

Programación de Operaciones en Manufactura Inteligente: Estado del Arte de la Industria 4.0.

Smart Manufacturing Operations Scheduling: State of the Art in Industry 4.0.

Oscar Gildardo Hernández Alomía¹

Claudia Esperanza Castiblanco Lara²

Alicia Cristina Silva Calpa³

¹ Doctor en Ingeniería de Procesos.

Universidad Nacional Abierta y a Distancia – UNAD.

ORCID: <https://orcid.org/0000-0002-0054-672X>

oscarg.hernandez@unad.edu.co

² Magíster en Salud Pública y Desarrollo Social.

Fundación Universitaria del Área Andina – Areandina.

ORCID: <https://orcid.org/0000-0003-0852-1241>

Ccastiblanco4@areandina.edu.co

³ Administradora de Empresas. Especialista en Pedagogía. Magíster en Sistemas de Calidad y Productividad. Doctora en Administración.

Universidad Nacional Abierta y a Distancia – UNAD.

ORCID: <https://orcid.org/0000-0002-9329-0777>

Alicia.silva@unad.edu.co

RESUMEN.

La programación de operaciones (scheduling) ha evolucionado hacia una función adaptativa y conectada en sistemas ciberfísicos y plataformas cloud. Esta transición, analizada en un periodo que abarca desde 1980 hasta 2025 bajo la metodología PRISMA, revela una convergencia hacia enfoques híbridos que integran simulación de eventos discretos, optimización matemática y aprendizaje por refuerzo para gestionar la complejidad de la Industria 4.0. En este ecosistema, los Digital Twins actúan como la infraestructura crítica para sincronizar la planta física con la toma de decisiones, mientras que el Deep Reinforcement Learning (DRL) y las redes de grafos destacan en entornos dinámicos por su capacidad de reprogramación en tiempo real. Aunque persisten retos en escalabilidad e interpretabilidad, el valor actual de la programación de operaciones trasciende la optimización clásica al incorporar resiliencia, trazabilidad y una alta capacidad de reacción ante perturbaciones industriales. Esta investigación ofrece una taxonomía comparativa de métodos de diversos autores a través de una línea histórica.

Palabras Clave.

Industria manufacturera; Ingeniería de la producción; Innovación, Aprendizaje; Programación informática.

ABSTRACT.

Production scheduling has evolved into an adaptive and connected function within cyber-physical systems and cloud platforms. This transition, analyzed over a period spanning from 1980 to 2025 using the PRISMA methodology, reveals a convergence toward hybrid approaches that integrate discrete event simulation, mathematical optimization, and reinforcement learning to manage the complexity of Industry 4.0. In this ecosystem, Digital Twins emerge as the critical infrastructure for synchronizing the physical plant with decision-making, while Deep Reinforcement Learning (DRL) and graph neural networks stand out in dynamic environments due to their real-time rescheduling capabilities. Although challenges in scalability and interpretability persist, the current value of operations scheduling

transcends classical optimization by incorporating resilience, traceability, and a high capacity for reacting to industrial disturbances. This research provides a comparative taxonomy of methods from various authors through a historical timeline.

Keywords.

Manufacturing Industry; Production engineering; Innovation; Learning; Computer programming.

INTRODUCCIÓN.

Dentro de la ingeniería de producción y de la investigación de operaciones la programación de operaciones constituye históricamente una de las áreas fundacionales ya que permite organizar la asignación de recursos, la secuencia de trabajos y la sincronización temporal de actividades dentro de un sistema productivo. Durante décadas, los problemas clásicos de job shop, flow shop y flexible job shop fueron abordados mediante formulaciones exactas, heurísticas y reglas de despacho orientadas a la minimización o makespan, tardanza o utilización de máquinas. Sin embargo, la emergencia de la manufactura inteligente transformó radicalmente el contexto del problema en la industria (Ngwu et al., 2025; Nieves et al., 2024).

