

Aplicaciones de Inteligencia Artificial para la Gestión de Operaciones: Un Análisis Bibliométrico

Julián E. Tornillo¹, Guadalupe Pascal¹, Daniel Alejandro Rossit^{2,3} y Andrés Redchuk⁴

¹ Facultad de Ingeniería, Universidad Nacional de Lomas de Zamora, Lomas de Zamora, Argentina

² Departamento de Ingeniería, Universidad Nacional del Sur, Bahía Blanca, Argentina

³ INMABB, CONICET, Bahía Blanca, Argentina

⁴ ETSII, Universidad Rey Juan Carlos, Madrid, España

Resumen. El paradigma Industria 4.0 plantea una digitalización profunda de los sistemas de producción. Esta digitalización integra las funciones de producción (ambiente físico) y de toma de decisiones (ambiente digital) en un único sistema, comúnmente llamados sistemas ciber-físicos. Los sistemas ciber-físicos permiten recolectar datos del proceso en tiempo real y utilizarlos para soportar la toma de decisiones, todos dentro de una misma arquitectura. A su vez, es posible aplicar distintas herramientas informáticas para el procesamiento de los datos y lograr procesos optimizados. Dentro de esas herramientas aquellas basadas en Inteligencia Artificial (AI) han tenido un especial interés en los últimos años, dando lugar a una gran cantidad de contribuciones sobre la disciplina. En este trabajo se propone analizar la literatura sobre los desarrollos y aplicaciones de AI en sistemas de producción, particularmente en la gestión de la producción y las operaciones. Para ello se revisan aquellos trabajos que se abordan con una lógica data-driven, en donde el foco está puesto en explotar las bondades de disponer una gran cantidad de datos en tiempo real. Se identifican los autores y países líderes, y se analizan los desarrollos y aplicaciones más relevantes. Finalmente, se plantean los desafíos futuros de la disciplina sobre la base de aquellas áreas que aun no han sido exploradas pero que serían especialmente potenciadas a partir de un enfoque basado en AI.

Keywords: Data-Driven · Inteligencia Artificial · Planificación y Control · Producción

1. Introducción

La transformación digital ha surgido como un eje transversal en las organizaciones y que influye profundamente en la planificación y control de la producción en ámbitos industriales [29]. La creciente competencia y la imperativa

necesidad de que las empresas respondan rápidamente a los cambios y demandas del mercado han acelerado la adopción de tecnologías 4.0. Estas tecnologías buscan fomentar una mayor flexibilidad, aumentar la productividad y optimizar la rentabilidad dentro del contexto de la cuarta y quinta revolución industrial, comúnmente conocidas como Industria 4.0 e Industria 5.0 [58]. Tecnologías como Internet Industrial de las Cosas (IIoT), Big Data (BD), la Computación en la Nube (CC), la Fabricación Digital (DM) son los pilares de la transformación digital de la industria. Además, la integración de otras tecnologías, como modelos de simulación y gemelos digitales (DT), en la planificación de la producción ha contribuido significativamente con los procesos de toma de decisiones estratégicas, facilitando la selección anticipada de equipamientos adecuados y modelos de planificación óptimos para una cadena de valor [21]. Estas tecnologías remodelan los paradigmas operativos, abriendo un nuevo camino para el desarrollo de nuevos métodos y técnicas para la gestión de la producción basada en datos (*Data Driven*, por sus siglas en inglés). Esta evolución paradigmática requiere una ágil adopción de estrategias basadas en datos para la gestión de operaciones, aprovechando eficazmente el valor intrínseco de la información en la era digital [12].

Las metodologías *Data Driven* para la planificación de la producción permiten elevar la precisión y eficiencia en los procesos y generar nuevas capacidades en las organizaciones para enfrentar desafíos complejos. Al aprovechar las capacidades analíticas de las tecnologías basadas en datos, las empresas pueden detectar patrones para mejorar las herramientas de pronósticos y previsiones, nuevas tendencias del mercado y abordar estratégicamente los problemas de planificación de la producción y gestión de la cadena de suministro de manera sostenible [15]. En este sentido, uno de los principales campos del conocimiento que permiten explotar los datos generados a partir de estas tecnologías es la Inteligencia Artificial (AI), particularmente los algoritmos de Aprendizaje Automático (ML) [6].

En este documento se presenta una primera sección con una introducción al marco conceptual de la gestión de la producción basada en datos a partir de inteligencia artificial. Luego, en la sección 2, se presenta la metodología utilizada y en la sección 3 los aspectos centrales del análisis bibliométrico realizado. Este análisis incluye las fuentes principales, las tendencias en los estudios académicos y las investigaciones recientes, identificando la evolución en los últimos años. Finalmente, en la sección 4, se proponen discusiones y líneas futuras de trabajo, considerando aquellas temáticas que comprenden nichos y oportunidades para futuras investigaciones.

1.1. Antecedentes

Tecnologías 4.0 Al estudiar la gestión de la producción basada en datos mediante inteligencia artificial, resulta central definir los conceptos principales asociados a este trabajo.

En el marco del paradigma Industria 4.0 para la gestión de las operaciones [23], existen diversas tecnologías habilitadoras que posibilitan la transformación

digital a partir de su integración [44]. Aunque, en algunos casos, estas tecnologías existen desde hace más de 20 años, las mismas eran utilizadas de forma aislada y no habían sido concebidas para su uso conjunto y articulado.

