y WEB OF SCIENCE

SCOPUS	(TITLE-ABS-KEY (control OR "production process") AND TITLE-ABS-KEY ("machine learning" OR dmaic) AND TITLE-ABS-KEY (enhanced OR "process improvement" OR integration) AND TITLE-ABS-KEY (industry)) AND PUBYEAR > 2020 AND PUBYEAR < 2024 AND (LIMIT-TO (OA , "all")) AND (LIMIT-TO (DOCTYPE , "ar")) AND (LIMIT-TO (SUBJAREA , "ENGI")) AND (LIMIT-TO (LANGUAGE , "English"))
WOS	control OR "production process" (Tema) and "Machine Learning" OR dmaic (Tema) and enhanced OR "process improvement" OR integration (Tema) and industry (Tema) and 2024 or 2023 or 2022 or 2021 or 2020 (Años de publicación) and Artículo (Tipos de documentos) and

English (Idiomas) and Todos los artículos de acceso abierto (Acceso abierto) and Engineering (Áreas de investigación)

En la figura 1 se mostrará el diagrama de flujo Prisma realizado para su selección.

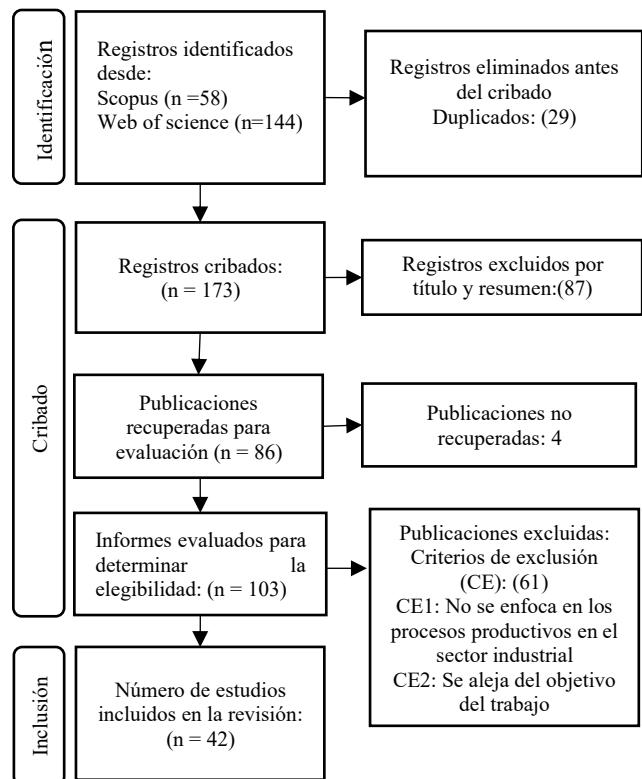


Fig.1 Flujograma Prisma

III. RESULTADOS

A. Evaluación de Machine Learning y DMAIC según los países de origen de publicación

La Fig.2, muestra la asignación de la literatura incluida en la revisión de forma porcentual en base a su país de origen de publicación. En la figura se aprecia una alta cantidad de publicaciones de países europeos, con un valor aproximado de 81% de artículos publicados destacando los países como Suiza (33.3%) y Países Bajos (19.0%). Por debajo de esos dos países, Estados Unidos (16.7%) se posiciona como el tercer país con mayor cantidad de publicaciones. Con ello se refleja el alto interés de países desarrollados por mejorar procesos productivos.

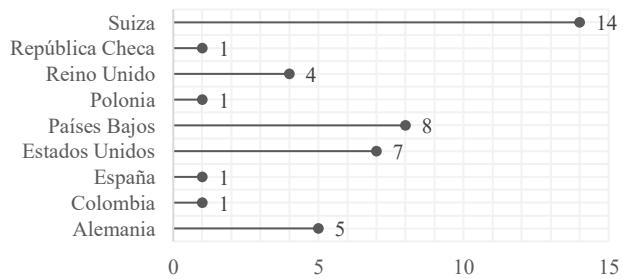


Fig.2 Número de publicaciones por países sobre mejora de procesos mediante la aplicación de Machine Learning y DMAIC 2020 - 2024.

B. Dificultades de controlar los procesos productivos en el sector industrial

El control manual o tradicional de procesos frente a una gran cantidad de factores dificulta la toma de decisiones de producción [12] la misma forma, las variables no controladas o inesperadas, junto a su interacción con otras variables, crean un entorno de control desafiantes [13]. Un control inadecuado no solo resulta en la generación de desperdicios y defectos del producto final, sino que también en el desperdicio de material, energía y esfuerzo de producción afectando la calidad, eficiencia y costo de producción [10]. La tabla IV muestra las dificultades que tiene distintas industrias para controlar los procesos productivos.

En la industria automotriz, el ensamblaje automatizado enfrenta retos relacionados a la coordinación entre el trabajo humano y robot en la producción, a causa de la falta control predictivo de los insumos de fabricación, decisiones descentralizadas, trazabilidad compleja [14]. Además, el diseño e implementación de la arquitectura electrónica presenta dificultades debido a la migración de tareas entre Unidades de Control Electrónico (ECUs), ya que las ECUs tradicionales sufren sobrecarga y no se adaptan automáticamente y presentan incompatibilidad entre arquitecturas [15].

En la manufactura, el monitoreo de la producción de cemento enfrenta dificultades para diagnosticar fallas en tiempo real y predecir la necesidad de mantenimiento debido a variaciones súbitas en los sensores, mantenimiento tardío e interrupciones inesperadas [12]. En la fabricación de juntas para transistores, se complica encontrar la combinación óptima de parámetros de fabricación mientras se mantiene un nivel constante de calidad, debido a la variabilidad en dimensiones como diámetro, altura o excentricidad [13]. En la producción de jarabe de maíz, mantener constantes las variables de calidad representa un desafío a lo largo del proceso debido a un bajo control sobre las mismas, así como a la falta de automatización [16]. El ensamblaje robótico enfrenta la dificultad de mejorar el reconocimiento en tiempo real de eventos de producción como la toma, ubicación y alineación de objetos, ya que los sistemas tradicionales tienen una la baja capacidad de para interpretar escenas complejas y convertirlas en acciones [17]. El moldeo por inyección de plásticos presenta dificultades para llenar completamente el molde debido a la variabilidad de parámetros como presión, velocidad y temperatura [18]. La producción de piezas se ve afectada por la necesidad de rediseñar herramientas de mecanizado debido a una selección errónea de las mismas para la variabilidad térmica, lo que se debe a la falta de estandarización, dependencia del operador y desconexión entre procesos [19]. El control de calidad se ve comprometido por la detección tardía de defectos, debido a procesos desconectados y la falta de integración con sistemas de ciberseguridad y modelos predictivos [20]. Finalmente, el maquinado por control numérico (CNC) puede presentar una alta tasa de defectos debido al calibrado manual y la falta de monitoreo, lo cual se debe a la ausencia de digitalización y la falta de un control sistemático de calidad [21].

