

# Integrating Machine Learning and Digital Twin to Improve Plant Equipment Efficiency in the Mining Sector: A Systematic Review

Heidy Y. Mamani, Estudiante<sup>1</sup>, Astrid N. Neyra, Estudiante<sup>2</sup> Nohemy M. Canahua, Mg.<sup>3</sup>  
<sup>1,2,3</sup>Universidad Tecnológica del Perú, Perú, <sup>1</sup>U21218466@utp.edu.pe, <sup>2</sup>U21223152@utp.edu.pe,  
<sup>3</sup>C26052@utp.edu.pe

*Abstract—Mining is an environment that demands increased operational efficiency, sustainability, and cost reduction, where digitalization is emerging as a crucial and strategic solution. The purpose of this systematic review is to evaluate the use of machine learning and digital twins in relation to the operational efficiency of mining plant equipment. Methodologies such as PRISMA ensure the effectiveness of the selection process for the articles considered, allowing the analysis to be structured using the PICO strategy, considering equipment characteristics, ML-DT integration mechanisms, and the results obtained after its implementation. The search was conducted using search engines such as Scopus and ScienceDirect, filtering publications that were not published between the years 2019 and 2025, obtaining a total of 74 articles that met the inclusion criteria. The findings revealed a growing trend in the use of these technologies to optimize processes such as flotation, conveying, predictive monitoring, and mill energy control. Overall, significant improvements were identified in reducing energy consumption, lowering maintenance costs, and increasing equipment availability and reliability. Furthermore, ML-based predictive models demonstrated high accuracy in early fault detection and real-time operational decision-making. In short, the integration of Machine Learning and Digital Twin in mining plants represents a key advance toward more efficient, safe, and sustainable operations. This technological synergy not only optimizes equipment performance but also paves the way for a more competitive and resilient mining industry in the face of future challenges.*

**Keywords** – Machine learning, Digital twin, Efficiency, Mining

# Integración del aprendizaje automático y gemelo digital para mejorar la eficiencia de los equipos de planta en el sector minero: Una revisión sistemática

Heidy Y. Mamani, Estudiante<sup>1</sup>, Astrid N. Neyra, Estudiante<sup>2</sup> Nohemy M. Canahua, Mg.<sup>3</sup>  
<sup>1,2,3</sup>Universidad Tecnológica del Perú, Perú, <sup>1</sup>U21218466@utp.edu.pe, <sup>2</sup>U21223152@utp.edu.pe,  
<sup>3</sup>C26052@utp.edu.pe

**Resumen—La minería es un entorno que exige una mayor demanda de eficiencia operativa, sostenibilidad y disminución de costos, donde la digitalización se inserta como una solución crucial y estratégica.** La revisión sistemática presente tiene como propósito evaluar la presencia del aprendizaje automático (machine learning) y los gemelos digitales (digital twin) con respecto a la eficiencia operativa de los equipos de planta minera. Las metodologías empleadas como PRISMA, permiten garantizar la eficacia del proceso de selección de los artículos considerados, permitiendo estructurar el análisis mediante la estrategia PICO, considerando las características de los equipos, los mecanismos de la integración ML-DT y los resultados encontrados después de su implantación.

Con respecto a la búsqueda se llevó a cabo en motores como Scopus, ScienceDirect, filtrando publicaciones que no entre los años 2019–2025, obteniendo un total de 74 artículos que cumplían con los criterios de inclusión. Los hallazgos revelaron una tendencia creciente en el uso de estas tecnologías para optimizar procesos como la flotación, el transporte por fajas, el monitoreo predictivo, y el control energético de los molinos. En términos generales, se identificaron mejoras significativas en la reducción del consumo energético, la disminución de costos de mantenimiento, y un incremento en la disponibilidad y confiabilidad de los equipos. Además, los modelos predictivos basados en ML demostraron alta precisión en la detección temprana de fallas y en la toma de decisiones operativas en tiempo real. En síntesis, la integración de Machine Learning y Digital Twin en plantas mineras representa un avance clave hacia operaciones más eficientes, seguras y sostenibles. Esta sinergia tecnológica no solo optimiza el desempeño de los equipos, sino que también abre camino hacia una minería más competitiva y resiliente ante los desafíos del futuro.

**Palabras clave --** Machine learning, Digital twin, Eficiencia, Minería

## I. INTRODUCCIÓN

La minería es un pilar esencial de la economía global y, en el Perú, este sector representa uno de los mayores aportes al Producto Bruto Interno (PBI) [1]. Sin embargo, su eficiencia operativa se ve limitada por fallas recurrentes en los equipos de planta, generando pérdidas económicas y tiempos muertos [2]. Ante ello, tecnologías como Machine Learning (ML) y Digital Twin (DT) vienen ganando protagonismo por su

capacidad de anticipar fallos, optimizar procesos y mejorar el mantenimiento [3]. Los modelos predictivos con ML detectan anomalías, mientras que los sistemas DT simulan condiciones reales para facilitar decisiones más precisas [4]. Gracias a estos beneficios, su aplicación en minería está en aumento, con

impactos positivos en la gestión de activos y la eficiencia operativa [5].

Sin embargo, a pesar de los avances de la Industria 4.0, muchas empresas mineras aún enfrentan dificultades para anticipar fallas críticas en los equipos de planta, afectando directamente la eficiencia y continuidad operativa [6]. Aunque existen sensores industriales que generan grandes volúmenes de datos, estos no siempre se transforman en información útil para tomar decisiones oportunas [7]. En el ámbito nacional, predomina el mantenimiento tradicional basado en registros históricos e inspecciones manuales, lo que limita la respuesta ante exigencias de competitividad [8]. Además, la integración entre Machine Learning (ML) y Digital Twin (DT) sigue siendo restringida por problemas de estandarización, interoperabilidad y procesamiento en tiempo real [9], [10]. Como resultado, el desarrollo de modelos predictivos sólidos y adaptables sigue siendo incipiente, pese a propuestas híbridas aún poco aplicadas en la industria [11]–[13].

En este contexto, la literatura especializada ha evidenciado un creciente interés por integrar Machine Learning (ML) y Digital Twin (DT) en el sector minero, especialmente para abordar desafíos relacionados con el mantenimiento predictivo [14], [15]. No obstante, los estudios existentes presentan una marcada fragmentación: algunos se centran únicamente en el modelado digital [16], otros priorizan el monitoreo y control basado en inteligencia artificial [17], [18], y varios se desarrollan en contextos industriales distintos al minero [19], [20]. Esta dispersión dificulta una comprensión completa del estado del arte, limitando la identificación de patrones, desafíos comunes y oportunidades de mejora. Por ello, esta revisión sistemática busca aportar una visión integrada que oriente futuras aplicaciones en equipos de planta minera.

Por lo tanto, esta revisión tiene como objetivo identificar, clasificar y analizar los estudios más relevantes sobre la integración de ML y DT aplicados al mantenimiento predictivo para mejorar la eficiencia operativa de equipos de planta en la industria minera. El propósito de esta revisión es evaluar cómo estas tecnologías han sido implementadas, qué resultados han generado en términos de eficiencia operativa, tomando en cuenta sus principales limitaciones como la disponibilidad de datos confiables y los elevados costos de integración. En consecuencia, esta revisión sistemática busca ofrecer una visión

integral del estado actual del conocimiento, identificar vacíos en la literatura, y proponer líneas de investigación futuras que contribuyan a una integración más efectiva de estas tecnologías en entornos reales del sector minero.

Este artículo se organiza en dos secciones principales: la Sección 2, Metodología, presenta las preguntas de investigación formuladas bajo el enfoque PICO, la estrategia de búsqueda en bases de datos como Scopus, Web of Science y EBSCOhost, y la aplicación del protocolo PRISMA para la selección de estudios. La Sección 3, Resultados, expone los hallazgos mediante tablas y figuras que permiten una lectura clara y estructurada del panorama actual.