Por otra parte, en la transición hacia la Industria 4.0, la programación de operaciones se realiza sobre sistemas ciberfísicos conectados, donde sensores, dispositivos IoT, plataformas MES/ERP, analítica avanzada y comunicación máquina a máquina generan nuevas condiciones de decisión (Ivanov et al., 2020). Las fábricas inteligentes no solo producen datos en tiempo real, sino que exigen que dichos datos se conviertan en acciones reactivas y proactivas capaces de sostener la continuidad operativa, la resiliencia y la eficiencia ante posibles perturbaciones. Es por esta razón que el scheduling actual se mueve desde una lógica estática hacia una lógica adaptativa, distribuida y basada en analítica de datos (Ivanov et al., 2020; Agostino et al., 2020).

Las contribuciones más influyentes según los estudios muestran tres vectores de transformación. El primero es la aparición de arquitecturas inteligentes como cloud manufacturing, control holónico y sistemas CPPS, que permiten la coordinación distribuida y la flexibilidad estructural. El segundo es la consolidación del Digital Twin como infraestructura de representación y simulación sincronizada con la planta (Latsou et al., 2024; Da Silva et al., 2025). El tercero es el avance de la inteligencia artificial, principalmente del aprendizaje profundo por refuerzo, usado como estrategia para aprender políticas de scheduling en el dominio de estados del sistema de gran escala (Del Real Torres et al., 2022; Zhang et al., 2020).

Este artículo visibiliza dichos avances reflejando la evolución del scheduling entre 2017 y 2025 hacia arquitecturas de manufactura inteligente y el reconocimiento de enfoques como Digital Twins, DRL, metaheurísticas y modelos exactos cuya característica representan mayor pertinencia a la hora de tomar decisiones para un scheduling más dinámico, escalable y robusto en entornos CPPS.

METODOLOGÍA.

La presente investigación se desarrolló mediante una revisión sistemática de literatura, siguiendo las directrices de la declaración PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) propuestas por Álvarez Tinajero, et al., (2026). Este enfoque metodológico permitió identificar, seleccionar, evaluar y sintetizar evidencia científica de forma rigurosa, transparente y reproducible, siendo especialmente pertinente en el campo interdisciplinario de la manufactura inteligente y su convergencia con la ingeniería de procesos, la analítica avanzada y la inteligencia artificial.

El estudio se estructura en cinco bloques: metodología de revisión sistemática, marco teórico, resultados temáticos del estado del arte, taxonomía comparativa de métodos y conclusiones con identificación de brechas de investigación. En este contexto, la pregunta de investigación plantea, ¿cómo ha evolucionado la programación de operaciones en manufactura inteligente e Industria 4.0, y qué

enfoques como Digital Twins, aprendizaje profundo por refuerzo (DRL), metaheurísticas y modelos exactos, muestran mayor pertinencia en términos de capacidad adaptativa, escalabilidad y robustez en entornos de sistemas ciberfísicos de producción (CPPS)?

Por su parte, el objetivo general busca sintetizar y comparar los enfoques contemporáneos de scheduling en manufactura inteligente, identificando tendencias tecnológicas, marcos conceptuales, algoritmos dominantes, herramientas de software y brechas de investigación. Para ello, se busca construir una taxonomía operativa de métodos que integre modelos exactos, metaheurísticas, DRL y Digital Twins con simulación de eventos discretos; desarrollar un análisis comparativo entre estos enfoques, las relaciones entre autores, algoritmos y líneas de investigación; la evolución histórica e identificar limitaciones recurrentes y líneas futuras en términos de escalabilidad, interpretabilidad, robustez y validación industrial.

La estrategia de búsqueda se orientó a literatura científica indexada en bases de datos como Scopus, Web of Science y repositorios especializados, priorizando estudios de alto impacto en el sector real. La ecuación de búsqueda combinó términos clave como production scheduling, smart manufacturing, Industry 4.0, Digital Twin, CPPS, deep reinforcement learning, metaheuristics y graph neural networks, lo que permitió captar estudios conceptuales, estudios empíricos, desarrollos metodológicos y aplicaciones en entornos industriales.