En la industria energética, el proceso de producción en reservorios de gas condensado con el método CCS-EOR

enfrenta dificultades para gestionar el flujo de inyección y producción debido a que el proceso se optimiza de forma manual [22]. En la generación, almacenamiento y distribución de energía renovable, el reto es controlar la generación y demanda debido a la intermitencia de las fuentes renovables, sumado a la incertidumbre en el consumo energético por la falta de sistemas que integren la medición, predicción y optimización de la energía [23].

TABLA IV
DIFICULTADES DEL SECTOR INDUSTRIAL PARA CONTROLAR LOS PROCESOS PRODUCTIVOS

Industria	Proceso	Dificultad	Cita
Agroindustria	Monitoreo y Gestión de cultivos en invernadero inteligentes	Variaciones ambientales complejas de medir y correlacionar de forma automatizada	[24], [25]
Industria Automotriz	Ensamble automatizado de automóviles	Coordinar el trabajo humano-robot en la producción	[14]
	Diseño e implementación de arquitectura electrónica	Migración de tareas de un ECU (unidad de control electrónico) a otro	[15]
Industria Manufacturera	Monitoreo de producción de cemento	Diagnosticar fallas en tiempo real y predecir mantenimiento	[12]
	Fabricación de juntas para transistores	Encontrar la combinación óptima de parámetros de fabricación manteniendo un nivel de calidad constante	[13]
	Producción de jarabe de maíz	No se mantiene constantes los valores de dextrosa y pH a lo largo del proceso	[16]
	Ensamble robótico	Mejorar el reconocimiento en tiempo real de eventos de producción (tomar, ubicar, alinear) que realiza el robot	[17]
	Moldeo por inyección de plásticos	No se llena completamente el molde de inyección (defecto short-short)	[18]
	Producción de piezas	Necesidad de rediseñar herramientas de mecanizado	[19]
	Control de calidad	Detección tardía de defectos	[20]
	Fabricación por CNC	Alta tasa de defectos	[26]
	Paradas anuales para mantenimiento general	Reduce la temporada productiva de invierno	[21]
	Control de producción de petróleo	Optimizar el control de pozos al realizar CO ₂ -EOR (La Recuperación Mejorada de Petróleo con Dióxido de Carbono)	[22]
Industria Energética	Generación, almacenamiento y distribución de energía renovable	No se gestiona adecuadamente la generación y demanda de fuentes renovables por su intermitencia	[23]
Industria de la Información y Comunicaciones	Diseño de sistemas de comunicación	Optimizar el tráfico y el rendimiento energético al generar, transmitir y distribuir datos	[27]

C. Mejoras de procesos productivos por medio de Machine Learning y la metodología DMAIC

En la tabla V se muestran las mejoras. La aplicación de la metodología DMAIC permitió una reducción del 41 % en la sobreproducción, lo que demuestra una mejora en la eficiencia operativa, al reducir el desperdicio de sobreproducción se gestiona mejor los inventarios, se reduce costos y mejora la rentabilidad [28]. La reducción de la tasa e defectos hasta en 1.5%, representa una mejora de calidad del producto final, lo que conlleva a la reducción de desperdicios, evitar costos de retrabajo y prevenir disconformidad con el cliente [21], [26]. El aumento hasta el 15% en la capacidad de producción no solo influye en una mayor eficiencia operativa y en un mejor aprovechamiento de recursos, sino que también posibilita satisfacer una mayor demanda e incrementar los ingresos [19], [26]. La reducción del tiempo ciclo de producción en 25% se asocia con una mayor eficiencia operativa, agilizando la entrega del producto al cliente, al mismo tiempo, se incrementa la capacidad de respuesta a la demanda del mercado [26].

Por otra parte, la implantación de ML ha resultado en una reducción aproximada del 25.2% en el consumo total del modelo analizado por medio de la implementación de Inteligencia Artificial Federada (FIA) y el Límite de Umbral de Confianza (TLL), en ese contexto, un ajuste y control de parámetros operativos a través de FIA se reduce el desperdicio de recursos mediante modelos de ML [14]. En un modelo simulado, se registró un aumento de producción de petróleo en

3.5%, en el que pese a ser un valor porcentual modesto puede representar un volumen de producción significativo en la práctica [22]. Por último, la integración de ML y DMAIC, resultó en la reducción de defectos por millón de oportunidades (DPMO) de 16066 a 119 en el proceso de fabricación al optimizar la calidad del proceso [10].

D. Ventajas y desventajas de Machine Learning y DMAIC en la mejora de procesos productivos

En cuanto a las ventajas competitivas que se generan, la mejora de calidad de producto es el resultado de una mejor gestión en el control de calidad y una reducción de defectos, esta última, a su vez ahorro de recursos debido a que reduce el desperdicio de recursos como materiales y energía [10], [18], [29]. La automatización, cada vez más hace menos necesaria la intervención humana, y junto con el monitoreo de recursos contribuyen con la detección temprana de anomalías [12], [30]. Todo ello contribuye con la reducción de costos operativos al evitar los reprocesos [31], [32].

Respecto a las desventajas la dependencia de la calidad de los datos y el riesgo de sobreajuste de datos puede comprometer la precisión y fiabilidad de las predicciones [33]. Además del alto costo de implementación y la vulnerabilidad ante ciberataques representan barreas estructurales que dificultan la adopción de tecnologías [25], [26]. En la tabla V se muestran las ventajas y desventajas.

