# Application of Machine Learning in Heijunka for the Automotive Sector

Julio Bernal-Pacheco[1]; Marko Silva Mejia[2]; Zaida Quispe-Lazaro[3]; Grecia García Quispe[4]; Saúl Bolívar Maldonado[5]; Cesar Avellana Cordova[6]

[1, 2, 3, 4, 5, 6]Universidad Privada del Norte, Lima, Perú. julio.bernal@upn.edu.pe[1], N00355778@upn.pe[2], N00389669@upn.pe[3], N00368527@upn.pe[4], N0038344@upn.pe[5], N00346322@upn.pe[6]

***Abstract*– The The increasing variability in mixed-model demand within the automotive sector has become one of the major challenges for production planning, revealing that traditional Heijunka systems are no longer able to respond effectively to today's dynamic manufacturing environments. To address this issue, a systematic literature review was conducted based on 80 scientific studies retrieved from Scopus, Web of Science, ScienceDirect, and SciELO. The review examined how the application of Machine Learning can strengthen Heijunka by incorporating predictive algorithms that enable the transition from traditional production leveling to a more intelligent, flexible, and adaptive system capable of anticipating demand fluctuations and supporting real-time decision-making within the framework of Industry 4.0 and Artificial Intelligence. Following the PRISMA methodology, evidence published between 2020 and 2026 was systematically analyzed. The findings indicate that integrating Machine Learning into Lean Manufacturing and Heijunka has the potential to significantly enhance production leveling systems. Although Artificial Intelligence and Industry 4.0 technologies have achieved substantial improvements in productivity, cycle time reduction, logistics optimization, and process control, their direct integration with Heijunka remains limited. This study identifies a significant research gap and highlights the need to evolve from conventional production leveling approaches toward intelligent predictive systems. The findings provide a solid foundation for developing smart manufacturing models that enhance the competitiveness and sustainability of the automotive industry through predictive and dynamic production leveling.***

***Keywords*-- Heijunka, Machine Learning, Lean Manufacturing, Automotive Industry, production leveling, Industry 4.0.**

# Aplicación de Machine Learning en Heijunka para el sector Automotriz.

Julio Bernal-Pacheco[1]; Marko Silva Mejia[2]; Zaida Quispe-Lazaro[3]; Grecia García Quispe[4]; Saúl Bolívar Maldonado[5]; Cesar Avellana Cordova[6]

[1, 2, 3, 4, 5, 6]Universidad Privada del Norte, Lima, Perú. julio.bernal@upn.edu.pe[1], N00355778@upn.pe[2], N00389669@upn.pe[3], N00368527@upn.pe[4], N0038344@upn.pe[5], N00346322@upn.pe[6]

***Resumen–*** ***La variabilidad intensificada en la demanda de modelos mixtos en el sector automotriz es uno de los principales retos para la planificación de la producción, poniendo de evidencia que el Heijunka ya no responde con la misma eficacia a los entornos productivos actuales. Es por ello que se realizó una revisión sistemática de 80 investigaciones, teniendo como base de datos a Scopus, Web of Science, ScienceDirect y SciELO, para analizar de manera rigurosa cómo la aplicación de Machine Learning, fortalece el Heijunka al integrar algoritmos predictivos que permitiría evolucionar desde un sistema de nivelación tradicional hacia uno más inteligente, flexible y capaz de anticiparse a las variaciones de la demanda para apoyar decisiones en tiempo real, en el marco de la Industria 4.0 e Inteligencia Artificial. Con la metodología PRISMA, se analizan las evidencias publicadas entre 2020 y 2026, que demuestran la incorporación de Machine Learning aplicados a la producción esbelta e integrados al Heijunka puede mejorar los sistemas de nivelación de la producción. Los resultados muestran que, si bien la Inteligencia Artificial y las tecnologías de la Industria 4.0 han logrado avances importantes en productividad, reducción de tiempos de ciclo, optimización logística y control de procesos, su aplicación conjunta con Heijunka todavía es limitada. Este trabajo pone en evidencia un vacío relevante en la literatura y sugiere evolucionar desde un sistema de nivelación tradicional hacia uno más inteligente, con hallazgos que ofrecen una base sólida para impulsar nuevas propuestas de manufactura inteligente que contribuyan a mejorar la competitividad y la sostenibilidad de la industria automotriz con modelos de nivelación predictivos y dinámicos para este sector.***

***Palabras clave-- Heijunka, Machine Learning, manufactura esbelta, industria automotriz, nivelación de la producción, Industria 4.0.***

## I. INTRODUCCIÓN

En el escenario actual, la industria automotriz constituye uno de los motores más importantes de la economía mundial, para la Organización de las Naciones Unidas para el Desarrollo Industrial (ONUDI), cada empleo creado en el sector manufacturero genera en promedio 2.5 empleos adicionales en otros sectores de la economía, y las empresas industriales concentran el 60% de todas las patentes verdes a nivel mundial, lo que evidencia su rol central en la innovación tecnológica global [1]. A nivel sectorial, en el 2024 las ventas mundiales de automóviles alcanzaron 74.6 millones de unidades, un incremento del 2.5% respecto al año anterior, mientras que en países como México la industria automotriz aporta cerca del 4.5% del Producto Interno Bruto (PIB) nacional y más del 20% del PIB manufacturero, generando un millón de empleos directos y 3.5 millones de empleos indirectos [1].