La metodología de esta revisión sistemática se basó en el protocolo PRISMA, analizando un periodo principal entre 2017 y 2025 debido al auge de la manufactura inteligente y el Deep Reinforcement Learning (Del Real Torres et al., 2022; Nievas et al., 2024), sin omitir aportes fundacionales previos. Tras un riguroso proceso de cribado que priorizó modelos verificables en sistemas ciberfísicos, Digital Twins y metaheurísticas, se consolidó un corpus de 14 artículos científicos de alto impacto (Q1). Esta muestra garantiza una base analítica sólida sobre la frontera del conocimiento en inteligencia artificial aplicada al scheduling.

La información se procesó mediante una síntesis temática e interpretación crítica, organizando los hallazgos según algoritmos, métricas de desempeño y niveles de validación. Esta sistematización permitió estructurar el estado del arte en líneas clave como cloud manufacturing, control en tiempo real y arquitecturas distribuidas. En conjunto, esta estrategia metodológica evidencia la transición desde enfoques centralizados hacia sistemas inteligentes y adaptativos, facilitando la identificación de tendencias emergentes y aportes industriales concretos para la Industria 4.0.

RESULTADOS.

Evolución histórica de la programación de operaciones. La programación de operaciones ha transitado desde modelos deterministas hacia sistemas inteligentes altamente integrados. En la década de 1980, el campo se consolidó mediante la investigación de operaciones clásica y modelos de Job Shop Scheduling Problem (JSSP) para optimizar el makespan. Durante los años noventa, el enfoque evolucionó hacia el uso de metaheurísticas y sistemas de planificación avanzada (APS), empleando algoritmos evolutivos para manejar una mayor complejidad, mientras que, en la década de 2000, la optimización multiobjetivo y la simulación de eventos discretos (DES) permitieron evaluaciones de desempeño más alineadas con la realidad industrial.

A partir de 2010, la irrupción de los sistemas ciberfísicos (CPPS), el IoT y el control distribuido transformó el scheduling en un proceso dinámico de reprogramación en tiempo real (Ivanov et al., 2020). Entre 2017 y 2020, la consolidación de la Industria 4.0 introdujo el cloud manufacturing y los Digital Twins, logrando una sincronización total entre el sistema físico y su réplica digital, lo que facilitó esquemas de control adaptativo fundamentados en datos y simulación continua (Agostino et al., 2020; Latsou et al., 2024).

En el periodo 2020–2023, la inteligencia artificial se consolidó mediante el aprendizaje profundo por refuerzo (DRL) y redes neuronales de grafos (GNN) para desarrollar políticas de decisión en entornos complejos (Zhang et al., 2020; Echeverria et al., 2023). Finalmente, entre 2023 y 2025, la tendencia viró hacia

enfoques híbridos y escalables que integran simulación, optimización e IA para maximizar la robustez en plantas digitalizadas (Moon et al., 2024; Ngwu et al., 2025; Nievas et al., 2024). Esta evolución marca un cambio de paradigma: el scheduling ya no es un problema estático, sino un sistema adaptativo capaz de aprender y reaccionar en tiempo real.

Figura 1

Evolución histórica de la programación de operaciones (1980–2025)




Nota. La Figura 1 ubica los hitos más representativos del campo, desde el dominio de reglas de despacho y metaheurísticas hasta la consolidación de Digital Twins, DRL y enfoques híbridos. *Fuente.* Elaboración propia.