TABLA V
MEJORAS, VENTAJAS Y DESVENTAJAS DE MACHINE LEARNING Y DMAIC

Tipo de enfoque	Mejoras	Cita	Ventajas	Cita	Desventajas	Cita
DMAIC	Disminución de sobre producción en 41%	[28]	Mejora de calidad	[10], [13], [19], [34], [35], [36]	Riesgo de limitar la innovación y creatividad	[37]
	Reducción de defectos hasta en 1.5%	[21], [26]				
	Aumento de la capacidad de producción hasta en 15%	[19], [26]	Estandarización de procesos	[13], [19], [26]		
	Reducción de tiempo ciclo de producción en 25 %	[26]	Reducción de variabilidad	[13], [28], [36]		
Machine Learning	Reducción de consumo de energía en 25.2% por modelo diseñado	[14]	Automatización	[12], [34]	Dependencia de datos de calidad	[33]
	Aumento de producción en 3.5% en simulación	[22]	Predicción de fallas, tendencias y demanda	[12]	Sobreajuste de datos	[38]
			Flexibilidad y adaptabilidad al cambio	[15], [34], [39]	Vulnerabilidad ante ciberataques	[40]
DMAIC y ML	Reducción de DPMO de 16066 a 119	[10]	Ahorro de costo	[14], [15], [39], [41]	Alto costo de implementación	[26]
			Análisis y toma de decisiones basado en datos	[34], [35]	No soluciona todos los problemas	[25]

E. Modelos de Machine Learning

Los tipos de aprendizaje en ML puede ser supervisado debido a que el modelo aprende a partir de datos etiquetados, pudiéndose utilizar para clasificar otros datos no etiquetados [42]. El aprendizaje no supervisado permite que el modelo identifique patrones en datos sin etiquetas, siendo usado para realizar tareas de agrupamiento [43]. Por otro lado, el aprendizaje semi supervisado combina datos etiquetados y no etiquetados para su entrenamiento, es una alternativa más

simple de implementar, barata y requiere de menos tiempo a comparación del aprendizaje supervisado tradicional [44]. En el caso del aprendizaje por refuerzo, el modelo aprende por ensayo y error [45]. Con relación a los tipos de tarea, pueden ser regresivas al predecir valores continuos, o en calificativos, al predecir clases o categorías, como por ejemplo bueno y malo o defectuoso y no defectuoso [46], [47].

En la optimización de procesos de fabricación mediante la integración de la metodología DMAIC con técnicas de ML se valuyeron modelos de Linear Regression (LR), Artificial Neural

Network (ANN), Decision Tree (DT), K-Nearest Neighbors (KNN) y Análisis de Clúster (CA) siendo el modelo KNN fue seleccionado debido a su desempeño superior en las métricas de rendimiento evaluadas, obteniendo un error cuadrático medio (RMSE) de 0.102, un error absoluto medio (MAE) de 0.001, un Error Absoluto Medio Porcentual (MAPE) con 0.32 y un Coeficiente de Determinación (R^2) de 98.8% [10].

Se evaluaron los modelos Linear Regression (LR), Decision Tree Regression (DTR), Random Forest Regression (RFR), Support Vector Regression (SVR) y Gradient Boosting

Regression (GBR) mejorando la Efectividad General del Equipo (OEE) del 44.4% al 50% al seleccionar el modelo RFR, al cual obtuvo valores de 0.7 en Error Absoluto Medio (MAE), 1.5 en Error Cuadrático Medio (MSE), 1.22 en Raíz del Error Cuadrático Medio (RMSE) y 0.93 en el Coeficiente de Determinación (R^2) siendo elegido frente al modelo GBR, que también desató como una opción viable para contribuir a la mejora OEE [4]. En la tabla VI se muestran los modelos de Machine Learning.

TABLA VI
MODELOS DE MACHINE LEARNING

Tipo de Modelo	Modelo	Tipo de aprendizaje	Tipo de tarea	Descripción	Cita
Arboles de decisión	Decisión Tree Classifier (DTR)	Supervisado	Clasificación	Clasifica los datos dividiéndolos en ramas según condiciones	[4], [10], [33], [34]
	Extra Trees Regressor (ETR)	Supervisado	Regresivo	Combina varios árboles aleatorios para hacer predicciones rápidas y variadas	[32]
	Random Forest Regressor (RFR)	Supervisado	Regresivo	Combina varios árboles de decisión para obtener predicciones más estables y precisas	[32]
	AdaBoost y AdaBoost Regressor	Supervisado	Clasificación, Regresivo	Combina varios modelos simples, dándoles más peso a los que corrigen errores previos	[32]
	XGBoost	Supervisado	Clasificación, Regresivo	Optimiza múltiples árboles de decisión para clasificar eventos críticos y para refinar de forma regresiva predicciones de otros modelos	[20], [32]
	Gradient Boosting Regression (GBR)	Supervisado	Regresivo	Refina predicciones y valores medidos	[4]
Redes Neuronales	Artificial Neural Network (ANN)	Supervisado	Regresivo	Predice ocurrencia de defectos	[10], [16]
	Deep Q-Networks (DQN)	Por refuerzo	Regresivo	Aprende a seleccionar acciones óptimas mediante recompensas futuras	[39]
	Multiplayer Perceptron (MLP)	Supervisado	Clasificación	Clasifica defectos mediante patrones aprendidos	[40]
	Convolutional Neural Network (CNN)	Supervisado	Clasificación, Regresión	Clasifica imágenes o predice valores continuos a partir de imagen	[34]
	Long Short-Term Memory (LSTM)	Supervisado	Clasificación	Predice la variabilidad de tareas en sistemas embebidos	[15]
	Nonlinear Autoregressive Exogenous Neural Network (NARXN)	Supervisado	Regresivo	Predice comportamientos futuros	[29]
	Spiking Neural Network (SNN)	Supervisado	Clasificación	Aprende a tomar decisiones identificando patrones	[15]
	Twin Delayed DDPG (TD3)	Por refuerzo	-	Optimiza decisiones basadas en recompensas	[48]
Modelos Lineales	Linear Regresión (LR)	Supervisado	Regresivo	Encuentra la relación más simple entre variables para predecir valores	[4], [10], [16], [34]
	Logistic Regression	Supervisado	Clasificación	Usado para clasificar eventos anómalos	[33]
	Support Vector Regression (SVR)	Supervisado	Regresivo	Predice valores manteniendo los errores dentro de un margen aceptable	[4]
Vecinos más cercanos	K-Nearest Neighbors (KNN)	Supervisado	Clasificación, Regresión	Clasifica eventos críticos mediante comparaciones y ayuda a refinar predicciones regresivas	[10], [12]
Máquina de soporte vectorial (SVM)	Support Vector Machine (SVM)	Supervisado	Regresivo, Clasificación	Clasifica eventos críticos y refinas predicciones regresivas	[16], [35], [49]