Hoy en día, los sistemas de producción avanzados son un entorno de fabricación inteligente que permite la configuración dinámica de parámetros relevantes utilizando software y hardware, lo que resulta un aporte para la toma de decisiones de forma rápida y precisa y contribuye a aumentar la capacidad de respuesta ante condiciones no previstas. A estos sistemas se los denomina comúnmente Sistemas de Producción Ciberfísicos (CPPS) [54].

Las principales tecnologías 4.0 que conforman los CPPS son diversas y complementarias. La IIoT, que establece conexiones entre máquinas y dispositivos para permitir la recopilación de datos e intercambios en tiempo real. BD, considerado el cerebro de los modelos data-driven [9], se enfoca en el análisis exhaustivo de grandes volúmenes de información para obtener conocimiento a partir de ellos. La Robótica Colaborativa o Cobots, que están diseñados para trabajar junto a humanos en espacios de trabajo compartidos de manera segura y eficiente, mejoran la productividad y la interacción humano-máquina. La DM es la aplicación de sistemas informáticos a servicios de fabricación, cadenas de suministro, productos y procesos, amalgamando tecnologías como la impresión 3D. La Simulación se utiliza principalmente para optimizar procesos de producción y estrategias de planificación basadas en la creación DT. Por su parte, CC contribuye almacenando y procesando información en entornos descentralizados y en tiempo real. La Ciberseguridad surge como una necesidad para salvaguardar la información generada a partir de las tecnologías mencionadas anteriormente.

Todas estas tecnologías se encuentran nutridas a partir de la Inteligencia Artificial, la cual comprende un conjunto de sistemas y algoritmos capaces de aprender y tomar decisiones basadas en datos. La implementación de modelos de AI, ha generado un impacto significativo en la gestión de las operaciones industriales [42] y permiten un análisis de datos altamente complejo y una automatización inteligente capaz de optimizar procesos y decisiones en un amplio espectro de industrias y empresas [52].

Inteligencia Artificial En los últimos años los modelos de AI son considerados como uno de los principales motores de la transformación de la industria [1]. Estos modelos están conformados por sistemas o máquinas que imitan la inteligencia humana para realizar tareas y pueden mejorar iterativamente a partir de la información que recopilan [41]. La información utilizada se acumula y se guarda de manera estructurada para luego, por medio de diferentes técnicas y algoritmos, generar conocimiento, que permite realizar tareas de manera autónoma, monitoreo remoto de operaciones, análisis en tiempo real y realizar predicciones, por citar algunos ejemplos. La inteligencia artificial está compuesta por distintas ramas del conocimiento, como el Procesamiento de Lenguaje Natural (NLP), el reconocimiento de imágenes (IR), la visión computacional (CV) y las máquinas de aprendizaje o aprendizaje máquina; también llamado *Machine Learning* (ML) [13]. El ML es un conjunto de algoritmos y técnicas que son, en

general, entrenados por investigadores y distintos grupos de profesionales para definir patrones y extraer información relevante [16]. Dentro del ML, existen cuatro tipos principales de aprendizaje: (i) aprendizaje supervisado o *supervised learning* (SL), (ii) aprendizaje no supervisado o *unsupervised learning* (UL), (iii) aprendizaje por refuerzo o *Reinforcement Learning* (RL) y (iv) Aprendizaje profundo o *Deep Learning* (DL).

Alcance del documento Este trabajo explora cómo la comunidad científica caracteriza y aborda estudios relacionados con la aplicación de la inteligencia artificial en entornos industriales y cómo ha evolucionado en los últimos años. En particular, desde una perspectiva industrial, se analiza la aplicación de la inteligencia artificial para la mejora de los procesos de planificación y control de la producción basados en datos. Además, el enfoque se centra en proporcionar una visión general que permita cuantificar y analizar las características bibliográficas, incluyendo un mapeo del estado actual del conocimiento sobre la temática y contribuir a futuras investigaciones en la disciplina.

2. Metodología

Para realizar el análisis bibliográfico se aplican los conceptos principales asociados a la metodología de revisión sistemática de literatura (SLR) para estudiar de manera integral el estado actual del conocimiento sobre la planificación de la producción basada en datos a partir de AI. Para ello, se adoptan las pautas sugeridas en el Manual Cochrane para Revisiones Sistemáticas [27], así como trabajos previos [17,14].

La Figura 1 ilustra la metodología para realizar SLR, que responde a un protocolo estructurado en diferentes etapas. La primera etapa consiste en establecer las preguntas de investigación para delimitar el campo de búsqueda al objetivo del documento. La segunda etapa implica definir la estrategia de búsqueda, abarcando las fuentes, parámetros y ecuación de búsqueda, así como el establecimiento de los criterios de inclusión y exclusión para garantizar la relevancia de los documentos analizados. La tercera etapa comprende el procedimiento de búsqueda propiamente dicho, en donde se recolectan y seleccionan los documentos según los criterios establecidos. La cuarta y última etapa comprende un análisis cuantitativo de los resultados obtenidos y una revisión de los documentos seleccionados para extraer la información relevante que permite generar resultados de relevancia para la disciplina.