Tradiciones teóricas y metodológicas del campo. En el campo de la programación de operaciones se sustenta un esqueleto de tradiciones teóricas y metodológicas que durante la historia han evolucionado de manera convergente, configurando un nuevo marco de carácter interdisciplinario que articula la optimización matemática, la ingeniería de sistemas, la digitalización industrial y la inteligencia artificial. En este sentido, pueden identificarse cuatro tradiciones interconectadas que explican la transformación del scheduling hacia su forma contemporánea (Ngwu et al., 2025; Nievas et al., 2024; Del Real Torres et al., 2022).

La evolución del *scheduling* se sintetiza en cuatro tradiciones interconectadas: la investigación de operaciones clásica (MILP/MINLP), la teoría de sistemas de control distribuido y holónico, el ecosistema de la Industria 4.0 (IoT y CPPS) y la emergencia del aprendizaje profundo por refuerzo (DRL), en la transición hacia el *cloud manufacturing*, demostrando cómo la conectividad por plataformas digitales complejiza la gestión de recursos distribuidos (Ivanov et al., 2020). Por su parte, Mourtzis destaca la integración de tecnologías habilitantes como 5G y analítica en el control adaptativo, mientras que Khadivi et al. (2023) y Moon et al. (2024) expanden la frontera del aprendizaje por refuerzo hacia taxonomías de *scheduling* y enfoques basados en grafos. Bajo esta perspectiva, el sector evoluciona hacia una adaptación, explicabilidad y sostenibilidades necesarias, validadas mediante la simulación en gemelos digitales y sistemas inteligentes de producción (Agostino et al., 2020; Latsou et al., 2024).

Figura 2

Evolución del Scheduling



Fuente: Elaboración propia

Scheduling en Cloud Manufacturing y Servitización. El Cloud Manufacturing y la servitización han trasladado el *scheduling* desde el taller aislado hacia redes de recursos productivos globales y conectados. En este esquema, la programación no solo gestiona secuencias de trabajo, sino que debe

optimizar variables como la latencia, el costo y el nivel de servicio en recursos distribuidos. Autores como Ivanov, Sokolov y Dolgui (2020) sistematizan esta evolución, integrando procesos flexibles y comunicación máquina-producto en una manufactura orientada a servicios. Metodológicamente, este enfoque impulsa el uso de modelos data-driven y métodos de descomposición para operar en ecosistemas digitales heterogéneos. Debido a la alta complejidad y la necesidad de responder a perturbaciones en tiempo real, la literatura actual (Ngwu et al., 2025; Nievas et al., 2024) apuesta por enfoques híbridos que combinan modelos exactos con control reactivo y heurísticas con heurísticas y control reactivo (Ngwu et al., 2025; Nievas et al., 2024).

Los Digital Twins (DT) se consolidan como una de las tecnologías más influyentes al permitir una representación digital sincronizada con el sistema físico, integrando sensores, datos MES/ERP, simulación y analítica para el control en tiempo real. Autores como Agostino et al. (2020) demuestran cómo este enfoque transforma el scheduling de una decisión estática en una función reactiva y optimizada según el estado del piso de producción. Por su parte, Zhang et al. (2023) avanzan hacia modelos jerárquicos que incorporan aprendizaje por refuerzo para la colaboración hombre-máquina, mientras que Latsou et al. (2024) proponen marcos unificados para garantizar la escalabilidad y reutilización industrial de estos gemelos.

Complementariamente, investigaciones recientes como las de Da Silva et al. (2025) subrayan que los DT integran Big Data, IoT y Machine Learning para el control adaptativo en procesos de mecanizado. En conjunto, la literatura refleja una tendencia hacia núcleos metodológicos que combinan gemelos digitales, simulación de eventos discretos y algoritmos de inteligencia artificial para una planificación dinámica y resiliente en la Industria 4.0.