F. Herramientas y complementos DMAIC

Son diversas la herramientas y complementos de DMAIC que favorecen su integración con ML, como se muestra en la Tabla VII. El gráfico de control se empleó para supervisar el comportamiento de un proceso a lo largo del tiempo, facilitando posibles desviaciones respecto a su comportamiento esperado [28]. Asimismo, Multi-characteristic process capability

analysis chart (MPCAC digitalizado), fue empleado para evaluar la capacidad del proceso considerando simultáneamente varias características de calidad [10], [13]. El diagrama de Pareto facilitó la identificación de las principales causas que contribuían a los defectos en el proceso, priorizando los problemas más críticos [28]. El mapa de flujo de valor (VSM) permitió visualizar actividades que no agregan valor y

cuellos de botella que afectaban la eficiencia general del proceso [28].

G. Tecnologías complementarias

Respecto a las tecnologías presentadas, se observa que Smart Meters cumple con el papel de capturar de forma continua de datos del proceso, proporcionando información a los modelos de ML en tiempo real. Por otro lado, Big Data y Cloud Computing facilitan el procesamiento, almacenamiento y análisis de una gran cantidad de datos, siendo decisivo para identificar patrones y establecer relaciones entre las variables y sus consecuencias. El uso de Digital Twins permite simular virtualmente escenarios de mejora y validar modelos predictivos. Asimismo, Internet of Things actúa como medio que garantiza la conectividad y el intercambio de información continuo de entre dispositivos, máquinas y sistemas inteligentes. Para culminar, Blockchain funciona como un mecanismo que garantiza la integridad y trazabilidad de datos, asegurando su confiabilidad.

H. Integración de Machine Learning con la Metodología DMAIC

Machine Learning a través de técnicas de agrupación y clasificación permite identificar patrones y anomalías de una gran cantidad de datos históricos de producción [50]. Seguido de la medición de los datos, los sistemas de Internet de las Cosas (IoT) permiten la recolección constante de datos que incluyen variables del proceso, rendimiento de equipos y calidad del producto necesarios para entrenar modelos de ML [27]. Los resultados de las predicciones y la relación entre variables pueden ser usados para simular y establecer condiciones óptimas de operación [51]. Por último, los modelos de ML pueden ser integrados en sistemas de control en tiempo real con el fin de monitorear las variables de los procesos garantizando que las mejoras implementadas sean sostenibles y el proceso se mantenga el nivel de calidad deseado y la eficiencia a largo plazo [52], [53]. En la tabla VII se muestran las herramientas y complementos, tecnologías e integración de ML.

TABLA VII
HERRAMIENTAS Y COMPLEMENTOS, TECNOLOGÍAS E INTEGRACIÓN DE ML

Fase	Herramientas y complementos DMAIC	Cita	Tecnologías complementarias	Cita	Integración de ML	Cita		
Definir (Define)	5 porqué	[19]	-	-	Identificación de problemas y objetivos a través de análisis de datos históricos de producción y métricas clave por medio de ML.	[50]		
	SIPOC	[10], [26], [28], [36]						
	Vocal del cliente (VoC)	[4], [26], [28]						
	Diagrama de Pareto	[28]						
	Método Delphi	[36]						
Medir (Measure)	Multi-characteristic process capability analysis chart (MPCAC)	[10], [13]	Smart Meters	[50]	Recopilación de datos en tiempo real para el posterior análisis y predicción por parte de los modelos de ML.	[16], [27]		
	Mapa de flujo de valor (VSM)	[28]	Sensores	[54]				
	Gráfico de control	[28]	Internet of Things (IoT)	[25]				
	Índice de Sostenibilidad en la Manufactura (MSI)	[36]						
Analizar (Analyze)	ANOVA	[10], [19]	Big Data Analytics	[39], [52]	Aplicación de modelos de ML para identificar las causas raíz de los problemas y predecir comportamientos.	[31], [32]		
	Espina de Ishikawa	[26], [28]	Cloud Computing	[39], [55]				
	Análisis de Modos y Efectos de Fallas (FMEA)	[28]						
Mejorar (Improve)	Taguchi	[13], [26]	Digital Twin	[31], [32]	Combinación de modelos de ML para mejorar la calidad o reducir fallos.	[51]		
	Lean							
	Gantt	[26]						
	Simulaciones	[26]						
	5W1H y 5W2H	[26], [28]						
	Kaisen	[28]						
Controlar (Control)	Gráficos de control	[10], [26], [28]	Blockchain,	[20]	Monitoreo continuo del proceso utilizando modelos de ML para corregir desviaciones y maximizar el desempeño.	[52], [53]		
	Poka Yoke	[26]						
	Lista de Verificación	[26]						
	Estandarización	[26]						
	KPIs	[28]						

I. Desafíos de Machine Learning con la metodología DMAIC para su integración en la mejora de procesos productivos

Los desafíos incluyen la falta de recursos que garanticen implementación ML y DMAIC, además la falta de capacitación y experiencia técnica del personal dificulta la correcta interpretación de los modelos y metodologías,

evidenciando también una resistencia cultural al cambio, respecto a la preferencia de métodos tradicionales y la desconfianza de soluciones, la falta de estrategias para la recolección, limpieza, integración y análisis de datos, para finalizar se debe considerar el uso de herramientas de protección ante vulnerabilidades que garanticen la integridad

de los datos. [10], [19], [26]. En la tabla VIII se muestrea los desafíos de la integración de Machine Learning con la metodología DMAIC.

TABLA VIII
DESAFÍOS DE LA INTEGRACIÓN DE MACHINE LEARNING CON LA METODOLOGÍA DMAIC

Desafíos de integración		Cita
Escasez de recursos	Falta de inversión en hardware y software, disponibilidad de colaboradores y restricciones de tiempo	[10], [19], [26]
Falta de capacitación y experiencia	Dificultad en contar con colaboradores con experiencia en Machine Learning y Six Sigma	[26]
Resistencia cultural	Resistencia al cambio en la cultura organizacional	[26]
	Resistencia organizacional por reemplazar prácticas tradicionales con soluciones tecnológicas	[26]
Falta de aprovechamiento de datos	No se procesa y analiza la totalidad de los datos medidos	[25]
Seguridad de datos	Garantizar la seguridad e integridad de los datos.	[26], [33]
Sociales	Exclusión de colaboradores por la automatización de procesos o falta de competencias en el uso de tecnologías	[56]

IV. DISCUSIÓN

A. Evaluación de Machine Learning y DMAIC según los países de origen de publicación

Si bien los resultados muestran una alta concentración de publicaciones en países europeos como suiza y países bajos, seguido de estados unidos, es posible que esta distribución se deba a la selección de publicaciones en lengua inglesa dejando fuera publicaciones de países con menor difusión de investigaciones en el idioma inglés.