## II. METODOLOGÍA

Esta sección describe el enfoque sistemático seguido para recopilar las publicaciones relevantes y filtrar un número prácticamente manejable de publicaciones, minimizando al mismo tiempo los sesgos.

### A. Estrategia de Búsqueda

Esta sección se elaboró utilizando el modelo PICO, una herramienta que facilita la formulación de preguntas clínicas y la búsqueda de información científica relevante. A partir de sus cuatro componentes (Población, Intervención, Comparación y Resultados), se definieron los conceptos clave del estudio. La Tabla I muestra la pregunta principal y sub-preguntas derivadas que orientaron el enfoque temático y metodológico de la revisión.

TABLA I

#### PREGUNTA PICO Y COMPLEMENTARIAS

¿Cómo influye la integración de Machine Learning y Digital Twin en la eficiencia operativa de equipos de planta en el sector minero?	
P	¿Qué tipo de características usan estos equipos de planta que limitan su eficiencia operativa?
I	¿Cómo se integran Machine Learning y Digital Twin para optimizar y realizar el mantenimiento en equipos de planta?
C	No aplica
O	¿Qué mejoras se observan tras la aplicación de estas herramientas en la eficiencia operativa de estos equipos?

### B. Palabras clave especializadas

Asegurando una búsqueda bibliográfica concreta, precisa y alineada con las intenciones del estudio, se inició con la desintegración de manera conceptual de las preguntas de investigación PICO. Esta aproximación logró establecer categorías del tema de interés, donde la selección de palabras que fueron empleadas como guía para la exploración de literatura científica que guarde relación con los temas importantes para la investigación, permitió delimitar un enfoque que garantice la pertinencia del material recopilado. La tabla II muestra la descomposición de la pregunta de investigación mediante el modelo PICO.

TABLA II

#### COMPONENTES PICO

Componentes		Keywords
<b>Población/ Problema</b>	Equipos de planta en el sector minero	Mining sector, mining operations, industrial plant, extractive industry, plant equipment.
<b>Intervención</b>	Machine Learning y Digital Twin	Machine Learning, Digital Twin, artificial intelligence, predictive maintenance.
<b>Comparación</b>	No aplica	No aplica
<b>Resultados</b>	Eficiencia operativa	Operational efficiency, optimization, equipment availability, failure reduction

### C. Selección de búsqueda

Para asegurar la pertinencia de la información científica recopilada, se realizó una búsqueda manual complementaria en motores especializados, lo que permitió identificar estudios adicionales clave para la temática. Esta etapa también profundizó en aspectos relevantes vinculados directamente con el objetivo de la investigación. Asimismo, se diseñaron ecuaciones de búsqueda específicas para refinar los resultados y lograr una selección más precisa y alineada con el enfoque del estudio. Estas estrategias se aplicaron en bases de datos de alto impacto como Scopus, Web of Science y EBSCOhost. La Tabla III presenta las ecuaciones empleadas, las cuales combinan términos clave como *Digital Twin*, *Machine Learning* y *Artificial Intelligence*, aplicados al contexto minero.

TABLA III  
BASE DE DATOS Y ECUACIONES DE BÚSQUEDA

Motores de búsqueda	Ecuación de búsqueda
<b>Scopus</b>	("Machine Learning" OR "Artificial Intelligence") AND ("Digital Twin" AND ("Mining Industry" OR "Mineral Processing") AND ("Efficiency" OR "Optimization"))
<b>Web of Science</b>	TS=(("digital twin" AND ("machine learning" OR "artificial intelligence" OR "data analytics")) AND (mining OR "mining industry"))
<b>EBSCOhost</b>	("digital twin" AND ("machine learning" OR "artificial intelligence" OR "data analytics")) AND (mining OR "mining industry" OR "mining sector"))

Durante la etapa de identificación, se aplicaron criterios de inclusión y exclusión previamente definidos, lo que permitió enfocar la revisión en estudios relevantes y evitar aquellos alejados del objetivo central de la investigación. La Tabla IV resume estos criterios, los cuales garantizaron la selección de investigaciones centradas en la aplicación de tecnologías avanzadas en minería, asegurando así la calidad y pertinencia del contenido analizado.

**TABLA IV**  
**CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN**

Criterios de Inclusión	Criterios de Exclusión
<b>CI1:</b> Los estudios deben estar enfocados en el sector minero o industrias relacionadas.	<b>CE1:</b> Estudios que NO abordan la eficiencia de equipos en el sector minero.
<b>CI2:</b> Los estudios deben centrarse en la implementación de Machine Learning y Digital Twin en el sector minero.	<b>CE2:</b> Estudios que no consideren Machine Learning ni Digital Twin como tecnologías para la mejora de la eficiencia operativa y el mantenimiento predictivo.
<b>CI3:</b> Los estudios deben contener la mejora de eficiencia operativa y el mantenimiento predictivo de equipos de planta en el sector minero.	<b>CE3:</b> Estudios que no se centren en equipos de planta o las tecnologías para la eficiencia operativa.
<b>CI4:</b> Los estudios deben otorgar resultados sobre la optimización operativa y la reducción de fallas en equipos de planta.	<b>CE4:</b> Estudios centrados en cadena de suministro, proyectos de infraestructura y construcción.

Tras la búsqueda en Scopus, Web of Science y EBSCOhost, se identificaron 663 publicaciones. Aplicando el diagrama PRISMA, se eliminaron 29 duplicados, 3 por estar fuera del rango 2020–2025, 260 por falta de acceso y 94 por no corresponder a artículos científicos o conferencias. Luego, se descartaron 140 por no contar con título o resumen, 36 por tratar temas ajenos como blockchain o coal, y finalmente, 27 por abordar sectores no relevantes como construcción, manufactura o cadenas de suministro.

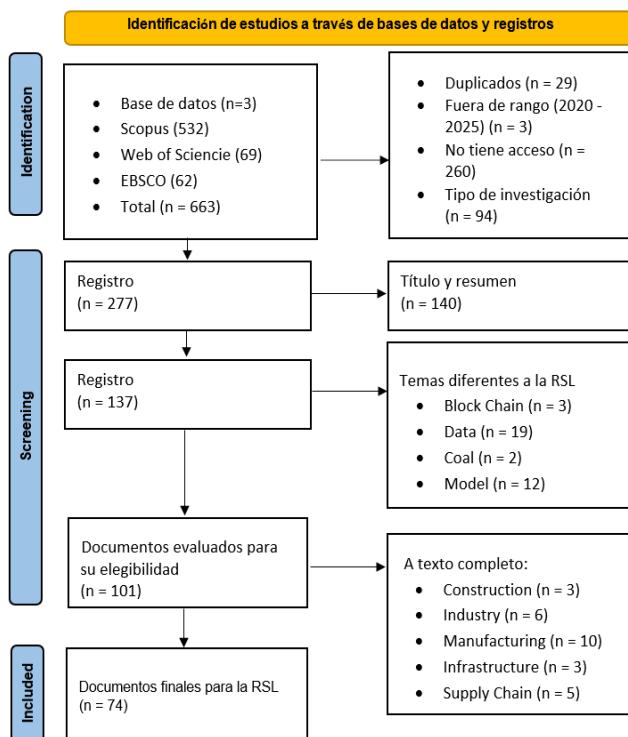


Fig. 1 Diagrama de flujo Prisma.

Finalmente, tras la aplicación de los lineamientos definidos para la inclusión y exclusión de material, se seleccionaron 74 artículos científicos que fueron considerados pertinentes para llevar a cabo el análisis bibliométrico.