La implementación de esta metodología permite una exploración sistémica y completa de la literatura publicada, consolidando un conjunto de trabajos significativamente representativos para analizar de manera crítica y confiable el estado actual del conocimiento sobre la temática a partir de los documentos seleccionados. Para ello, se han elaborado preguntas de investigación que motivan este trabajo. Algunas de las preguntas destacadas son:

- ¿Cuáles son las principales técnicas y herramientas de AI aplicada a la gestión de la producción y las operaciones?

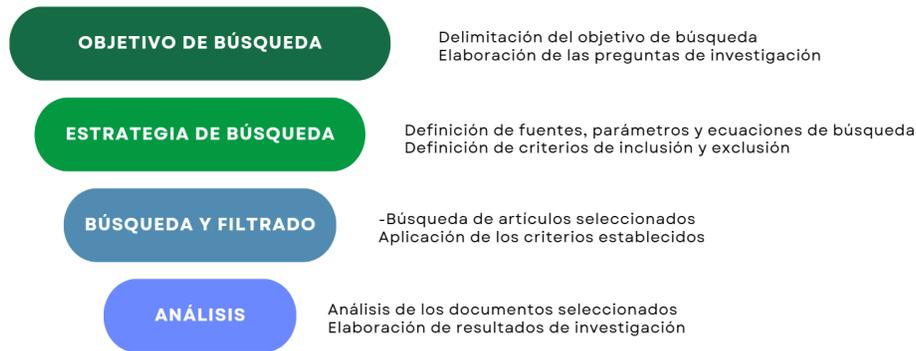


Figura 1. Metodología - Protocolo para la realización de revisiones sistemáticas de literatura. Fuente: Autores

- ¿Qué autores, instituciones y revistas científicas son referentes en la disciplina?
- ¿Qué países lideran las investigaciones en la disciplina y cuál es el rol de los países latinoamericanos?
- ¿Cuáles son las principales temáticas y aplicaciones que dan lugar a nichos y oportunidades para futuras investigaciones en la disciplina?

A partir de estas preguntas, en la Tabla 1 muestra una ecuación de búsqueda organizada en tres bloques, basada en las palabras clave seleccionadas para delimitar el objetivo de búsqueda.

Tabla 1. Ecuación de búsqueda y palabras clave. Fuente: Autores

Bloque 1	Bloque 2	Bloque 3
“artificial Intelligence” OR “AI” OR “Machine Learning” OR “Learning Algorithm”	“data driven” OR “data-driven”	“production planning” OR “production control” OR “planning and control”

Cada uno de los bloques han sido concatenados mediante un operador “AND” para garantizar que los resultados obtenidos contengan al menos uno de los términos definidos para cada bloque.

Las bases de datos utilizadas para realizar la búsqueda han sido Scopus y Web of Science. Si bien el período de tiempo no fue definido inicialmente, en las búsquedas preliminares no se han identificado trabajos anteriores al año 2013; por lo que el período de tiempo a estudiar es la evolución 2013-2023.

3. Resultados

La búsqueda realizada muestra 162 documentos, compuestos por 115 extraídos de Scopus y 47 de Web of Science. Excluyendo los 26 documentos que fueron identificados como duplicados, se obtiene un corpus de 136 contribuciones. Luego, según los criterios de exclusión definidos, no se consideran 24 trabajos que no poseen DOI y 3 trabajos que no están escritos en idioma inglés o español, obteniendo un conjunto de 109 documentos para procesar. Por último, de la revisión de la literatura se identifican 34 documentos que no cumplen con los criterios de inclusión, relacionados a la pertinencia y relevancia. Se incluyen documentos que reflejen la aplicación de técnicas de ML para la planificación y control de la producción en modelos *Data Driven*. De esta manera, para el alcance de esta investigación, resultan pertinentes 75 contribuciones seleccionadas para esta SLR. El corpus final está compuesto por 50 artículos de revista, 24 presentaciones en congresos y conferencias, y 2 a capítulos de libro. De esta manera, se utiliza la herramienta de Bibliometrix [4] de R como apoyo al análisis realizado.

3.1. Análisis bibliométrico

En este apartado se presentan los resultados cuantitativos obtenidos del conjunto final de artículos a estudiar. La Figura 2 presenta la distribución temporal de la producción científica de la disciplina estudiada en este trabajo. El eje vertical representa el número de documentos y el eje horizontal muestra los años de estudio entre 2013 y 2023. Se observa una tendencia de crecimiento gradual en la producción a lo largo del tiempo, lo que indica un creciente interés y enfoque en esta área de investigación. Los primeros años muestran un nivel de producción bajo, que comienza a crecer sostenidamente a partir del año 2017. El pico máximo es alcanzado en el año 2022 con más de 30 contribuciones. Este crecimiento evidencia que es una temática de interés creciente en la comunidad. Respecto al año 2023, si bien se observa un decrecimiento con respecto al año anterior, esto puede deberse a que existen contribuciones que se encuentran pendientes de publicación en su versión final.

La Figura 3 ofrece una representación visual de la distribución geográfica de la producción científica a nivel global. La tonalidad de los colores utilizados en el mapa está determinada por el número de publicaciones de cada país a partir de una tabla de frecuencias.