B. Dificultades en procesos productivos

En este análisis se identifican varias dificultades en el control, monitoreo y optimización de procesos en el industrial, en el que la implementación de sistemas inteligentes ha permitido mejoras en la trazabilidad y el control de la calidad en la producción [14]. Aún que existen casos en los que persiste una desconexión entre sistemas físicos y digitales [20].

C. Mejoras, ventajas y desventajas de por medio de Machine Learning y DMAIC.

La aplicación de DMAIC permitió mejoras la eficiencia operativa como la reducción del 41% de sobreproducción y 25% en tiempo ciclo [26], [28]. En calidad se logró reducir la tasa de defectos hasta en 1.5%, evitando retrabajos y desperdicios [21], [26].

El uso de ML contribuyó a la reducción del 25.2% en el consumo de recursos [14]. La integración de resultó en una disminución de DPMO de 16066 a 119 [10].

Entre las ventajas se destaca la automatización, el control de calidad mejorado y la detección temprana de fallas [10], [12]. Sin embargo, la dependencia de datos de calidad, el riesgo de sobreajuste, altos costos y vulnerabilidad a ciberataques representan desventajas relevantes para la implementación [26], [33], [38], [40].

D. Modelos de Machine Learning

En la optimización de procesos de fabricación mediante la integración de la metodología DMAIC con técnicas de ML, después de detectar y procesar fallos con el objetivo de determinar la causa raíz del problema se realizó una comparación de modelos, seleccionando a KNN debido sus resultados a las evaluaciones de RMSE, MAE, MAPE y R² [10]. En comparación a la integración que se realizó en la Industria de Bebidas, quien selección al modelo no solo por sus buenos resultados numéricos en la evaluación de MAE, MSE, RMSE y R², sino que también por su fácil integración en los sistemas existentes, su buen rendimiento y confiabilidad [4].

E. Herramientas y complementos DMAIC

Distintos autores asignan distintas herramientas y complementos de forma diferente en las distintas fases de DMAIC, siendo el caso del Diagrama de Pareto no solo se ha utilizado en la fase de en medir, también se ha utilizado en la fase de definir [10], [28]. Similar a ello, FMEA no solo se ha utilizado en la fase de analizar, también se ha aplicado en la fase de definir [28], [36]. Por otra parte VSM se ha incorporado en la fase de definir y en la fase de medir evidenciando la flexibilidad del uso de las herramientas y complementos dependiendo del objetivo y necesidades de cada caso de estudio [28], [53].

F. Tecnologías complementarias e integración de Machine Learning con la Metodología DMAIC

La implementación de tecnologías complementarias como Smart Meters, IoT, Big Data y Cloud Computing fortalece la aplicación de ML dentro de DMAIC, permitiendo la captura, procesamiento y análisis continuo de datos del proceso [25], [39], [50]. Herramientas como Digital Twins Y Blockchain también complementa el entorno, facilitando la simulación de mejora y asegurando la calidad del proceso [20], [31].

G. Desafíos de Machine Learning con la metodología DMAIC para su integración en la mejora de procesos productivos

Los desafíos para la implantación se relacionan a la falta de recursos técnicos y económicos, así como la falta de capacitación y experiencia del personal, lo que dificulta la interpretación y uso de modelos y herramientas, y a su vez fortalece la resistencia cultural al cambio y la preferencia por métodos tradicionales [26]. Pese a que se puede medir distintos factores e implementar sistemas que combinen tecnologías y modelos, no siempre se logra optimizar la monitorización y análisis en su totalidad [25].

H. Limitación y sugerencia para futuras investigaciones

La integración de ML con la metodología DMAIC ha permitido optimizar procesos industriales, así como ayudar a tomar mejores decisiones mediante un análisis predictivo. Demostrado ser efectivo en la mejora continua, la reducción de desperdicios y el aumento de la eficiencia operativa. Sin embargo, en la mayoría de estudios, ya sea que mencionen alguno de los enfoques o su integración, se centran en el diagnóstico o monitoreo de variables críticas del proceso, sin incorporar soluciones automatizadas o sostenibles a largo plazo [25]. Esta limitación representa una oportunidad para futuras

investigaciones que busquen profundizar en la automatización de la mejora continua a través de modelos híbridos que combine el análisis estadístico de DMAIC con la capacidad predictiva de ML.

V. CONCLUSIONES

Esta revisión sistemática de literatura permitió analizar el impacto de la integración de Machine Learning con la metodología DMAIC en la mejora de procesos productivos en el sector industrial, siendo evidente mejoras en el incremento de la capacidad de producción en 15%, en la reducción de tiempo ciclo en 25%, así como la disminución de 16066 a 119 DPOM, lo que contribuye con una mejora del nivel sigma. Además, se observaron ventajas como la automatización de tareas, el análisis y toma de decisiones basadas en datos y la estandarización de los procesos.

Asimismo, se identificaron diversos modelos de ML en su mayoría basados en árboles de decisión, redes neuronales y vecinos cercanos, permitiendo la clasificación, predicción y control de distintas factores y variables que generan datos. Entre los destinos modelos, ANN y el modelo RFR fueron seleccionados en distintas comparaciones con otros modelos debido a su desempeño y resultados favorables para medir su efectividad.

La integración puede ser respaldada por herramientas y complementos como gráfico de control, diagrama de Pareto y MPCAC permiten el monitoreo, la identificación causa raíz en y la evaluación de desempeño del proceso. Herramientas y complementos que al combinarse con tecnologías como IoT y sensores mejoran la toma de decisiones basada en datos.