Control holónico y arquitecturas distribuidas. La arquitectura de control holónico y los sistemas distribuidos resurgen como una solución clave para la autonomía y cooperación en la producción. Bajo este paradigma, entidades como máquinas y productos actúan como holones capaces de negociar y reaccionar

localmente, eliminando la dependencia de un planificador central. Este enfoque es especialmente valioso en entornos reconfigurables con alta variabilidad y perturbaciones constantes (Ngwu et al., 2025; Nievas et al., 2024). Lejos de reemplazar la optimización clásica, las arquitecturas holónicas la complementan al integrarse con sistemas ciberfísicos e IoT. Según Ngwu et al. (2025), esta sinergia promueve la descentralización de decisiones, fortaleciendo la flexibilidad operativa y la capacidad de respuesta en entornos dinámicos y de alta incertidumbre propios de la Industria 4.0.

El Deep Reinforcement Learning (DRL) se ha consolidado como una línea de investigación crítica al modelar el scheduling como un proceso de decisión de Markov, donde agentes aprenden políticas de secuenciación mediante la interacción con entornos digitales (Del Real Torres et al., 2022). Autores como Khadivi et al. (2023) clasifican estos métodos en arquitecturas convencionales, híbridas y redes de grafos, destacando que, aunque el DRL supera en velocidad a las soluciones exactas en entornos dinámicos, aún enfrenta desafíos en interpretabilidad y escalabilidad (Nievas et al., 2024).

Una tendencia vanguardista es el uso de representaciones gráficas para mejorar la generalización en problemas complejos; Moon, Lee y Park (2024) proponen el Heterogeneous Graph Scheduler, mientras que Echeverria et al. (2023) y Zhang et al. (2020) utilizan grafos heterogéneos para representar recursos y reglas de despacho. En conjunto, el DRL desplaza el enfoque de la optimización de instancias únicas hacia el aprendizaje de políticas reutilizables, ofreciendo una ventaja competitiva en sistemas industriales que requieren toma de decisiones continua (Ngwu et al., 2025).

Metaheurísticas multiobjetivo y optimización clásica mejorada. A pesar del auge del Deep Reinforcement Learning (DRL) y los Digital Twins, la optimización clásica y las metaheurísticas multiobjetivo mantienen su relevancia en escenarios de alta complejidad. Según Rossit et al. (2024), estos enfoques son esenciales cuando se requiere interpretabilidad y el manejo de criterios contrapuestos, como el makespan y la tardanza ponderada, especialmente en entornos de flow shop

con operaciones faltantes. La validez de estos métodos, destacados por autores como Rossit, Nesmachnow y Márquez, reside en su aplicación en configuraciones industriales reales que superan los benchmarks idealizados. Asimismo, Nievas et al. (2024) subrayan la ductilidad de las metaheurísticas, las cuales permiten integrar rápidamente restricciones energéticas y preferencias de decisión, ofreciendo un despliegue más sencillo en comparación con los modelos de aprendizaje profundo en diversos contextos productivos.

Software, frameworks y herramientas aplicables. El ecosistema tecnológico del scheduling inteligente se estructura desde la simulación hasta la ejecución industrial, apoyándose en herramientas especializadas según el enfoque. Para modelos exactos, optimizadores como CPLEX, Gurobi y OR-Tools son los estándares (Ngwu et al., 2025), mientras que en el ámbito del Deep Reinforcement Learning (DRL) predominan PyTorch y TensorFlow, integrando redes neuronales de grafos para gestionar la complejidad moderna (Echeverria et al., 2023; Moon et al., 2024). A nivel operativo, la efectividad de estas soluciones depende de su integración con sistemas MES, APS, plataformas IoT y arquitecturas cloud/edge. El despliegue de políticas avanzadas y gemelos digitales requiere, además, capacidades de MLOps y gobernanza de datos, evidenciando que el éxito no depende solo del algoritmo, sino del nivel de madurez digital de la organización (Ngwu et al., 2025; Alexopoulos et al., 2024).