A pesar de esta relevancia económica, el sector automotriz enfrenta una problemática recurrente, con una alta variabilidad de la demanda y la producción de modelos mixtos generan desequilibrios en las líneas de ensamblaje, sobrecostos logísticos y desperdicios de tiempo y recursos. Para hacer frente a esta situación, la industria ha recurrido históricamente a Heijunka, herramienta del Sistema de Producción Toyota orientada a nivelar el volumen y la mezcla de producción. Sin embargo, su aplicación tradicional depende en gran medida de ajustes manuales y de la experiencia del personal de planta, lo que limita su capacidad de adaptación ante cambios abruptos de la demanda, un problema que se intensifica en el contexto de la Industria 4.0, donde tecnologías emergentes como el Machine Learning ofrecen nuevas posibilidades de automatización y predicción aún poco exploradas en conjunto con esta herramienta.

Con relación al sistema de nivelación de la producción, Heijunka consiste en distribuir de manera uniforme el volumen y la variedad de artículos producidos a lo largo de un periodo determinado, evitando picos y valles en la carga de trabajo que ocasionen sobreproducción, acumulación de inventarios innecesarios y sobrecarga de recursos humanos y productivos. En consecuencia, la nivelación se convierte en la base que sostiene la estabilidad de un sistema de producción, asegurando que la fabricación responda de manera efectiva la demanda real del cliente [2].

Bajo esta misma perspectiva, la manufactura esbelta, constituye una estrategia de gestión en el que se integra Heijunka con sus principales herramientas. Según [3], la filosofía de gestión busca maximizar el valor entregado al cliente mediante la eliminación sistemática de toda actividad que no agregue valor al proceso productivo. Para lograrlo, se promueve la optimización del flujo de materiales e información a través de herramientas como el Just in Time, el Kanban y el propio Heijunka, con el fin de lograr procesos más ágiles, flexibles y eficientes.

En este contexto, el Machine Learning, se posiciona como una tecnología clave para fortalecer la planificación y la nivelación de la producción en Heijunka. El autor [4], lo define como el campo de estudio que proporciona a los sistemas computacionales la capacidad de aprender patrones a partir de datos históricos y mejorar su desempeño en tareas específicas sin necesidad de ser programados explícitamente

para cada escenario. En consecuencia, esta tecnología, permite generar predicciones, clasificaciones o decisiones automatizadas frente a escenarios cambiantes o inciertos, alineada con los principios de la manufactura inteligente. La figura 1, ilustra la transición de un Heijunka tradicional, hacia un enfoque inteligente y dinámico impulsado por Machine Learning.

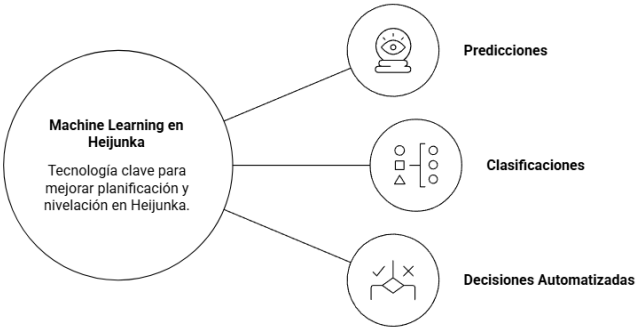



*Figura 1. Impacto de Machine Learning en Heinjunka.*

En ese marco, los autores [5] desarrollaron un modelo de programación lineal entera mixta (MILP) junto con un procedimiento metaheurístico para optimizar la secuenciación Heijunka en una línea de ensamblaje de la planta de motores Nissan en Barcelona, logrando un ahorro promedio de 1,162.83 euros diarios al transformar la línea tradicional en un esquema Heijunka-flow shop. Asimismo, los investigadores [16], realizaron una revisión sistemática de 257 artículos (seleccionados de un universo de 2,786) sobre aplicaciones de Machine Learning y Deep Learning en manufactura automotriz, encontrando que el mantenimiento de equipos concentra el 31% de los estudios y que la optimización de la cadena de suministro es el área con mayor crecimiento entre 2022 y 2025.