### III. RESULTADOS BIBLIOMÉTRICOS

La presentación de resultados mostrará los hallazgos del análisis bibliométrico, incluyendo el origen geográfico de las investigaciones, la evolución temporal de las publicaciones y el análisis de palabras clave, con el fin de identificar tendencias, regiones productivas y conexiones temáticas en la literatura.

#### A. Origen geográfico de investigaciones

La Figura 2 evidencia una marcada concentración de investigaciones originadas en Asia, siendo este el continente con la mayor cantidad de contribuciones. La Figura 1 muestra una fuerte concentración de estudios en Asia, especialmente en países como Rusia, India y Australia, con importante desarrollo en tecnologías mineras. Europa también aporta con trabajos provenientes de Alemania, Francia y el Reino Unido. En América, destaca Estados Unidos, Canadá y Brasil, junto a Chile como únicos representantes sudamericanos. En África, solo Sudáfrica presenta publicaciones relevantes, reflejando una distribución geográfica diversa, pero con menor representación en algunas regiones. En pocas palabras, la producción científica con respecto a la tecnología aplicada al sector minero, especialmente sobre Gemelos Digitales y Machine Learning, está liderada por las potencias tecnológicas e industrial; caso contrario a los países aún en vías de desarrollo, las cuales presentan una baja participación.

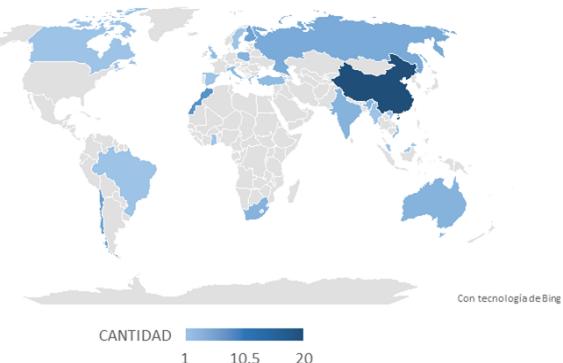


Fig. 2 Contribuciones científicas por continente.

#### B. Países clave en investigación y desarrollo

La figura 3 muestra la distribución de investigaciones por país en tecnologías aplicadas al sector minero. China lidera en número de publicaciones, consolidándose como referente en innovación tecnológica. Le siguen Canadá, España y Marruecos con participación moderada, mientras que Australia, India, Sudáfrica, Rusia y Polonia también destacan en temas como automatización y mantenimiento predictivo. En cambio, países como Brasil, Turquía, Italia, Finlandia, Vietnam y Ghana presentan una contribución limitada, posiblemente por menor inversión o capacidad en investigación tecnológica minera.

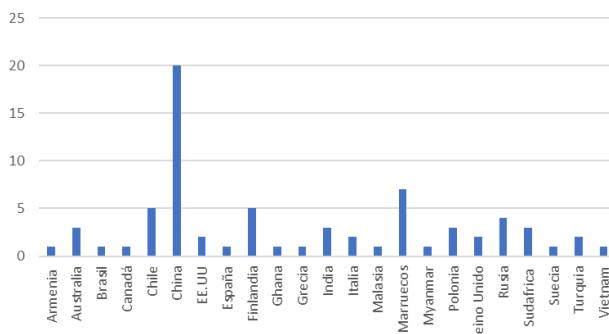


Fig. 3 Publicaciones por país.

En pocas palabras, los resultados demuestran que esta distribución nacional realiza esfuerzos de investigación concentrados en grupos de países concretos, donde estos están posicionándose como referentes para el impulso de tecnologías emergentes en el sector minero.

### C. *Tendencias de publicación por año*

Con respecto a la figura 4, en los primeros años 2020 y 2021 del periodo analizado (2020-2025), la cantidad de publicaciones fue relativamente baja, dejando como reflejo el bajo interés inicial limitado en el área. Posteriormente durante el año 2022, se visualiza un aumento progresivo en el número de investigaciones, alcanzando 15% del total. Continuando con el orden cronológico, ya para el año 2023 continuó este aumento de manera notable, concentrando un 28% de las publicaciones científicas, y en el año 2024 se consolidó la máxima producción científica con un 35% del total de artículos analizados. Finalmente, el mismo interés sustancial se mantiene con 12% en el año 2025.

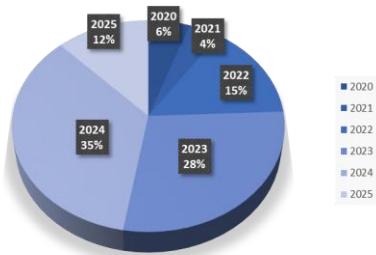


Fig. 4 Publicaciones por país.

Este análisis con base a la cantidad de investigaciones realizadas por año, presenta una evolución considerable con respecto a la producción científica que guarda relación con el tema de estudio, enfatizando el crecimiento pronunciado entre 2022 y 2024, pues esto subraya un interés progresivo del campo de estudio.

#### D. *Malla de Co-ocurrencia de palabras clave*

La figura 5 generada a través de Vosviewer, representa la conexión temática junto a la prominencia de los puntos clave dentro de la literatura analizada. Desde este punto, se visualizan varias relaciones que delinean los principales focos de investigación. Palabras clave como “Machine Learning” e “Digital Twin” surgen como nodos centrales, con vínculos robustos a términos como “Industry 4.0”, “Mining Industry” y

“Artificial Intelligence”, sugiriendo la relevante interconexión entre la industria minera y las tecnologías de vanguardia.

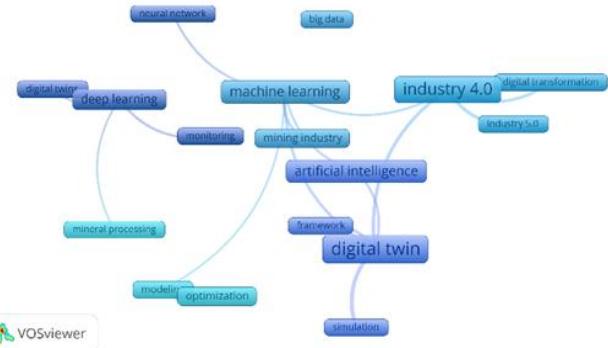


Fig. 5 Co-ocurrencia de palabras clave-VOSviewer.

En síntesis, el mapa refleja la concurrencia de palabras clave revelando la destacada presencia de "Industry 4.0" y "Machine learning", y su vínculo con "Artificial intelligence", "Digital Twin", y otros conceptos. Así como un concepto integrador que conecta a diversas áreas , "Digital Twin" y "Machine Learning" como motor de conceptos relacionados al análisis y monitoreo de datos.

#### IV. RESULTADOS DE INGENIERÍA

Tras la revisión y selección metodológica de los estudios relevantes, se inició el análisis exhaustivo de los resultados vinculados a la ingeniería de vanguardia aplicados al entorno minero industrial. Los resultados se presentan por categorías clave, logrando una comprensión de los motivos que afectan en el rendimiento, monitoreo, mantenimiento y automatización de la industria en estudio.

A. *¿Qué tipo de características usan estos equipos de planta que limitan su eficiencia operativa?*

La maquinaria de planta en el sector minero posee varias características limitantes que perturban la eficiencia operativa, tal y como se señala en la figura 6. En primer lugar, se identificaron condiciones de monitoreo adversas, como polvo, humedad y calor en fundiciones y minas subterráneas, que deterioran los sensores y afectan la calidad de los datos utilizados por los modelos de ML. [1], [2], [11], [18], [22], [48], [51], [73]. Sumado a esto, las vibraciones, desgastes y cargas mecánicas en equipos como molinos y bandas, provocan señales inestables y ruido, perjudicando la exactitud de las simulaciones digitales (DT) [13], [34], [43], [44], [64], [68]. Por otro lado, se identifican retos que complican el modelo preciso y disminuyen la capacidad de generación de algoritmos ML y DT, estos se desprenden de la complejidad geológica, estrechamente ligada con la topografía inestable o mineralogía fluctuante [9], [10], [27], [31], [52], [60], [61], [63]. Asimismo, la iluminación precaria limita el ingreso visual para algoritmos de IA, restringiendo el modelamiento visual de DT [12], [16], [40], [49], [54].