En este análisis, destacan países como Estados Unidos (37 contribuciones), China (34 contribuciones) y Alemania (27 contribuciones), que se distinguen por tonos de azul más intenso. Países como Brasil (10), Italia (9), Suecia (8) y Canadá (7) u otros países de Europa Occidental presentan frecuencias más bajas pero aún significativas.

La presencia de líneas en color rojo que conectan países indica el intercambio y las colaboraciones entre distintos países en las distintas contribuciones sobre el tema. Se destacan China, Alemania y Estados Unidos como países que más

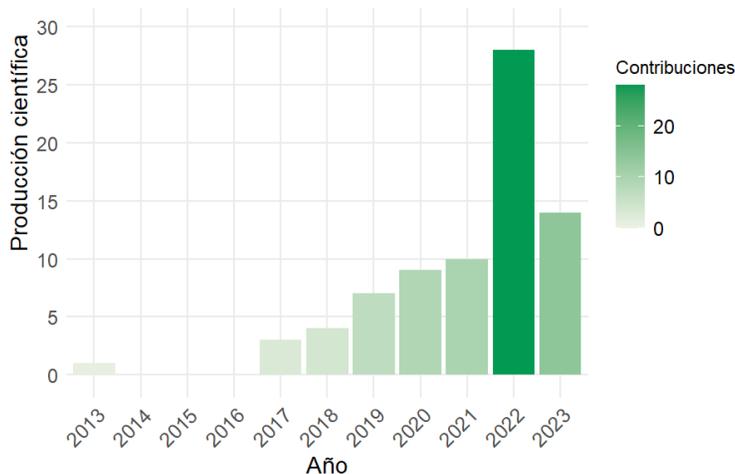


Figura 2. Evolución anual de la producción científica de la disciplina. Fuente: Autores

colaboraciones han establecido. Por otra parte, también se observan colaboraciones entre los distintos países de Europa Occidental, así como también trabajos conjuntos entre estados Unidos y otros países de América y África. Finalmente, en América Latina se destaca Brasil a partir de colaboraciones con Portugal y Estados Unidos. En este sentido, no se observa producción científica de alto impacto en los demás países de la región.

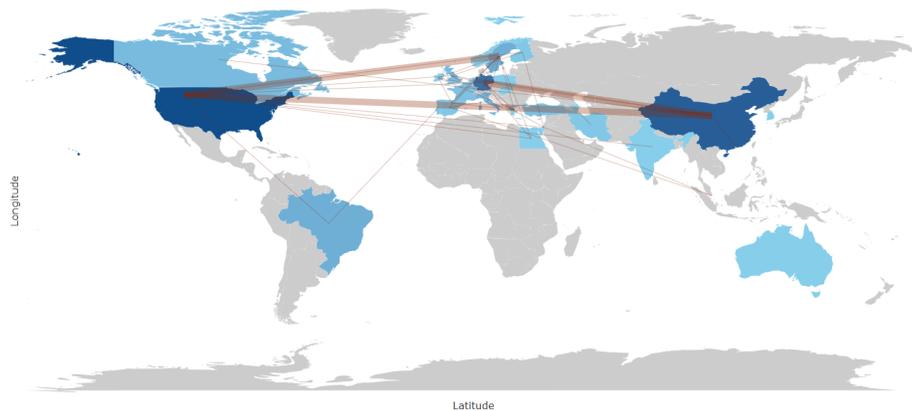


Figura 3. Nivel de producción científica por país a nivel global, incluyendo colaboraciones entre autores e instituciones de distintos países. Fuente: Autores

En el Cuadro 2 se muestra un listado de las fuentes que presentan mayor cantidad y relevancia de artículos para la disciplina. Al analizar la totalidad

de las contribuciones seleccionadas, se observa que el 47% corresponde a DL, de las cuales el 24% y el 23% corresponden a RL y otras aplicaciones del DL respectivamente. Asimismo, el 44% de los trabajos analizados corresponden a SL, de los cuales el 23% corresponde a aplicaciones de NN y el 21% a otras aplicaciones de SL. Por su parte, el 8% de las contribuciones corresponden a aplicaciones de UL y el 1% a otras aplicaciones de ML.

Tabla 2. Listado de las diez fuentes más relevantes, incluyendo los trabajos asociados, el año de publicación y el eje temático en el cual ha sido incluida cada contribución. Fuente: Autores

Fuente	Contribuciones	Cita	Eje
INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH	Takeda-Berger SL, Frazzon, EM (2023)	[50]	NN
	Castañé G et. al. (2023)	[10]	RL
	Khayyati S., Tan B. (2022)	[30]	SL/NN
	Panzer M., Bender B. (2022) (Review)	[40]	RL
COMPUTERS AND CHEMICAL ENGINEERING	Zhu J et. al. (2023)	[62]	DL
	Hubbs CD et. al. (2020)	[28]	RL
	Shin J, Lee JH (2019)	[47]	RL
	Ning C, You F (2018)	[37]	UL
CIRP ANNALS	Endo M, Sencer B (2022)	[18]	NN
	Wang P et. al (2018)	[56]	DL
	Stricker N et. al (2018)	[49]	RL
COMPUTERS AND INDUSTRIAL ENGINEERING	Wesendrup K, Hellingrath B (2023)	[57]	RL
	Zhang C, Wang Z (2023)	[59]	UL
COMPUTERS IN INDUSTRY	Fani, V et. al. (2023)	[20]	UL
	Antons O, Arlinghaus JC (2022)	[3]	RL
IEEE TRANS. ON INDUSTRIAL INFORMATICS	Essien A, Giannetti C (2020)	[19]	DL
	Wang J et. al. (2018)	[55]	NN
PROCEDIA CIRP	May MC et. al. (2021)	[36]	NN
	Zhang Y et. al. (2019)	[60]	NN
IEEE ACCESS	Zhou T et. al. (2021)	[61]	RL
	Barino FO et. al. (2020)	[7]	NN
IEEE ROBOTICS AND AUTOMATION LETTERS	Cauligi A et. al. (2022)	[11]	SL
	Selim M. et. al (2022)	[46]	RL
APPLIED SCIENCES (SWITZERLAND)	Gödri I (2022)	[26]	UL
	Tiensuu H et. al. (2021)	[53]	SL