Tabla 1*Enfoques de programación de operaciones en manufactura inteligente*

Criterio	DRL	Metaheurísticas	Digital Twins Optimización
<i>Naturaleza de decisión</i>	Aprende una política secuencial	Busca una o varias soluciones por exploración	Orquesta decisiones con un modelo vivo sincronizado
<i>Mayor fortaleza</i>	Adaptabilidad en scheduling dinámico	Flexibilidad multiobjetivo y facilidad de personalización	Reprogramación en tiempo real y trazabilidad
<i>Debilidad principal</i>	Interpretabilidad y riesgo de sobreajuste	Costo computacional y sensibilidad de parámetros	Costo de implementación e integración IT/OT
<i>Requisitos de datos</i>	Medio alto (entrenamiento, simulación)	Bajo–medio	Alto (IoT, MES/ERP, gobernanza de datos)
<i>Escenario ideal</i>	Flexible job shop con variabilidad y decisiones frecuentes	Flow shop y contextos con múltiples KPIs	Plantas con madurez digital y necesidad de control reactivo

Nota. Comparación de enfoques de programación de operaciones en manufactura inteligente: DRL, metaheurísticas y Digital Twins integrado. *Fuente.* Elaboración propia.


Modelos, ecuaciones y pseudocódigos representativos. La formulación del scheduling bajo DRL se basa generalmente en un Proceso de Decisión de Markov (MDP), definido por el conjunto (S, A, P, R, γ) . En este modelo, S representa el estado del sistema, A las acciones, P la transición, R la recompensa y γ el factor de descuento; esta estructura permite que el agente aprenda políticas óptimas mediante el entrenamiento (Del Real Torres et al., 2022; Khadivi et al., 2023). Más allá del DRL para la selección dinámica de reglas de despacho, el ecosistema actual integra metaheurísticas multiobjetivo para optimizar criterios simultáneos y reprogramación reactiva mediante Digital Twins para decisiones en tiempo real. Los esquemas algorítmicos y pseudocódigos reportados en la literatura reciente (2020-2025) no son fórmulas únicas, sino síntesis conceptuales que ilustran la implementación de estas tecnologías en la manufactura inteligente.

La selección entre DRL, Metaheurísticas y Digital Twins/DES para el scheduling industrial no es universal, sino que depende de la madurez digital y la complejidad de la planta. Mientras el DRL se especializa en la autonomía dentro de entornos dinámicos, las metaheurísticas destacan por su robustez en problemas complejos y los Digital Twins por su precisión en la validación operativa. En última instancia, la efectividad del método elegido está supeditada a su capacidad para integrarse en el ecosistema específico de la Industria 4.0.

Arquitectura conceptual del scheduling adaptativo. La arquitectura conceptual establece que la programación de operaciones en entornos de Industria 4.0 no depende de un único componente, sino de la interacción sistémica entre tres capas complementarias. En primer lugar, las arquitecturas de manufactura inteligente, como cloud manufacturing y el control holónico, determinan la estructura organizativa y el grado de descentralización de las decisiones.

Figura 3

Arquitectura conceptual del scheduling adaptativo en manufactura inteligente



Fuente. Elaboración propia

El núcleo analítico de la manufactura inteligente se fundamenta en métodos y algoritmos de programación que abarcan desde modelos exactos y metaheurísticas hasta enfoques de aprendizaje profundo por refuerzo, que son responsables de generar soluciones y políticas de decisión óptimas. Esta capacidad analítica se apoya en una infraestructura digital compuesta por Digital Twins, sistemas MES/APS e IoT, que suministran información en tiempo real, facilitan la simulación y brindan el soporte necesario para la ejecución operativa en la planta.

La efectividad del sistema radica en la interconexión de sus dimensiones: mientras la arquitectura define el proceso de toma de decisiones, la infraestructura aporta los datos y los algoritmos transforman dicha información en acciones concretas. Esta interacción bidireccional, especialmente entre los Gemelos Digitales y la inteligencia artificial, permite una adaptación constante y la consolidación de un scheduling dinámico y resiliente. De este modo, la evolución de la programación de operaciones se orienta hacia un modelo de arquitectura conceptual plenamente integrado en el contexto de la Industria 4.0.