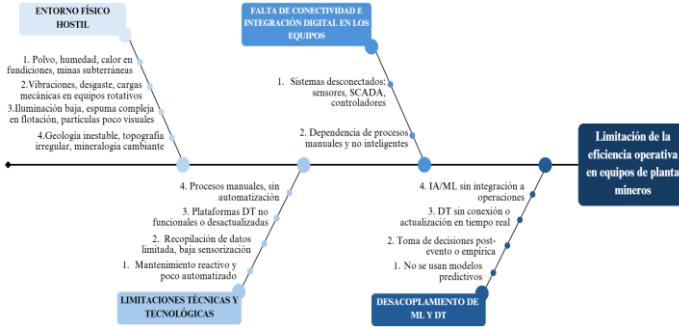


Fig. 6 Diagrama de Ishikawa sobre limitantes de la eficiencia operativa.

En segundo lugar, el mantenimiento reactivo y poco automatizado son características recurrentes en los equipos que se encuentran a la espera de fallas para la intervención sin una planificación anticipada, generando costos elevados y poca disponibilidad operativa [1], [2], [11], [13], [18], [22], [30], [33], [36], [42], [43], [47], [51], [69]. Sumado a ello, la escasa digitalización y la falta de monitoreo en tiempo real limitan el desarrollo de modelos ML y simulaciones DT, al no contar con datos continuos y precisos. [6], [10], [12], [15], [16], [26], [31], [34], [41], [46], [49], [55], [57], [59]. En este contexto, la experiencia basada en acontecimientos que no empleen instrumentos predictivos limitan la capacidad de los sistemas inteligentes con respecto a la precisión de los modelos [17], [20], [25], [38], [45], [50], [52], [53], [61], [62], [63], [65], [67], [71], en relación a esto se integra la escasa implementación de sistemas predictivos, donde la carencia de modelos que pronostiquen las fallas o modifiquen los parámetros automáticamente generan discrepancias entre el ML y las operaciones reales [27], [29], [35], [44], [48], [54], [58], [60], [64], [66], [68], [70], [72], [74]. Finalmente, la falta de conectividad e integración digital en la maquinaria comienza por la desconexión entre sensores, SCADA, controladores y de sistemas de análisis, imposibilitando la sincronización y control uniforme de los datos, comprometiendo la renovación en tiempo real del DT [1], [6], [20], [31], [35], [48], [62], [64], [66], [73]. Según lo mencionado, esta separación se ve perjudicada por las limitaciones en el favorecimiento de datos, debido a que la mayoría de los equipos no presentan sensores adecuados lo que imposibilita el entrenamiento correcto de los modelos ML y reduce la precisión de la predicción de fallas [12], [24], [26], [36], [37], [43], [45], [65]. También, las limitaciones identificadas en los sistemas de DT se dan por no encontrarse sincronizadas con los sistemas físicos, ocasionando que la utilidad se limite a simulaciones estáticas sin la capacidad del monitoreo en tiempo real [3], [17], [53], [55], [57], [59], [67], [71], [72]. En última instancia, la dependencia de procesos manuales y no inteligentes se mantiene resistente, imposibilitando el cierre del bucle automático basado en datos, dejando a ML y DT desconectados del proceso real de la toma de decisiones [4], [42], [46], [49], [60], [63], [68], [70].

## B. ¿Cómo se integran Machine Learning y Digital Twin para optimizar y realizar el mantenimiento en equipos de planta?

Machine Learning (ML) y Digital Twin (DT), mediante una aplicación conjunta en circunstancias industriales, han provocado la mejora sustancial con respecto a la eficiencia operativa de la maquinaria de planta en la industria minera. Se observa como principal mejora la optimización del mantenimiento a través de integración en tiempo real, en especial la interacción entre ML, DT, sensores IoT y sistemas SCAD que permiten una supervisión habitual de la condición de los activos, lo que se traduce en una disminución de tiempos inactivos y mejor precisión para la toma de decisiones operativas [1], [2], [3], [10], [25], [33], [63], [71], [74]. En este sentido, la ejecución conjunta potencia un monitoreo continuo, percibándose de la condición críticas como el desgaste, vibraciones anómalas o fallos inminentes, generando una respuesta anticipada y oportuna que reducen eventos inesperados [11], [13], [28], [48], [57], [64]. Asimismo, se han percibido beneficios en relación con la actualización dinámica del DT, donde los gemelos digitales se amoldan de forma autónoma en relación de los datos actuales e históricos, incrementando la fidelidad las simulaciones y la precisión del control de operaciones [10], [21], [29], [52], [58], [71]. Esta capacidad permite implementar estrategias adaptativas en tiempo real, ajustando variables críticas sin afectar el proceso. Además, los modelos predictivos facilitan la anticipación de fallas, la simulación de escenarios y la mejora de la confiabilidad operativa, reduciendo los costos de mantenimiento. [5], [18], [20], [27], [35], [44], [45], [50], [52], [55], [59], [60], [62], [66], [67], [74].

Tomando un enfoque más estructural, el ML actúa como motor de predicción, que logra inspeccionar y analizar grandes volúmenes de datos históricos y operacionales con el fin de ejecutar alertas, recomendaciones o ajustes automáticos [1], [3], [10], [11], [13], [18], [27], [28], [33]–[36], [39], [42], [43], [45], [47], [50], [52], [53], [56], [60], [63], [65]–[67], [69]–[71], [73]. Junto a ello, el DT tiene el rol de simular escenarios donde se evalúan los comportamientos de los equipos bajo diversas condiciones, rutas de mantenimiento o propuestas de decisión, sin la necesidad de paralizar el sistema real [1], [3], [5]–[7], [10], [11], [18], [23], [25], [27], [29], [33]–[39], [42]–[44], [52]–[54], [56], [68], [70]. A partir de este enfoque se logra una mejor planificación, reducción de riesgos operativos y la agilización a los tiempos de respuesta de cambios o emergencias. Para finalizar, la incorporación de arquitectura modular y adaptable como IoT, Edge computing, visualización y SCADA, junto a la comunicación fluida entre ML y DT, hacen más robusta la adaptabilidad y eficiencia del mantenimiento predictivo [5], [6], [15], [16], [18], [20], [22], [24], [26], [29], [31], [32], [33], [38], [42], [43], [49], [51], [54], [55], [57]–[60], [61], [62], [64], [71]–[74]. Tal y como se muestra en la figura 7, se presenta un flujoograma que resume el orden de integración entre Machine Learning y Digital Twin

con el objetivo de optimizar el mantenimiento de la maquinaria minera. Donde se visualiza el flujo lógico a partir de la supervisión continua, la detección de situaciones críticas hasta la simulación de escenarios y la implementación de medidas correctivas.