3.2. Principales aplicaciones

Los campos de aplicación identificados refieren a distintos aspectos relacionados a la planificación de la producción y la gestión de operaciones. El 23% de las contribuciones seleccionadas emplean técnicas de inteligencia artificial a la planificación de la producción propiamente dicha; particularmente en problemas de programación o *scheduling*. Algunas de las aplicaciones industriales que

se destacan son el estudio de las paradas de hornos de cracking [59], la gestión del inventario [51], la optimización del consumo energético [35]. Por otro lado, si bien se observan documentos que utilizan redes neuronales para la programación de la producción [50], en los últimos años ha cobrado mayor relevancia el empleo de algoritmos de RL para planificación dinámica [28]. Si bien hay estudios que aplican estas técnicas en fábricas inteligentes [61,38], el empleo de algoritmos avanzados de RL como por ejemplo Deep-Q-Network (DQN) también pueden ser utilizados en procesos productivos con menor integración tecnológica pero que presentan una alta flexibilidad [32,33].

Por otra parte, también se observa 23% de contribuciones que tienen incidencia en tareas de control de la producción, en donde se incluye el monitoreo y la gestión en tiempo real de los datos e información relevante inherente al proceso productivo. Las técnicas de aprendizaje supervisado son principalmente utilizadas para el control de calidad [24,53]. En particular, las NN se combinan con modelos de simulación para optimizar los procesos de control [25,2]. Por su parte, en sistemas expertos de producción se pueden utilizar algoritmos de DL para diagnóstico y previsión de eventos futuros [63]. Por ejemplo, en sistemas de producción autónomo se pueden utilizar algoritmos de RL multiagente como alternativa superadora a las heurísticas tradicionales [3].

El 21% de las contribuciones abordan las tareas de previsión de demanda para optimizar la eficiencia y la productividad de las operaciones. En este aspecto las principales técnicas utilizadas refieren a las redes neuronales para la gestión de la demanda [7]. Se observa que la elaboración de pronósticos a partir de herramientas de inteligencia artificial es ampliamente utilizada en el rubro energético [8,31], particularmente gas y petróleo [48,34].

También se observa un 12% que hace foco en la gestión del mantenimiento, mediante el uso algoritmos de ML como herramienta para la predicción de fallas. En algunos casos, estas técnicas se emplean en entornos estocásticos desde el punto de vista de los inventarios, la demanda y la incidencia humana [39]. Además, sobre la base del concepto CPPS se encuentran en continuo desarrollo modelos de mantenimiento profundo digital, o *Deep Digital Maintenance* (DDM) [45]. Este enfoque permite, por ejemplo, calcular el impacto en costos y tiempos de proceso por fallos o averías en tiempo real y previo al evento, lo que permite fortalecer la toma de decisiones.

El 21% restante se distribuye en otras actividades relacionadas con la gestión de operaciones pero con menor incidencia en la planificación de la producción, como por ejemplo la gestión de proveedores [22], la optimización de gemelos digitales [43], predicción del tiempo de ciclo [18] O desarrollos metodológicos para la gestión de redes de producción ciber-físicas [5].

4. Discusiones y líneas futuras

4.1. Discusiones

En las secciones previas se ha abordado la aplicación de herramientas de inteligencia artificial en los sistemas de planificación y control de la producción.

Se observa que las herramientas de AI aplicadas en sistemas *Data Driven* se encuentran maduros y conforman una oportunidad para potenciar los procesos de transformación digital de las organizaciones.

Con respecto a la primera pregunta de investigación, referida a cuáles son las principales técnicas y herramientas de AI aplicada a la gestión de la producción y las operaciones, se destaca la implementación de algoritmos de ML como redes neuronales para tareas de predicción y algoritmos de aprendizaje por refuerzo para sistemas CPPS autónomos. No obstante, también se han identificado otras técnicas supervisadas como SVM y no supervisadas, como PCA o *clustering* para entornos de producción en donde existe mayor incidencia humana en el proceso.

Con respecto a la segunda y tercera pregunta de investigación, orientadas a reconocer las revistas científicas y los países líderes en la disciplina respectivamente, si bien las contribuciones están concentradas en países centrales como Estados Unidos, China o Alemania, se evidencian colaboraciones e investigaciones incipientes en algunos países de África, Oceanía y América Latina. Por otra parte, en la tercera pregunta de investigación también se plantea el rol de los países latinoamericanos. Los procesos de transformación digital que están atravesando las pequeñas y medianas empresas a nivel regional conllevan una creciente incorporación de tecnologías 4.0 en los procesos de producción y operaciones. En esta línea, países como Argentina y Brasil presentan los mayores índices de desarrollo industrial a nivel latinoamericano y podría ser una oportunidad para potenciar líneas de investigación y desarrollo tecnológico en esta disciplina.