Aunque la integración presenta mejoras y ventajas, existen desafíos para su implementación como la resistencia organizacional por reemplazar prácticas tradicionales con soluciones tecnológicas, la falta de procesamiento y análisis de los datos medidos, la exclusión de colaboradores debido a la automatización de procesos o por la falta de competencias digitales, así como asegurar la protección e integridad de los datos recolectados. Por lo tanto, esta revisión aporta una base estructurada para la integración efectiva de ML con DMAIC, reuniendo modelos, herramientas y complementos, promoviendo una cultura organizacional orientada en lo digital, en la sostenibilidad y basada en datos.

REFERENCIAS

- [1] A. Nindiani, H. Hardi Purba, y A. Trimarjoko, «Consistency of DMAIC phases implementation on Six Sigma method in manufacturing and service industry: a literature review», *Manag. Prod. Eng. Rev. 2020 Vol 11 No 4*, 2020, Accedido: 10 de abril de 2025. [En línea]. Disponible en: <https://journals.pan.pl/dlibra/publication/136118/editition/119029>
- [2] T. Pongboonchai-Empl, J. Antony, J. A. Garza-Reyes, T. Komkowski, y G. L. Tortorella, «Integration of Industry 4.0 technologies into Lean Six Sigma DMAIC: a systematic review», *Prod. Plan. Control*, vol. 35, n.º 12, pp. 1403-1428, 2024, doi: 10.1080/09537287.2023.2188496.
- [3] A. Khilil, Z. Shi, A. Umar, y B. Ma, «A New Industry 4.0 Approach for Development of Manufacturing Firms Based on DFSS», *Processes*, vol. 11, n.º 7, 2023, doi: 10.3390/pr11072176.
- [4] W. Q. Dos Santos, O. McDermott, y A. Trubetskaya, «Lean Six Sigma 4.0 Application in the Food & Beverage Industry: A Case Study», *IEEE Eng. Manag. Rev.*, 2025, doi: 10.1109/EMR.2025.3538268.
- [5] D. Skalli, A. Charkaoui, A. Cherrafi, J. A. Garza-Reyes, J. Antony, y A. Shokri, «Industry 4.0 and Lean Six Sigma integration in manufacturing: A literature review, an integrated framework and proposed research perspectives», *Qual. Manag. J.*, vol. 30, n.º 1, pp. 16-40, 2023, doi: 10.1080/10686967.2022.2144784.
- [6] C. A. Escobar, D. Macias-Arregoyta, y R. Morales-Menendez, «The decay of Six Sigma and the rise of Quality 4.0 in manufacturing innovation», *Qual. Eng.*, vol. 36, n.º 2, pp. 316-335, 2024, doi: 10.1080/08982112.2023.2206679.
- [7] I. T. B. Widiwati, S. D. Liman, y F. Nurprihatin, «The implementation of Lean Six Sigma approach to minimize waste at a food manufacturing industry», *J. Eng. Res. Kuwait*, 2024, doi: 10.1016/j.jer.2024.01.022.
- [8] T. Graafmans, O. Turetken, H. Poppelaars, y D. Fahland, «Process Mining for Six Sigma: A Guideline and Tool Support», *Bus. Inf. Syst. Eng.*, vol. 63, n.º 3, pp. 277-300, 2021, doi: 10.1007/s12599-020-00649-w.
- [9] M. Trovato, L. Belluomo, M. Bici, M. Prist, F. Campana, y P. Cicconi, «Machine learning in design for additive manufacturing: A state-of-the-art discussion for a support tool in product design lifecycle», *Int. J. Adv. Manuf. Technol.*, vol. 137, n.º 5, pp. 2157-2180, 2025, doi: 10.1007/s00170-025-15273-9.
- [10] Z. Abd Elnaby, A. Zaher, R. K. Abdel-Magied, y H. I. Elkhouly, «Improving plastic manufacturing processes with the integration of Six Sigma and machine learning techniques: a case study», *J. Ind. Prod. Eng.*, vol. 41, n.º 1, pp. 1-18, 2024, doi: 10.1080/21681015.2023.2260384.
- [11] S. Kaka, M. Maryam, R. K. Wassan, U. Sarwar, A. Akbar, y J. Ansari, «Reducing Outgoing Quality Level (OQL) in Textile Manufacturing Through Six Sigma Methodology: A Case Study», *Text. Leather Rev.*, vol. 7, pp. 1252-1272, 2024, doi: 10.31881/TLR.2024.133.
- [12] H. Zermane y A. Drardja, «Development of an efficient cement production monitoring system based on the improved random forest algorithm», *Int. J. Adv. Manuf. Technol.*, vol. 120, n.º 3, pp. 1853-1866, may 2022, doi: 10.1007/s00170-022-08884-z.
- [13] K.-S. Chen, G.-P. Ye, C.-M. Yu, y C.-H. Yu, «Construct the Optimum Process Model for Transistor Gaskets with Six-Sigma DMAICs», *Appl. Sci.*, vol. 13, n.º 12, Art. n.º 12, ene. 2023, doi: 10.3390/app13126895.
- [14] A. Manimuthu, Venkatesh, V. G., Shi, Yangyan, Sreedharan, V. Raja, y S. C. L. and Koh, «Design and development of automobile assembly model using federated artificial intelligence with smart contracts», *Int. J. Prod. Res.*, vol. 60, n.º 1, pp. 111-135, ene. 2022, doi: 10.1080/00207543.2021.1988750.
- [15] O. Delgadillo, B. Bleniinger, J. Kuhn, y U. Baumgarten, «A Generalistic Approach to Machine-Learning-Supported Task Migration on Real-Time Systems», *J. Low Power Electron. Appl.*, vol. 12, n.º 2, Art. n.º 2, jun. 2022, doi: 10.3390/jlpea12020026.
- [16] S.-J. Hsieh y J. Hykin, «Multi-Stage Corn-to-Syrup Process Monitoring and Yield Prediction Using Machine Learning and Statistical Methods», *Sensors*, vol. 24, n.º 19, Art. n.º 19, ene. 2024, doi: 10.3390/s24196401.
- [17] K. Xia, C. Saidy, M. Kirkpatrick, N. Anumbe, A. Sheth, y R. Harik, «Towards Semantic Integration of Machine Vision Systems to Aid Manufacturing Event Understanding», *Sensors*, vol. 21, n.º 13, Art. n.º 13, ene. 2021, doi: 10.3390/s21134276.
- [18] Z.-W. Zhou, H.-Y. Yang, B.-X. Xu, Y.-H. Ting, S.-C. Chen, y W.-R. Jong, «Prediction of Short-Shot Defects in Injection Molding by Transfer Learning», *Appl. Sci.*, vol. 13, n.º 23, Art. n.º 23, ene. 2023, doi: 10.3390/app132312868.
- [19] M. L. Duc, L. Hlavatý, P. Bilík, y R. Martinek, «Enhancing manufacturing excellence with Lean Six Sigma and zero defects based on Industry 4.0», 2023, doi: 10.14743/apem2023.1.455.
- [20] Z. Shahbazi y Y.-C. Byun, «Integration of Blockchain, IoT and Machine Learning for Multistage Quality Control and Enhancing Security in Smart Manufacturing», *Sensors*, vol. 21, n.º 4, Art. n.º 4, ene. 2021, doi: 10.3390/s21041467.
- [21] A. Trubetskaya, A. Ryan, D. J. Powell, y C. Moore, «Utilising a hybrid DMAIC/TAM model to optimise annual maintenance shutdown performance in the dairy industry: a case study», *Int. J. Lean Six Sigma*, vol. 15, n.º 8, pp. 70-92, dic. 2023, doi: 10.1108/IJLSS-05-2023-0083.
- [22] E. Kuk, J. Stopa, M. Kuk, D. Janiga, y P. Wojnarowski, «Petroleum Reservoir Control Optimization with the Use of the Auto-Adaptive Decision Trees», *Energies*, vol. 14, n.º 18, Art. n.º 18, ene. 2021, doi: 10.3390/en14185702.