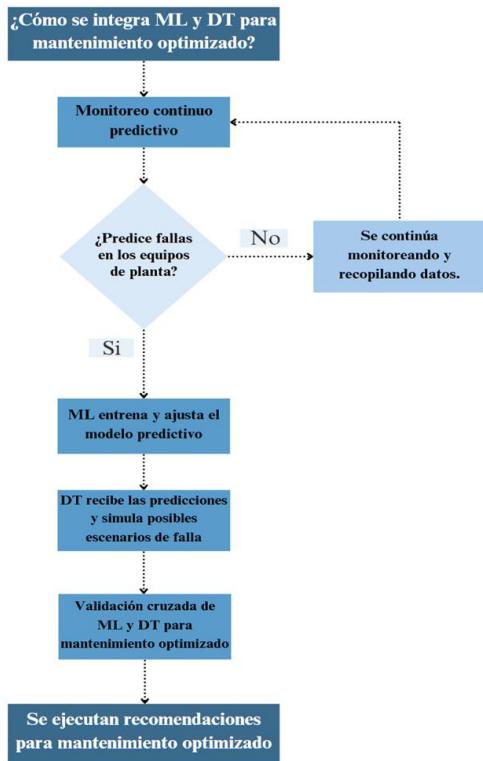


Fig. 7 Flujograma de sinergia entre ML y DT.

C. *¿Qué mejoras se observan tras la aplicación de estas herramientas en la eficiencia operativa de estos equipos?*

La integración de ML y DT permitieron mejoras en la eficiencia operativa para los equipos de planta en el sector minero, las cuales se pueden segmentar en mejoras cualitativas y cuantitativas.

La figura 8 describe las mejoras cualitativas, se observa que la optimización operativa en el empleo de recursos críticos como aire, energía y agua, donde gracias a los ajustes realizados de manera automática se redujo el consumo y desgaste de los mismos equipos en cuestión [34], [50], [53], [54], [66], [71]. También, la mejora de las rutas y ciclos de operación ha permitido la disminución de innecesarias operaciones, reduciendo el deslizamiento de equipos y el consumo energético [57], [61], [62], [68], [70], [73]. Con respecto al mantenimiento predictivo, los programas con fundamento en el ML permiten anticiparse a las fallas con modelos de predicción, dejando de las intervenciones que no son cruciales y mejoran la planificación preventiva [1], [6], [10], [11], [13]. La decisión a través de DT y la simulación genera la posibilidad de realizar pre-modificaciones virtuales y validar escenarios, donde las

decisiones se toman en base a condiciones operativas, siendo más eficientes y facilitando el uso óptimo de los recursos disponibles [29], [47], [56], [67]. En esta misma sintonía, las alertas predictivas potencialmente reducir el riesgo operativo y disminuir el tiempo de respuesta frente a anomalías al brindar avisos a tiempo [42], [46], [51], [65]. En consecuencia, todo lo mencionado permite acelerar la disponibilidad y confiabilidad de los equipos, reduciendo fallas no planificadas y aumentando los tiempos efectivos de operación [29], [47], [56], [67], traduciéndose en una mayor disponibilidad con respecto a la maquinaria.

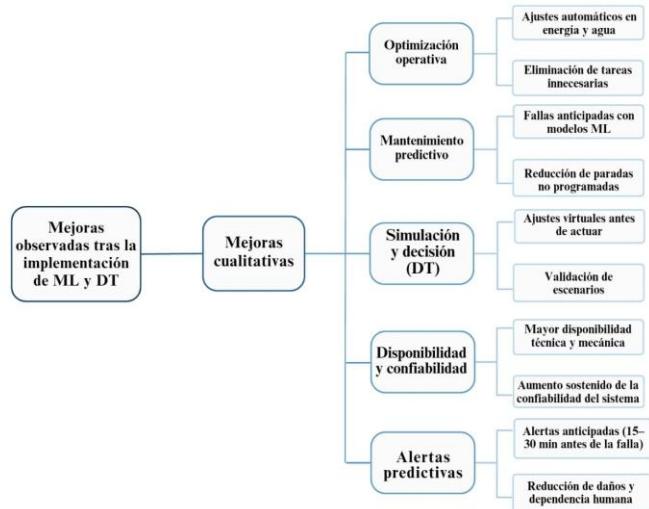


Fig. 8 Diagrama de mejoras cualitativas.

La Figura 9 ilustra las mejoras cuantitativas percibidas tras la integración de Machine Learning (ML) y Digital Twin (DT) en equipos de planta. Hablando desde la perspectiva de la optimización operativa, se observa una reducción del 7,62 % en el consumo energético del molino SAG y del 19,80 % en el proceso de flotación, logrando de manera significativa un ahorro en costos y energía, tanto en entornos de planta piloto como en condiciones reales [34], [50], [53], [54], [66], [71]. Con respecto al caso de las cintas transportadoras, la eficiencia operativa (medida a través de OEE) aumentó 13,10 %, favoreciendo la continuidad de procesos y la reducción de interrupciones [34], [50], [53], [54], [66], [71]. En cuanto al mantenimiento predictivo, la adopción de modelos ML, principalmente redes neuronales y random forest integradas a DT de fidelidad media, permitió una reducción de hasta 50 % en costos de mantenimiento de equipos críticos, evidenciando la capacidad de anticipar fallas y optimizar intervenciones [1], [6], [10], [11], [13]–[74]. La disponibilidad de planta experimentó un incremento de 10 %, esto es gracias a la disminución de fallas no planificadas y a una mejor coordinación de operaciones [1], [3], [4]–[74]. Finalmente, la precisión de los modelos predictivos alcanzó 95 %, fortaleciendo la automatización de decisiones y la operación

segura y eficiente de los equipos [1], [2], [13], [16], [69]. Cabe mencionar que, pese a la consistencia de estos resultados, la heterogeneidad entre estudios, la variabilidad en condiciones operativas y la fidelidad media de los Digital Twins representan posibles fuentes de sesgo; por ello, la replicabilidad completa requiere documentación detallada de parámetros de sensores, frecuencia de muestreo y protocolos de integración.

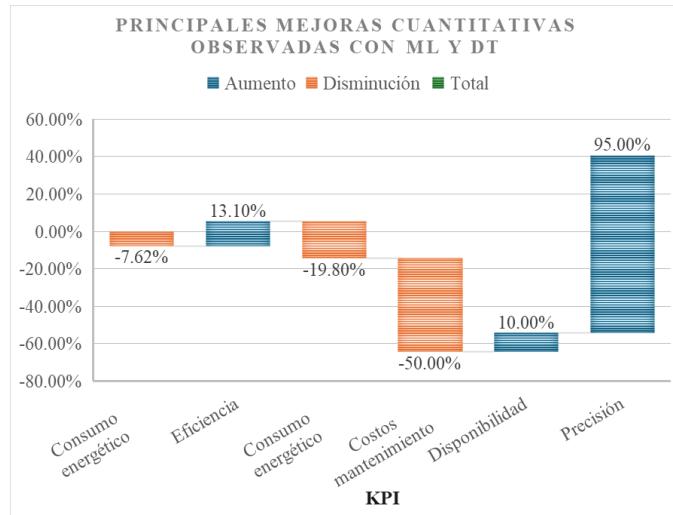


Fig. 9 Mejoras cuantitativas observadas con ML y DT.

## V. DISCUSIÓN

En este estudio de revisión se identificó que gran parte de las limitaciones en la eficiencia operativa de los equipos en plantas mineras se deben al uso ineficiente de energía, al desgaste prematuro causado por operaciones fuera de los parámetros óptimos y a la ausencia de estrategias de mantenimiento predictivo [10], [36]. Frente a los modelos tradicionales, la integración de Machine Learning (ML) y Digital Twin (DT) demostró ser más eficaz al permitir la anticipación de fallas, la optimización de condiciones operativas y la reducción de tiempos de inactividad no planificados [2], [15]. En procesos como flotación y molienda, se registró una disminución del consumo energético del 7.62 % mediante el ajuste de parámetros operativos [50], mientras que otros estudios reportaron reducciones de hasta 19.8 % al implementar ajustes automáticos basados en algoritmos inteligentes [54]. A diferencia de enfoques correctivos, esta integración posibilitó una reducción del 50 % en los costos de mantenimiento al evitar fallas críticas y mantenimientos innecesarios [39]. Asimismo, la velocidad de respuesta mejoró considerablemente: se detectaron fallas con más de 15 minutos de anticipación [1], y sistemas con visualización actualizada cada dos segundos permitieron decisiones inmediatas [40]. En términos de indicadores de rendimiento, algunos casos mostraron un aumento del 21 % en el OEE [64], y una reducción de hasta 283 minutos en el tiempo ocioso de camiones por turno [38], lo que evidencia un impacto positivo directo. No obstante, a diferencia de investigaciones empíricas, ciertos trabajos sólo ofrecen beneficios proyectados, sin validación práctica ni medición de KPIs [17], [47]. En conjunto,

los resultados consolidan el potencial del enfoque ML-DT para transformar la eficiencia operativa minera mediante análisis predictivo, operación informada y mantenimiento optimizado.