DISCUSIÓN.

El argumento central de la literatura reciente es que la programación de operaciones ya no puede evaluarse únicamente por su capacidad de minimizar makespan o tardanza. En entornos inteligentes, el scheduling debe sostener resiliencia, explicabilidad, adaptación y trazabilidad. Esta ampliación del criterio de valor explica la creciente popularidad de enfoques híbridos que combinan simulación, optimización y aprendizaje (Ngwu et al., 2025; Nievas et al., 2024).

Desde el punto de vista teórico, el paso de la optimización clásica al aprendizaje secuencial redefine el problema como una política de decisión. Esto abre enormes oportunidades, pero también exige nuevas garantías. El mejor resultado promedio en benchmark no equivale a la mejor estrategia industrial si la política no puede explicarse, auditarse o generalizarse fuera de distribución (Del Real Torres et al., 2022; Khadivi et al., 2023).

Desde el punto de vista práctico, la principal implicación es que la selección del enfoque depende del grado de madurez digital de la organización. Una empresa con baja integración de datos probablemente obtenga más valor inmediato de metaheurísticas o modelos híbridos simples, mientras que una planta con sistema sensor, simulación y trazabilidad puede aprovechar más un Digital Twin o una política DRL desplegada (Agostino et al., 2020; Alexopoulos et al., 2024).

A pesar de los avances significativos en la programación de operaciones dentro de la manufactura inteligente, persisten limitaciones estructurales que delimitan su madurez científica e industrial. En particular, las políticas basadas en aprendizaje profundo por refuerzo (DRL) enfrentan desafíos críticos en términos de interpretabilidad y explicabilidad, lo que dificulta su adopción en entornos donde la trazabilidad y la confianza en la toma de decisiones son esenciales (Khadivi et al., 2023; Nievas et al., 2024). Asimismo, la robustez de estos modelos fuera de distribución continúa siendo insuficiente, especialmente ante escenarios caracterizados por cambios en el conglomerado de producción, fallas poco frecuentes o configuraciones inéditas de planta (Del Real Torres et al., 2022).

CONCLUSIONES.

La evidencia revisada permite afirmar que la programación de operaciones en manufactura inteligente se ha transformado en un problema ciber-físico, data-driven y dinámico. La función del scheduler ya no es solo secuenciar operaciones, sino sostener una lógica de decisión adaptativa bajo eventos, incertidumbre y múltiples objetivos de desempeño (Ivanov et al., 2020; Ngwu et al., 2025).

Los Digital Twins se consolidan como infraestructura clave para conectar estado real, simulación y reprogramación (Agostino et al., 2020; Latsou et al., 2024); el DRL, especialmente con grafos, se proyecta como la familia algorítmica más prometedora para decisiones online (Moon et al., 2024; Echeverria et al., 2023; Zhang et al., 2020); y las metaheurísticas mantienen alta vigencia por su flexibilidad y facilidad de aplicación a escenarios industriales complejos (Rossit et al., 2024).

En síntesis, el futuro del scheduling en Industry 4.0 se orienta hacia enfoques híbridos y escalables que integren datos, simulación, optimización y aprendizaje, sin sacrificar robustez, auditabilidad ni viabilidad de despliegue. Esta transición representa tanto una oportunidad metodológica como una agenda abierta de investigación (Ngwu et al., 2025).

Aunque los Digital Twins se consolidan como una infraestructura prometedora, su implementación demanda altos niveles de integración IT/OT, así como esfuerzos continuos de mantenimiento y actualización del modelo digital (Da Silva et al., 2025; Latsou et al., 2024). A estas limitaciones se suma la baja comparabilidad entre estudios, derivada de la heterogeneidad en datasets, métricas y protocolos experimentales, lo que dificulta la validación cruzada de resultados (Ngwu et al., 2025).