- [23] I. Rojek, A. Mroziński, P. Kotlarz, M. Macko, y D. Mikolajewski, «AI-Based Computational Model in Sustainable Transformation of Energy Markets», *Energies*, vol. 16, n.º 24, Art. n.º 24, ene. 2023, doi: 10.3390/en16248059.
- [24] P. Indira, I. S. Arafat, R. Karthikeyan, S. Selvarajan, y P. K. Balachandran, «Fabrication and investigation of agricultural monitoring system with IoT & AI», *SN Appl. Sci.*, vol. 5, n.º 12, p. 322, nov. 2023, doi: 10.1007/s42452-023-05526-1.
- [25] M. Zhu y J. Shang, «Remote Monitoring and Management System of Intelligent Agriculture under the Internet of Things and Deep Learning», *Wirel. Commun. Mob. Comput.*, vol. 2022, n.º 1, p. 1206677, 2022, doi: 10.1155/2022/1206677.
- [26] T. D. Tuan, M. L. DUC, y D. N. Hien, «Integrating Six Sigma into an Industry 4.0 System for Enhanced Productivity: A Case Study in CNC Processes», *Manag. Prod. Eng. Rev. 2024 No 1*, 2024, Accedido: 29 de mayo de 2025. [En línea]. Disponible en: <https://journals.pan.pl/dlibra/publication/149989/edition/131002>
- [27] M. R. Mahmood, M. A. Matin, P. Sarigiannidis, y S. K. Goudos, «A Comprehensive Review on Artificial Intelligence/Machine Learning Algorithms for Empowering the Future IoT Toward 6G Era», *IEEE Access*, vol. 10, pp. 87535-87562, 2022, doi: 10.1109/ACCESS.2022.3199689.
- [28] H. Hernadewita, I. Setiawan, y H. Hendra, «Enhance quality improvement through lean six sigma in division Side Board Clavinova Piano's», *Int. J. Prod. Manag. Eng.*, vol. 10, n.º 2, Art. n.º 2, jul. 2022, doi: 10.4995/ijpme.2022.16140.
- [29] K. Lutoslawski, M. Hernes, J. Radomska, M. Hajdas, E. Walaszczyk, y A. Kozina, «Food Demand Prediction Using the Nonlinear Autoregressive Exogenous Neural Network», *IEEE Access*, vol. 9, pp. 146123-146136, 2021, doi: 10.1109/ACCESS.2021.3123255.
- [30] M. Shahin, F. F. Chen, A. Hosseinzadeh, H. Khodadadi Koodiani, H. Bouzary, y A. Shahin, «Enhanced safety implementation in 5S + 1 via object detection algorithms», *Int. J. Adv. Manuf. Technol.*, vol. 125, n.º 7, pp. 3701-3721, abr. 2023, doi: 10.1007/s00170-023-10970-9.
- [31] F. Carvalho, J. M. R. S. Tavares, y M. Campos Ferreira, «A Machine Learning Approach for Predicting and Mitigating Pallet Collapse during Transport: The Case of the Glass Industry», *Appl. Sci.*, vol. 14, n.º 18, Art. n.º 18, ene. 2024, doi: 10.3390/app14188256.
- [32] H. Mubarak, M. J. Sanjari, S. Stegen, y A. Abdellatif, «Improved Active and Reactive Energy Forecasting Using a Stacking Ensemble Approach: Steel Industry Case Study», *Energies*, vol. 16, n.º 21, Art. n.º 21, ene. 2023, doi: 10.3390/en16217252.
- [33] M. Elsisi, K. Mahmoud, M. Lehtonen, y M. M. F. Darwish, «Reliable Industry 4.0 Based on Machine Learning and IoT for Analyzing, Monitoring, and Securing Smart Meters», *Sensors*, vol. 21, n.º 2, Art. n.º 2, ene. 2021, doi: 10.3390/s21020487.
- [34] J. Wan, X. Li, H.-N. Dai, A. Kusiak, M. Martínez-García, y D. Li, «Artificial-Intelligence-Driven Customized Manufacturing Factory: Key Technologies, Applications, and Challenges», *Proc. IEEE*, vol. 109, n.º 4, pp. 377-398, abr. 2021, doi: 10.1109/JPROC.2020.3034808.
- [35] Q. Hu, C. Sellers, J. S.-I. Kwon, y H.-J. Wu, «Integration of surface-enhanced Raman spectroscopy (SERS) and machine learning tools for coffee beverage classification», *Digit. Chem. Eng.*, vol. 3, p. 100020, jun. 2022, doi: 10.1016/j.dche.2022.100020.
- [36] D. M. Utama y M. Abirfatin, «Sustainable Lean Six-sigma: A new framework for improve sustainable manufacturing performance», *Clean. Eng. Technol.*, vol. 17, 2023, doi: 10.1016/j.clet.2023.100700.
- [37] C. A. Escobar, D. Macias-Arregoyta, y R. Morales-Menendez, «The decay of Six Sigma and the rise of Quality 4.0 in manufacturing innovation», *Qual. Eng.*, vol. 36, n.º 2, pp. 316-335, abr. 2024, doi: 10.1080/08982112.2023.2206679.
- [38] N. Chuenmee, N. Phothi, K. Chamniprasart, S. Khaengkarn, y J. Srisertpol, «Machine learning for predicting resistance spot weld quality in automotive manufacturing», *Results Eng.*, vol. 25, p. 103570, mar. 2025, doi: 10.1016/j.rineng.2024.103570.
- [39] J. C. Serrano-Ruiz, J. Mula, y R. Poler, «Development of a multidimensional conceptual model for job shop smart manufacturing scheduling from the Industry 4.0 perspective», *J. Manuf. Syst.*, vol. 63, pp. 185-202, abr. 2022, doi: 10.1016/j.jmsy.2022.03.011.