## VI. CONCLUSIÓN

Esta investigación identificó los procesos dentro de las plantas mineras que obtienen mayores beneficios al integrar Aprendizaje Automático (ML) y Gemelos Digitales (DT), evidenciando mejoras sustanciales en la eficiencia operativa, especialmente en las etapas de flotación y en el uso de cintas transportadoras. En el proceso de flotación, se logró una disminución del consumo energético entre 7.62% y 19.8%, atribuida a la optimización en la dosificación de reactivos y al monitoreo continuo de variables críticas. Por su parte, las cintas transportadoras incrementaron su eficiencia en un 13.10% mediante el ajuste dinámico de velocidad y carga.

Asimismo, la combinación de modelos predictivos con simulaciones de fallas demostró ser más eficaz que el uso aislado de estas tecnologías, permitiendo una reducción del 50% en los costos de mantenimiento de equipos críticos. Esta estrategia también incrementó la disponibilidad operativa en un 10%, al minimizar paradas inesperadas y fortalecer la confiabilidad de los sistemas. Los modelos alcanzaron una precisión del 95%, lo que facilitó la detección temprana de anomalías y la implementación de respuestas proactivas ante posibles fallos.

En síntesis, la integración de ML y DT resultó especialmente efectiva en equipos con condiciones operativas variables y tiempos de respuesta exigentes, optimizando el rendimiento energético, mejorando la gestión del mantenimiento y consolidando una operación minera más digital, eficiente y sostenible.

## REFERENCES

- [1] M. Zeb et al., "Digital Twin framework for fault detection in flotation circuits using deep learning", Reliab. Eng. Syst. Saf., vol. 241, 110709, 2024. doi: 10.1016/j.ress.2024.110709.
- [2] J. Viveros Gunckel et al., "Predictive maintenance of belt conveyors in mining using DT and ML integration", Comput. Ind. Eng., vol. 190, 110805, 2024. doi: 10.1016/j.cie.2024.110805.
- [3] H. Alzaabi, M. A. Hossain, y A. A. Alkassasbeh, "A hybrid model for predictive maintenance in mining using IoT and machine learning," Sensors, vol. 17, no. 3, Art. no. 406, 2024. doi: 10.3390/sym17030406
- [4] J. Li et al., "Optimizing dispatching in mining via deep reinforcement learning", Comput. Oper. Res., vol. 161, 106815, 2024. doi: 10.1016/j.cor.2024.106815.
- [5] Martínez et al., "Application of AI in mineral processing plant optimization", Miner. Eng., vol. 208, 108867, 2024. doi: 10.1016/j.mineng.2024.108867.
- [6] L. Xu et al., "AI-based predictive systems in mining operations", Adv. Ind. Manuf. Eng., vol. 6, 100146, 2024. doi: 10.1016/j.aime.2024.100146.
- [7] S. K. Sahoo et al., "A comprehensive review of digital twin architectures and integration challenges," Automation in Construction, vol. 159, 105642, 2024. doi: 10.1016/j.autcon.2024.105642
- [8] J. Zhang et al., "A probabilistic approach to model uncertainty in predictive maintenance systems," Tunnelling and Underground Space Technology, vol. 142, 106054, 2024. doi: 10.1016/j.tust.2024.106054