Por último, en relación a la cuarta pregunta de investigación, se han identificado aplicaciones de AI en diversas tareas asociadas a la gestión de operaciones. Algunas de las principales aplicaciones refieren a tareas de programación y secuenciación de operaciones, previsión y gestión de la demanda, control de la producción y gestión del mantenimiento, abarcando estas categorías el 80 % del total de contribuciones seleccionadas. En este sentido, uno de los principales desafíos para la aplicación de AI refieren no solo a la selección de las técnicas y algoritmos específicos a emplear, sino también a la revisión y el seguimiento de los resultados en tiempo real, que podrían implicar la modificación de parámetros en los modelos de AI o incluso la utilización o incorporación de otras técnicas. En esta línea, se destaca la implementación de algoritmos avanzados de DL como DQN, principalmente para tareas de *scheduling* con un enfoque orientado a la gestión de datos en tiempo real. Sin embargo, la mayoría de las contribuciones se focalizan en la aplicación propiamente dicha y no abordan el monitoreo del estado de situación del piso de planta de manera integral.

4.2. Líneas futuras

Como líneas futuras de investigación se propone profundizar la revisión de la literatura para identificar la incidencia en las aplicaciones de AI en conjunto con las distintas tecnologías 4.0 en modelos *Data Driven*. Además, se propone mapear aquellas contribuciones que, de manera explícita o implícita, incluyan el enfoque 5.0. Esto refiere a desarrollos y aplicaciones que contemplen aspectos ambientales y humanos como parte de las variables de proceso a optimizar.

Referencias

1. Ahmed, I., Jeon, G., Piccialli, F.: From artificial intelligence to explainable artificial intelligence in industry 4.0: A survey on what, how, and where. *IEEE Transactions on Industrial Informatics* **18**, 5031–5042 (8 2022)
2. Ajay, A., Bauza, M., Wu, J., Fazeli, N., Tenenbaum, J.B., Rodriguez, A., Kaelbling, L.P.: Combining physical simulators and object-based networks for control. pp. 3217–3223. *IEEE* (5 2019)
3. Antons, O., Arlinghaus, J.C.: Data-driven and autonomous manufacturing control in cyber-physical production systems. *Computers in Industry* **141**, 103711 (10 2022)
4. Aria, M., Cuccurullo, C.: bibliometrix: An r-tool for comprehensive science mapping analysis. *Journal of Informetrics* **11**, 959–975 (11 2017)
5. Bagozi, A., Bianchini, D., Rula, A.: Multi-perspective data modelling in cyber physical production networks: Data, services and actors. *Data Science and Engineering* **7**, 193–212 (9 2022)
6. Bahaloo, S., Mehrizadeh, M., Najafi-Marghmaleki, A.: Review of application of artificial intelligence techniques in petroleum operations. *Petroleum Research* **8**, 167–182 (6 2023)
7. Barino, F.O., Silva, V.N.H., Lopez-Barbero, A.P., Honorio, L.D.M., Santos, A.B.D.: Correlated time-series in multi-day-ahead streamflow forecasting using convolutional networks. *IEEE Access* **8**, 215748–215757 (2020)
8. Bowala, S., Makhan, M., Liang, Y., Thavaneswaran, A., Appadoo, S.S.: Superiority of the neural network dynamic regression models for ontario electricity demand forecasting. vol. 2022-September, pp. 182–187. *IEEE* (9 2022)
9. Bueno, A., Filho, M.G., Carvalho, J.V., Calfei, M.: Smart production planning and control model. vol. 256, pp. 253–267. *Springer* (11 2022)
10. Castañé, G., Dolgui, A., Kousi, N., Meyers, B., Thevenin, S., Vyhmeister, E., Östberg, P.O.: The assistant project: Ai for high level decisions in manufacturing. *International Journal of Production Research* **61**, 2288–2306 (4 2023)
11. Cauligi, A., Culbertson, P., Schmerling, E., Schwager, M., Stellato, B., Pavone, M.: Coco: Online mixed-integer control via supervised learning. *IEEE Robotics and Automation Letters* **7**, 1447–1454 (4 2022)
12. Cavanillas, J.M., Curry, E., Wahlster, W.: *New Horizons for a Data-Driven Economy: A Roadmap for Usage and Exploitation of Big Data in Europe*. Springer, 1 edn. (1 2016)
13. Chen, Z., Wu, M., Chan, A., Li, X., Ong, Y.S.: Survey on ai sustainability: Emerging trends on learning algorithms and research challenges [review article]. *IEEE Computational Intelligence Magazine* **18**, 60–77 (5 2023)
14. Chiappa, S., Videla, E., Viana-Céspedes, V., Piñeyro, P., Rossit, D.A.: Cloud manufacturing architectures: State-of-art, research challenges and platforms description. *Journal of Industrial Information Integration* **34**, 100472 (8 2023)
15. Ching, N.T., Ghobakhloo, M., Iranmanesh, M., Maroufkhani, P., Asadi, S.: Industry 4.0 applications for sustainable manufacturing: A systematic literature review and a roadmap to sustainable development. *Journal of Cleaner Production* **334**, 130133 (2 2022)
16. Dwork, C., Roth, A.: The algorithmic foundations of differential privacy. *Foundations and Trends in Theoretical Computer Science* **9**, 211–487 (2013)
17. Dybå, T., Dingsøy, T.: Empirical studies of agile software development: A systematic review. *Information and Software Technology* **50**, 833–859 (8 2008)