- [40] M. A. Rahman *et al.*, «A Cloud-Based Cyber-Physical System with Industry 4.0: Remote and Digitized Additive Manufacturing», *Automation*, vol. 3, n.º 3, Art. n.º 3, sep. 2022, doi: 10.3390/automation3030021.
- [41] F. Rodríguez, W. D. Chicaiza, A. Sánchez, y J. M. Escaño, «Updating digital twins: Methodology for data accuracy quality control using machine learning techniques», *Comput. Ind.*, vol. 151, p. 103958, oct. 2023, doi: 10.1016/j.compind.2023.103958.
- [42] P. Cunningham, M. Cord, y S. J. Delany, «Supervised Learning», en *Machine Learning Techniques for Multimedia: Case Studies on Organization and Retrieval*, M. Cord y P. Cunningham, Eds., Berlin, Heidelberg: Springer, 2008, pp. 21-49. doi: 10.1007/978-3-540-75171-7_2.
- [43] G. James, D. Witten, T. Hastie, R. Tibshirani, y J. Taylor, «Unsupervised Learning», en *An Introduction to Statistical Learning: with Applications in Python*, G. James, D. Witten, T. Hastie, R. Tibshirani, y J. Taylor, Eds., Cham: Springer International Publishing, 2023, pp. 503-556. doi: 10.1007/978-3-031-38747-0_12.
- [44] M. F. A. Hady y F. Schwenker, «Semi-supervised Learning», en *Handbook on Neural Information Processing*, M. Bianchini, M. Maggini, y L. C. Jain, Eds., Berlin, Heidelberg: Springer, 2013, pp. 215-239. doi: 10.1007/978-3-642-36657-4_7.
- [45] L. P. Kaelbling, M. L. Littman, y A. W. Moore, «Reinforcement Learning: A Survey», *J. Artif. Intell. Res.*, vol. 4, pp. 237-285, may 1996, doi: 10.1613/jair.301.
- [46] V. E. Lyalin, V. P. Grahov, N. G. Sokolova, T. A. Berkutova, y N. L. Tararuha, «Algorithmic approach based on logical qualifiers of subcontractors during creation of large machine-building complexes», *Vibroengineering Procedia*, vol. 10, pp. 480-485, dic. 2016.
- [47] «(PDF) A Review on Machine Learning Algorithms, Tasks and Applications», ResearchGate. Accedido: 22 de julio de 2025. [En línea]. Disponible en: https://www.researchgate.net/publication/320609700_A_Review_on_Machine_Learning_Algorithms_Tasks_and_Applications
- [48] A. Sardashti y J. Nazari, «A learning-based approach to fault detection and fault-tolerant control of permanent magnet DC motors», *J. Eng. Appl. Sci.*, vol. 70, n.º 1, p. 109, sep. 2023, doi: 10.1186/s44147-023-00279-5.
- [49] I. Punta-Sánchez, T. Dymerski, J. L. P. Calle, A. Ruiz-Rodríguez, M. Ferreiro-González, y M. Palma, «Detecting Honey Adulteration: Advanced Approach Using UF-GC Coupled with Machine Learning», *Sensors*, vol. 24, n.º 23, Art. n.º 23, ene. 2024, doi: 10.3390/s24237481.
- [50] S. García-Méndez, F. De Arriba-Pérez, M. Del Carmen Somoza-López, S. García-Méndez, F. De Arriba-Pérez, y M. Del Carmen Somoza-López, «Informatics and Dairy Industry Coalition: Artificial Intelligence Trends and Present Challenges», *IEEE Ind. Electron. Mag.*, vol. 18, n.º 2, Art. n.º 2, 2024, doi: 10.1109/MIE.2023.3328106.
- [51] T. G. Walmsley *et al.*, «Adaptive digital twins for energy-intensive industries and their local communities», *Digit. Chem. Eng.*, vol. 10, p. 100139, mar. 2024, doi: 10.1016/j.dche.2024.100139.
- [52] C. Binder, C. Neureiter, y A. Lüder, «Towards a domain-specific information architecture enabling the investigation and optimization of flexible production systems by utilizing artificial intelligence», *Int. J. Adv. Manuf. Technol.*, vol. 123, n.º 1, pp. 49-81, nov. 2022, doi: 10.1007/s00170-022-10141-2.
- [53] A. Y. Magodi, I. A. Daniy, y K. Mpofu, «APPLICATION OF LEAN SIX SIGMA TO A SMALL ENTERPRISE IN THE GAUTENG PROVINCE: A CASE STUDY», *South Afr. J. Ind. Eng.*, vol. 33, n.º 1, Art. n.º 1, may 2022, doi: 10.7166/33-1-2504.
- [54] L. Roveda, M. Magni, M. Cantoni, D. Piga, y G. Bucca, «Human–robot collaboration in sensorless assembly task learning enhanced by uncertainties adaptation via Bayesian Optimization», *Robot. Auton. Syst.*, vol. 136, p. 103711, feb. 2021, doi: 10.1016/j.robot.2020.103711.
- [55] G. Naeem, M. Asif, y M. Khalid, «Industry 4.0 digital technologies for the advancement of renewable energy: Functions, applications, potential and challenges», *Energy Convers. Manag. X*, vol. 24, p. 100779, oct. 2024, doi: 10.1016/j.ecmx.2024.100779.
- [56] M. S. Farahani y G. Ghasemi, «Artificial Intelligence and Inequality: Challenges and Opportunities», *Qeios*, feb. 2024, doi: 10.32388/7HWUZ2.