- [9] L. Bai et al., "Risk-based approach to digital twin-driven decision-making for mining operations," *Results in Engineering*, vol. 23, Art. no. 103057, 2024. doi: 10.1016/j.rineng.2024.103057
- [10] S. Y. Jang, D. W. Kim, y M. K. Lee, "Production efficiency analysis using data-driven approaches in digital twin systems," *Computers & Industrial Engineering*, vol. 187, 110268, 2024. doi: 10.1016/j.cie.2024.110268
- [11] S. Kumar, S. Gupta, y M. Goyal, "A survey on applications of digital twin in industry," *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 3, 2024. doi: 10.14569/IJACSA.2024.0150332
- [12] C. Jiang et al., "Explainable AI in industrial fault diagnosis: A review," *Frontiers in Artificial Intelligence*, vol. 7, Art. no. 1453931, 2024. doi: 10.3389/frai.2024.1453931
- [13] M. Ahmed et al., "Hybrid neural network approach for real-time condition monitoring in mining conveyors," *Computers, Materials & Continua*, vol. 77, no. 3, pp. 4105–4120, 2023. doi: 10.32604/cmcs.2023.028018
- [14] Mohamed et al., "Digital twin integration for intelligent maintenance in process industries," *International Journal of Production Economics*, vol. 256, 109034, 2023. doi: 10.1016/j.ijpe.2023.109034
- [15] Y. Zhang et al., "A survey on smart maintenance using digital twins and machine learning," *MIS Quarterly Executive*, 2024. doi: 10.1007/s10796-024-10476-z
- [16] Y. Wang et al., "A framework for predictive maintenance in mining based on anomaly detection," *Applied Sciences*, vol. 13, no. 6, 4028, 2023. doi: 10.3390/app13064028
- [17] S. T. Yu et al., "Digital twin implementation for smart manufacturing systems," *Manufacturing Letters*, vol. 38, pp. 1–5, 2023. doi: 10.1016/j.mfglet.2023.08.014
- [18] M. Wang et al., "Design and Implementation of an Automatic Emulsion Dispensing and Remote Monitoring System Based on IoT Platform," *IEEE Access*, vol. 11, 2023. doi: 10.1109/ACCESS.2023.3316254.
- [19] F. Escorcia et al., "Machine learning and data analytics for predictive maintenance in mining: Gaps and perspectives," *Mining*, vol. 1, no. 1, pp. 1–18, 2024. doi: 10.3390/mining2010006
- [20] L. A. Lopez et al., "Digital twin architecture for smart mining: A data fusion perspective," *Mining*, vol. 12, no. 2, Art. no. 0210, 2022. doi: 10.3390/min12020210
- [21] C. Bavelos, E. Anastasiou, N. Dimitropoulos, G. Michalos, and S. Makris, "Virtual reality-based dynamic scene recreation and robot teleoperation for hazardous environments," *Computer-Aided Civil and Infrastructure Engineering*, Jan. 2024, doi: 10.1111/mice.13337.
- [22] T. Li, B. Chang, Y. Sun, Y. Zhou, B. Zhou, and L. Zhang, "Development and application of a generalized fatigue driving monitoring system for open-pit mining vehicles: A case study in a myanmar copper mine," *Results in Engineering*, vol. 26, Jun. 2025. doi: 10.1016/j.rineng.2025.105206.
- [23] Y. H. Chang, F. C. Wu, and H. W. Lin, "Design and Implementation of ESP32-Based Edge Computing for Object Detection," *Sensors*, vol. 25, no. 6, Mar. 2025. doi: 10.3390/s25061656.
- [24] R. S. Mendonca, M. da Silva, F. A. C. Ayres, I. v. Bessa, R. L. P. Medeiros, and V. F. Lucena, "Development of a Novel Retrofit Framework Considering Industry 4.0 Concepts: A Case Study of a Modular Production System," *Processes*, vol. 13, no. 1, Jan. 2025. doi: 10.3390/pr13010136.
- [25] P. Viveros, C. Moya, R. Mena, F. Kristjanpoller, and D. R. Godoy, "An Integrated Approach: A Hybrid Machine Learning Model for the Classification of Unscheduled Stoppages in a Mining Crushing Line Employing Principal Component Analysis and Artificial Neural Networks," *Sensors*, vol. 24, no. 17, Sep. 2024. doi: 10.3390/s24175804.
- [26] Q. Jin, H. Chen, and F. Hu, "Proposal of Industry 5.0-Enabled Sustainability of Product-Service Systems and Its Quantitative Multi-Criteria Decision-Making Method," *Processes*, vol. 12, no. 3, Mar. 2024. doi: 10.3390/pr12030473.
- [27] T. Zhang, T. Fu, T. Ni, H. Yue, Y. Wang, and X. Song, "Data-driven excavation trajectory planning for unmanned mining excavator," *Automation in Construction*, vol. 162, Jun. 2024. doi: 10.1016/j.autcon.2024.105395.
- [28] O. Hasidi et al., "Data-driven system for intelligent monitoring and optimization of froth flotation circuits using Artificial Neural Networks and Genetic Algorithms," *Journal of Process Control*, vol. 137, May 2024. doi: 10.1016/j.jprocont.2024.103198.
- [29] J. Metcalfe, C. Ellul, J. Morley, and J. Stoter, "Characterizing the Role of Geospatial Science in Digital Twins," *ISPRS International Journal of Geo-Information*, vol. 13, no. 9, p. 320, Sep. 2024. doi: 10.3390/ijgi13090320.
- [30] N. el Bazi et al., "Scalable Compositional Digital Twin-Based Monitoring System for Production Management: Design and Development in an Experimental Open-Pit Mine," *Designs*, vol. 8, no. 3, Jun. 2024. doi: 10.3390/designs8030040.
- [31] Z. Huang, S. Ge, Y. He, D. Wang, and S. Zhang, "Research on the Intelligent System Architecture and Control Strategy of Mining Robot Crowds," *Energies*, vol. 17, no. 8, Apr. 2024. doi: 10.3390/en17081834.
- [32] M. Baghdasaryan and V. Hovhannisyn, "Stability Assessment of an Ore Mill Electric Drive Using Machine Learning," *HighTech and Innovation Journal*, vol. 5, no. 2, pp. 213–230, Jun. 2024. doi: 10.28991/HIJ-2024-05-02-01.
- [33] P. Pääkkönen, S. Horsmanheimo, D. Pakkala, L. Tuomimäki, and J. Backman, "Reference architecture design and evaluation for digitalization of underground mining," *Internet of Things (Netherlands)*, vol. 26, Jul. 2024. doi: 10.1016/j.iot.2024.101238.
- [34] K. Herbuš et al., "Development and Validation of Concept of Innovative Method of Computer-Aided Monitoring and Diagnostics of Machine Components," *Applied Sciences (Switzerland)*, vol. 14, no. 21, Nov. 2024. doi: 10.3390/app142110056.
- [35] Rojek, T. Marciak, and D. Mikolajewski, "Digital Twins in 3D Printing Processes Using Artificial Intelligence," *Electronics (Switzerland)*, vol. 13, no. 17, Sep. 2024. doi: 10.3390/electronics13173550.
- [36] S. Y. Baroud, N. A. Yahaya, and A. M. Elzamly, "Cutting-Edge AI Approaches with MAS for PdM in Industry 4.0: Challenges and Future Directions," *Journal of Applied Data Sciences*, vol. 5, no. 2, pp. 455–473, May 2024. doi: 10.47738/jads.v5i2.196.
- [37] M. Mosca, R. Mosca, and M. Braggio, "Big Data and AI for Smart Maintenance: Literature review on the impact on plants Resilience," in *Procedia Computer Science*, Elsevier B.V., 2025, pp. 1959–1971. doi: 10.1016/j.procs.2025.01.258.
- [38] K. Liu, B. Mei, Q. Li, S. Sun, and Q. Zhang, "Collaborative Production Planning Based on an Intelligent Unmanned Mining System for Open-Pit Mines in the Industry 4.0 Era," *Machines*, vol. 12, no. 6, Jun. 2024. doi: 10.3390/machines12060419.
- [39] K. V. Kharchenko, A. Zh. Zubets, E. I. Moskvitina, L. K. Babayan, and A. M. Laffah, "Analyzing the efficiency of implementing predictive maintenance of mining equipment based on Industry 4.0 technologies," *Mining Industry Journal (Gornaya Promishlennost)*, no. 4/2024, pp. 130–138, Aug. 2024. doi: 10.30686/1609-9192-2024-4-130-138.
- [40] Bendaouia et al., "Artificial intelligence for enhanced flotation monitoring in the mining industry: A ConvLSTM-based approach," *Computers and Chemical Engineering*, vol. 180, 2024. doi: 10.1016/j.compchemeng.2023.108476.
- [41] J. Mwanza, P. Mashumba, and A. Telukdarie, "A Framework for Monitoring Stability of Tailings Dams in Real-time Using Digital Twin Simulation and Machine Learning," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 2279–2288. doi: 10.1016/j.procs.2024.02.047.
- [42] S. A. Patil, N. P. Sable, P. N. Mahalle, and G. R. Shinde, "Intelligent Mechanisms for PdM in Automotive Machinery: A Comprehensive Analysis using ML/DL," *Journal of Electrical Systems*, vol. 19, no. 2, 2023. doi: 10.52783/jes.697.
- [43] X. Liang, J. Wu, and K. Ruan, "Simulation Modeling and Temperature Over-Advance Perception of Mine Hoist System Based on Digital Twin Technology," *Machines*, vol. 11, no. 10, 2023. doi: 10.3390/machines11100966.
- [44] L. S. Santos, E. N. Macêdo, P. R. C. F. Ribeiro Filho, A. P. A. Cunha, and N. Cheung, "Belt Rotation in Pipe Conveyors: Failure Mode Analysis and Overlap Stability Assessment," *Sustainability (Switzerland)*, vol. 15, no. 14, 2023. doi: 10.3390/su151411312.
- [45] F. Abu-Abed and S. Zhironkin, "New Game Artificial Intelligence Tools for Virtual Mine on Unreal Engine," *Applied Sciences (Switzerland)*, vol. 13, no. 10, 2023. doi: 10.3390/app13106339.
- [46] R. Yu, X. Yang, and K. Cheng, "Deep learning and IoT enabled digital twin framework for monitoring open-pit coal mines," *Frontiers in Energy Research*, vol. 11, 2023. doi: 10.3389/fenrg.2023.1265111.
- [47] N. el Bazi et al., "Generic Multi-Layered Digital-Twin-Framework-Enabled Asset Lifecycle Management for the Sustainable Mining Industry," *Sustainability (Switzerland)*, vol. 15, no. 4, 2023. doi: 10.3390/su15043470.
- [48] O. Dayo-Olupona, B. Genc, T. Celik, and S. Bada, "Adoptable approaches to predictive maintenance in mining industry: An overview," *Resources Policy*, vol. 86, 2023. doi: 10.1016/j.resourpol.2023.104291.
- [49] Bendaouia et al., "Advancing Flotation Process Optimization Through Real-Time Machine Vision Monitoring: A Convolutional Neural Network Approach," in *International Joint Conference on Knowledge*