18. Endo, M., Sencer, B.: Accurate prediction of machining cycle times by data-driven modelling of nc system's interpolation dynamics. *CIRP Annals* **71**, 405–408 (1 2022)
19. Essien, A., Giannetti, C.: A deep learning model for smart manufacturing using convolutional lstm neural network autoencoders. *IEEE Transactions on Industrial Informatics* **16**, 6069–6078 (9 2020)
20. Fani, V., Antomarioni, S., Bandinelli, R., Bevilacqua, M.: Data-driven decision support tool for production planning: a framework combining association rules and simulation. *Computers in Industry* **144**, 103800 (1 2023)
21. Ferranti, F., Manenti, F., Vingerhoets, G., Vallerio, M.: Value chain planning optimization: a data driven digital twin approach. *IFAC-PapersOnLine* **54**, 572–577 (1 2021)
22. Ferreira, R., Sousa, C., Carneiro, D., Cardeiro, C.: Data-driven production planning approach based on suppliers and subcontractors analysis: The case of the footwear cluster. *Procedia Computer Science* **219**, 941–948 (1 2023)
23. Ghobakhloo, M., Fathi, M., Iranmanesh, M., Maroufkhani, P., Morales, M.E.: Industry 4.0 ten years on: A bibliometric and systematic review of concepts, sustainability value drivers, and success determinants. *Journal of Cleaner Production* **302**, 127052 (6 2021)
24. Gramegna, N., Greggio, F., Bonollo, F.: Advances in production management systems. towards smart and digital manufacturing. vol. 592, p. 10. Springer International Publishing (2020)
25. Gryzlov, A., Mironova, L., Safonov, S., Arsalan, M.: Artificial intelligence and data analytics for virtual flow metering. pp. 1–14. *SPE* (12 2021)
26. Gödri, I.: Improving delivery performance in high-mix low-volume manufacturing by model-based and data-driven methods. *Applied Sciences* **12**, 5618 (6 2022)
27. Higgins, J., Thomas, J., Chandler, J., Cumpston, M., Li, T., Page, M.J., Welch, V.A. (eds.): *Cochrane Handbook for Systematic Reviews of Interventions version 6.4 (updated August 2023)*. Cochrane (2023), <https://training.cochrane.org/handbook>
28. Hubbs, C.D., Li, C., Sahinidis, N.V., Grossmann, I.E., Wassick, J.M.: A deep reinforcement learning approach for chemical production scheduling. *Computers Chemical Engineering* **141**, 106982 (10 2020)
29. Jones, M.D., Hutcheson, S., Camba, J.D.: Past, present, and future barriers to digital transformation in manufacturing: A review. *Journal of Manufacturing Systems* **60**, 936–948 (7 2021)
30. Khayyati, S., Tan, B.: A machine learning approach for implementing data-driven production control policies. *International Journal of Production Research* **60**, 3107–3128 (5 2022)
31. Kováč, S., Střelec, P., Horák, T., Michalčonok, G., Važan, P.: Forecasting Heat Production for a Large District Heating Network with NARX Neural Networks, vol. 502 LNNS, pp. 131–139. Springer Science and Business Media Deutschland GmbH (2022)
32. Li, Y., Gu, W., Yuan, M., Tang, Y.: Real-time data-driven dynamic scheduling for flexible job shop with insufficient transportation resources using hybrid deep q network. *Robotics and Computer-Integrated Manufacturing* **74**, 102283 (4 2022)
33. Liu, R., Piplani, R., Toro, C.: A deep multi-agent reinforcement learning approach to solve dynamic job shop scheduling problem. *Computers Operations Research* **159**, 106294 (11 2023)