Se evidencia una brecha significativa en la validación longitudinal y en el despliegue industrial documentado, predominando aún estudios basados en simuladores y benchmarks académicos, lo que limita la transferencia efectiva del conocimiento hacia aplicaciones reales (Alexopoulos et al., 2024). En conjunto, estas brechas configuran una agenda de investigación orientada a fortalecer la robustez, interpretabilidad y aplicabilidad industrial del scheduling en entornos de Industria 4.0.

BIBLIOGRAFÍA.

- Agostino, I., Ambrogio, G., & Di Lorenzo, R. (2020). Using a digital twin for production planning and control in Industry 4.0. *Procedia Manufacturing*, 42, 543–548.
- Alexopoulos, K., Chryssolouris, G., & Michalos, G. (2024). Adaptive production scheduling in smart manufacturing systems using deep reinforcement learning and discrete event simulation. *Applied Sciences*, 15(1), 232.
- Alvarez-Tinajero, N., Basantes-Andrade, A., Ayala-Vásquez, O., Pereira-González, L. M., & Arciniegas-Romero, G. (2026). Mathematical Competencies and

Critical Thinking in Secondary Education: A PRISMA-Based Systematic Review (2019–2025). *F1000Research*, 14, 1407.

Da Silva, L. R. R., Pereira, T. M., & Gonçalves, C. A. (2025). A review on Digital Twin technologies for machining processes in Industry 4.0. *Journal of Manufacturing and Materials Processing*, 9(7), 211.

Del Real Torres, A., Fernández-Ahumada, E., & García-Peñalvo, F. J. (2022). A review of deep reinforcement learning approaches for smart manufacturing in Industry 4.0 and 5.0 frameworks. *Applied Sciences*, 12(23), 12377.

Echeverria, I., Arteaga, I., & Egana, J. (2023). Graph-based deep reinforcement learning for large-scale flexible job shop scheduling. *arXiv*. <https://arxiv.org/abs/2310.15706>

Ivanov, D., Sokolov, B., & Dolgui, A. (2020). A digital supply chain twin for managing the disruption risks and resilience in the era of Industry 4.0. *Transportation Research Part E: Logistics and Transportation Review*, 142, 102190.

Khadivi, P., Charter, A., Yaghoubi, S., Jalayer, M., Ahang, M., Shojaeinasab, A., & Najjaran, H. (2023). Deep reinforcement learning for scheduling in smart manufacturing: A comprehensive review. *arXiv*. <https://arxiv.org/abs/2310.03195>

Latsou, C., Mavrikios, D., & Chryssolouris, G. (2024). A unified framework for scalable and reusable Digital Twin development. *IFAC-PapersOnLine*, 57(7), 1335–1341.

Moon, T., Lee, K., & Park, J. (2024). Heterogeneous graph-based reinforcement learning for flexible job shop scheduling. *arXiv*. <https://arxiv.org/abs/2402.08979>

Ngwu, C. S., Zhang, Y., & Wu, C. (2025). Artificial intelligence techniques in production scheduling: A systematic review. *Journal of Intelligent Manufacturing*. Advance online publication.

- Nievas, N., Moreira, M., & Oliveira, E. (2024). A review of reinforcement learning applications in manufacturing systems. *Journal of Intelligent Systems*, 33(2), 456–479.
- Rossit, D. A., Nesmachnow, S., & Márquez, A. (2024). Metaheuristic approaches for multi-objective flow shop scheduling with missing operations. *arXiv*. <https://arxiv.org/abs/2407.15802>
- Zhang, R., Wang, M., & Fan, T. (2023). Flexible scheduling for human–machine collaborative workshops based on a hierarchical digital twin and reinforcement learning. *Flexible Services and Manufacturing Journal*.
- Zhang, C., Zhang, J., Lim, A., & Ong, Y. S. (2020). Learning dispatching rules via deep reinforcement learning. *arXiv*. <https://arxiv.org/abs/2010.12367>