- Discovery, Knowledge Engineering and Knowledge Management, IC3K - Proceedings, 2023. doi: 10.5220/001223730003598.
- [50] M. Saldaña, E. Gálvez, A. Navarra, N. Toro, and L. A. Cisternas, "Optimization of the SAG Grinding Process Using Statistical Analysis and Machine Learning: A Case Study of the Chilean Copper Mining Industry," Materials, vol. 16, no. 8, 2023, doi: 10.3390/ma16083220.
- [51] J. Swanepoel, J. C. Vosloo, J. H. van Laar, and W. A. Pelser, "Prioritisation of Environmental Improvement Projects in Deep-Level Mine Ventilation Systems," Mining, Metallurgy and Exploration, vol. 40, no. 2, 2023, doi: 10.1007/s42461-023-00738-w.
- [52] Quelopana, J. Órdenes, R. Wilson, and A. Navarra, "Technology Upgrade Assessment for Open-Pit Mines through Mine Plan Optimization and Discrete Event Simulation," Minerals, vol. 13, no. 5, 2023, doi: 10.3390/min13050642.
- [53] M. Oheoja et al., "Continuous adaptation of a digital twin model for a pilot flotation plant," Minerals Engineering, vol. 198, 2023, doi: 10.1016/j.mineng.2023.108081.
- [54] T. Fu, T. Zhang, Y. Lv, X. Song, G. Li, and H. Yue, "Digital twin-based excavation trajectory generation of Uncrewed excavators for autonomous mining," Automation in Construction, vol. 151, 2023, doi: 10.1016/j.autcon.2023.104855.
- [55] V. R. Gasimov, P. A. Bovshik, B. M. Loginov, A. S. Karandaev, V. R. Khramshin, and A. A. Radionov, "Substantiating and Implementing Concept of Digital Twins for Virtual Commissioning of Industrial Mechatronic Complexes Exemplified by Rolling Mill Coilers," Machines, vol. 11, no. 2, 2023, doi: 10.3390/machines11020276.
- [56] Management System: Design of a Monitoring and Peak Load Forecasting System for an Experimental Open-Pit Mine," Applied System Innovation, vol. 5, no. 1, 2022, doi: 10.3390/as15010018.
- [57] M. Yaqot, R. E. Franzoi, A. Islam, and B. C. Menezes, "Cyber-Physical System Demonstration of an Automated Shuttle-Conveyor-Belt Operation for Inventory Control of Multiple Stockpiles: A Proof of Concept," IEEE Access, vol. 10, 2022, doi: 10.1109/ACCESS.2022.3226942.
- [58] F. Zhang, J. Tian, J. Wang, G. Liu, and Y. Liu, "ECViST: Mine Intelligent Monitoring Based on Edge Computing and Vision Swin Transformer-YOLOv5," Energies, vol. 15, no. 23, 2022, doi: 10.3390/en15239015.
- [59] J. Savolainen and M. Urbani, "Maintenance optimization for a multi-unit system with digital twin simulation: Example from the mining industry," Journal of Intelligent Manufacturing, vol. 32, no. 7, 2021, doi: 10.1007/s10845-021-01740-z.
- [60] F. Peña-Graf, J. Órdenes, R. Wilson, and A. Navarra, "Discrete Event Simulation for Machine-Learning Enabled Mine Production Control with Application to Gold Processing," Metals, vol. 12, no. 2, 2022, doi: 10.3390/met12020225.
- [61] Hazrathosseini and A. Moradi Afrapoli, "The advent of digital twins in surface mining: Its time has finally arrived," Resources Policy, vol. 80, 2023, doi: 10.1016/j.resourpol.2022.103155.
- [62] R. Liang, C. Huang, C. Zhang, B. Li, S. Saydam, and I. Canbulat, "Exploring the Fusion Potentials of Data Visualization and Data Analytics in the Process of Mining Digitalization," IEEE Access, vol. 11, pp. 40608–40628, 2023, doi: 10.1109/ACCESS.2023.3267813.
- [63] W. Chen, Z. Li, B. Hao, J. Gao, and M. Fan, "A Machine Learning Based Intelligent Decision Support System for Flotation Dynamics in Simulation of Clay Minerals," Scientific Programming, vol. 2022, 2022, doi: 10.1155/2022/7893940.
- [64] V. Tripathi et al., "A Sustainable Productive Method for Enhancing Operational Excellence in Shop Floor Management for Industry 4.0 Using Hybrid Integration of Lean and Smart Manufacturing: An Ingenious Case Study," Sustainability (Switzerland), vol. 14, no. 12, 2022, doi: 10.3390/su14127452.
- [65] G. Bai and T. Xu, "Coal Mine Safety Evaluation Based on Machine Learning: A BP Neural Network Model," Computational Intelligence and Neuroscience, vol. 2022, 2022, doi: 10.1155/2022/5233845.
- [66] E. Bondoc, M. Tayefeh, and A. Barari, "LIVE Digital Twin: Developing a Sensor Network to Monitor the Health of Belt Conveyor System," in IFAC-PapersOnLine, 2022. doi: 10.1016/j.ifacol.2022.09.182.
- [67] Y. Bao, X. Zhang, T. Zhou, Z. Chen, and X. Ming, "Application of Industrial Internet for Equipment Asset Management in Social Digitalization Platform Based on System Engineering Using Fuzzy DEMATEL-TOPSIS," Machines, vol. 10, no. 12, 2022, doi: 10.3390/machines10121137.
- [68] H. Shi, J. Xie, X. Wang, J. Li, and X. Ge, "An operation optimization method of a fully mechanized coal mining face based on semi-physical virtual simulation," International Journal of Coal Science and Technology, vol. 7, no. 1, 2020, doi: 10.1007/s40789-019-00282-3.
- [69] L. Chen, X. Hu, G. Wang, D. Cao, L. Li, and F. Y. Wang, "Parallel mining operating systems: From digital twins to mining intelligence," in Proceedings 2021 IEEE 1st International Conference on Digital Twins and Parallel Intelligence, DTPI 2021, 2021. doi: 10.1109/DTPI52967.2021.9540195.
- [70] D. N. Sizemov, I. O. Temkin, S. A. Deryabin, and D. Y. Vladimirov, "ON SOME ASPECTS OF INCREASING THE TARGET PRODUCTIVITY OF UNMANNED MINE DUMP TRUCKS," Eurasian Mining, vol. 36, no. 2, 2021, doi: 10.17580/em.2021.02.15
- [71] Sun, C. Yang, Y. Wang, W. Gui, I. Craig, and L. Olivier, "A comprehensive hybrid first principles/machine learning modeling framework for complex industrial processes," Journal of Process Control, vol. 86, 2020, doi: 10.1016/j.jprocont.2019.11.012.
- [72] R. Gao, K. Zhou, C. Yang, and K. Zhu, "An Underground Mine Risk Identification Model and Safety Management Method Based on Explanation Graph-Probabilistic Multi-Plan Analysis (EG-PMPA)," IEEE Access, vol. 8, 2020, doi: 10.1109/ACCESS.2020.3045339.
- [73] R. Hu, D. An, M. Shi, W. Lu, N. Sun, H. Zhang, and J. Xu, "Research status and development trends of intelligent mining robots," Gold, no. 9, pp. 59–68, Sep. 2023. doi: 10.11792/hj20230910.
- [74] I. Beloglazov, P. A. Petrov, and V. Y. Bazhin, "The concept of digital twins for tech operator training simulator design for mining and processing industry," Eurasian Mining, vol. 2020, no. 2, pp. 50–54, 2020, doi: 10.17580/em.2020.02.12.
- [75] M.-S. Hosseini et al., "Formulating research questions for evidence-based studies," J. Med. Surg. Public Health, vol. 2, Art. no. 100046, 2024. DOI: 10.1016/j.glmedi.2023.100046.
- [76] M. J. Page et al., "Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas," Rev. Esp. Cardiol., vol. 74, no. 9, pp. 790–799, 2021. DOI: 10.1016/j.recesp.2021.06.016.