34. Ma, H., Zhao, W., Zhao, Y., He, Y.: A data-driven oil production prediction method based on the gradient boosting decision tree regression. *Computer Modeling in Engineering Sciences* **134**, 1773–1790 (2023)
35. Ma, S., Zhang, Y., Lv, J., Ge, Y., Yang, H., Li, L.: Big data driven predictive production planning for energy-intensive manufacturing industries. *Energy* **211**, 118320 (11 2020)
36. May, M.C., Behnen, L., Holzer, A., Kuhnle, A., Lanza, G.: Multi-variate time-series for time constraint adherence prediction in complex job shops. *Procedia CIRP* **103**, 55–60 (2021)
37. Ning, C., You, F.: Data-driven decision making under uncertainty integrating robust optimization with principal component analysis and kernel smoothing methods. *Computers Chemical Engineering* **112**, 190–210 (4 2018)
38. Oberdorf, F., Stein, N., Flath, C.M.: Analytics-enabled escalation management: System development and business value assessment. *Computers in Industry* **131**, 103481 (10 2021)
39. Ong, K.S.H., Wang, W., Niyato, D., Friedrichs, T.: Deep-reinforcement-learning-based predictive maintenance model for effective resource management in industrial iot. *IEEE Internet of Things Journal* **9**, 5173–5188 (4 2022)
40. Panzer, M., Bender, B.: Deep reinforcement learning in production systems: a systematic literature review. *International Journal of Production Research* **60**, 4316–4341 (7 2022)
41. Patange, G.S., Pandya, A.B.: How artificial intelligence and machine learning assist in industry 4.0 for mechanical engineers. *Materials Today: Proceedings* **72**, 622–625 (8 2022)
42. Pathak, P., Bhatt, V., Jadhav, A.: Impact of artificial intelligence: Applications, transformation strategy and future potential. pp. 239–244. Institute of Electrical and Electronics Engineers Inc. (2022)
43. Peng, G., Cheng, Y., Zhang, X., Xu, D., Jiang, S.: Digital twin-enabled production optimization for steel industry. pp. 1126–1131. *IEEE* (5 2022)
44. Rad, F.F., Oghazi, P., Palmié, M., Chirumalla, K., Pashkevich, N., Patel, P.C., Sattari, S.: Industry 4.0 and supply chain performance: A systematic literature review of the benefits, challenges, and critical success factors of 11 core technologies. *Industrial Marketing Management* **105**, 268–293 (8 2022)
45. Rødseth, H., Schjølberg, P., Marhaug, A.: Deep digital maintenance. *Advances in Manufacturing* **5**, 299–310 (12 2017)
46. Selim, M., Alanwar, A., Kousik, S., Gao, G., Pavone, M., Johansson, K.H.: Safe reinforcement learning using black-box reachability analysis. *IEEE Robotics and Automation Letters* **7**, 10665–10672 (10 2022)
47. Shin, J., Lee, J.H.: Multi-timescale, multi-period decision-making model development by combining reinforcement learning and mathematical programming. *Computers Chemical Engineering* **121**, 556–573 (2 2019)
48. Shrivastava, K., Shukla, P., Banerjee, R., Koley, M.: Automated production forecasting using a novel machine learning based approach. *SPE* (3 2023)
49. Stricker, N., Kuhnle, A., Sturm, R., Friess, S.: Reinforcement learning for adaptive order dispatching in the semiconductor industry. *CIRP Annals* **67**, 511–514 (1 2018)
50. Takeda-Berger, S.L., Frazzon, E.M.: An inventory data-driven model for predictive-reactive production scheduling. *International Journal of Production Research* pp. 1–25 (5 2023)

51. Takeda-Berger, S.L., Zanella, R.M., Frazzon, E.M.: Towards a data-driven predictive-reactive production scheduling approach based on inventory availability. *IFAC-PapersOnLine* **52**, 1343–1348 (9 2019)
52. Tao, F., Zhang, H., Liu, A., Nee, A.Y.: Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics* **15**, 2405–2415 (4 2019)
53. Tiensuu, H., Tamminen, S., Puukko, E., Rönning, J.: Evidence-based and explainable smart decision support for quality improvement in stainless steel manufacturing. *Applied Sciences* **11**, 10897 (11 2021)
54. Vogel-Heuser, B., Fay, A., Schaefer, I., Tichy, M.: Evolution of software in automated production systems: Challenges and research directions. *Journal of Systems and Software* **110**, 54–84 (12 2015)
55. Wang, J., Zhang, J., Wang, X.: Bilateral lstm: A two-dimensional long short-term memory model with multiply memory units for short-term cycle time forecasting in re-entrant manufacturing systems. *IEEE Transactions on Industrial Informatics* **14**, 748–758 (2 2018)
56. Wang, P., Liu, H., Wang, L., Gao, R.X.: Deep learning-based human motion recognition for predictive context-aware human-robot collaboration. *CIRP Annals* **67**, 17–20 (1 2018)
57. Wesendrup, K., Hellingrath, B.: Post-prognostics demand management, production, spare parts and maintenance planning for a single-machine system using reinforcement learning. *Computers Industrial Engineering* **179**, 109216 (5 2023)
58. Xu, X., Lu, Y., Vogel-Heuser, B., Wang, L.: Industry 4.0 and industry 5.0—inception, conception and perception. *Journal of Manufacturing Systems* **61**, 530–535 (10 2021)
59. Zhang, C., Wang, Z.: Optimal scheduling of ethylene plants under uncertainty: An unsupervised learning-based data-driven strategy. *Computers Industrial Engineering* **183**, 109470 (9 2023)
60. Zhang, Y., Zhang, R., Wang, Y., Guo, H., Zhong, R.Y., Qu, T., Li, Z.: Big data driven decision-making for batch-based production systems. *Procedia CIRP* **83**, 814–818 (2019)
61. Zhou, T., Tang, D., Zhu, H., Wang, L.: Reinforcement learning with composite rewards for production scheduling in a smart factory. *IEEE Access* **9**, 752–766 (2021)
62. Zhu, J., Fan, C., Yang, M., Qian, F., Mahalec, V.: Data-driven models of crude distillation units for production planning and for operations monitoring. *Computers Chemical Engineering* **177**, 108322 (9 2023)
63. Zou, J., Chang, Q., Arinez, J., Xiao, G., Lei, Y.: Dynamic production system diagnosis and prognosis using model-based data-driven method. *Expert Systems with Applications* **80**, 200–209 (9 2017)