Por otro lado, el caso de la industria automotriz (planta ZF, México), según [6] se implementaron Heijunka de forma tradicional en la línea de ensamblaje TCS II, logrando que el indicador de entregas a tiempo (OTD) se recuperara del 0% al 100%, que la capacidad de producción diaria aumentara un 500% (de 162 a 810 piezas), que el tiempo de ciclo se redujera en un 60% (de 3.10 a 1.26 minutos) y que el Lead Time cayera de 15 a 4 días. Pese a estos resultados, estos autores concluyeron, que el enfoque depende de ajustes manuales, sin automatización ni adaptación en tiempo real, por lo que recomiendan incorporar Machine Learning para crear un "Heijunka Dinámico" capaz de predecir fluctuaciones y balancear la línea automáticamente.

A partir de lo descrito en los párrafos anteriores, se logró formular la siguiente pregunta para el análisis de la revisión sistemática de la literatura científica: ¿De qué manera la aplicación de Machine Learning en Heijunka optimiza la producción y la logística en las empresas del sector automotriz?

Por ello, el objetivo de este estudio es analizar de qué manera la aplicación de Machine Learning en el sistema Heijunka optimiza la producción en las empresas del sector automotriz, a través de una revisión sistemática de la literatura científica de los últimos seis años.

## II. METODOLOGÍA

El presente estudio se desarrolló a partir de un análisis sistemático que sigue cuidadosamente la metodología PRISMA 2020. La estrategia de búsqueda cubrió el periodo (2020-2026) en base de datos de alto impacto como Scopus, Web of Science, Scielo y ScienceDirect.

Las ecuaciones de búsqueda trilingües (español, inglés y portugués) combinaron términos clave incluyendo "machine learning", "artificial intelligence", "aprendizaje automático" e "inteligencia artificial" (detallados en la tabla 1).

El proceso consistió en una lectura comparativa y depurativa, donde se identificaron los conceptos, enfoques y evidencias más relevantes de cada fuente, organizándolos de forma coherente para construir un marco metodológico claro y utilizable para el estudio sobre todo, aquellas evidencias prácticas que realmente ilustran cómo esta fusión tecnológica está revolucionando el Heijunka a través de Machine Learning.

Esta estrategia permitió unificar criterios y concentrar los aportes vinculados a la mejora del desempeño de Heijunka mediante herramientas digitales avanzadas (IA).
El detalle de las ecuaciones de búsqueda y las bases de datos se resume en la Tabla 1.

TABLA I
COMANDOS UTILIZADOS

| BASE DE DATOS | ECUACIONES DE BÚSQUEDA |
|---|---|
| Scopus | ((("machine learning") OR ("artificial intelligence") OR ("aprendizaje automático") OR ("inteligencia artificial") ) AND (Heijunka OR ("production leveling") OR ("nivelación de la producción")) AND ((automotive) OR (automotriz) OR ("automotive industry") OR ("industria automotriz")) AND ((efficiency) OR (eficiencia) OR (productivity) OR (productividad) OR (optimization) OR (optimización) OR (waste) OR (desperdicio))) |
| Web of science (WoS) | (("machine learning" OR "inteligencia artificial") AND (Heijunka OR "production leveling") AND (automotive OR automotriz)) |
| Scielo | ("machine learning" OR "inteligencia artificial") AND (Heijunka OR "production leveling") AND (automotive OR automotriz) |
| Science Direct | ("machine learning" OR "artificial intelligence" OR "deep learning") AND (Heijunka OR "production leveling" OR "lean manufacturing") AND (automotive OR "automotive industry") |

Fuente: Elaboración propia

Una vez definidas las ecuaciones de búsqueda, se establecieron los criterios de inclusión y exclusión que permitieron delimitar la muestra final de artículos analizados, los cuales se detallan en la Tabla 2.

Tabla II
CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

| Se incluyeron | Se excluyeron |
|---|---|
| Artículos publicados entre 2020 y 2026. | Artículos publicados fuera del período 2020–2026 |
| Artículos con texto completo y acceso gratuito | Artículos sin texto completo. |
| Artículos indexados en las bases de datos Scopus, Web of Science (WoS) y SciELO. | Artículos no indexados en Scopus, Web of Science (WoS) y SciELO. |
| Artículos relacionados con las categorías de estudio. | Artículos que no guardan relación con las categorías de estudio. |

Fuente: Elaboración propia

## III. RESULTADOS

El proceso de revisión explicado anteriormente se basa en la metodología PRISMA [10], la cual propone un sistema de evaluación de revisión sistemática basado en la valoración de diversos componentes clave del diseño y la ejecución de los estudios científicos, organizados en cuatro fases: identificación, cribado, elegibilidad e inclusión. La aplicación conjunta de las ecuaciones de búsqueda (Tabla 1) y los criterios de selección (Tabla 2) permitió depurar el universo inicial de publicaciones hasta obtener una muestra final de 80 artículos científicos, distribuidos en las cuatro bases de datos consultadas: Scopus (54 artículos, 67.5%), ScienceDirect (13 artículos, 16.25%), Web of Science (9 artículos, 11.25%) y SciELO (4 artículos, 5%), los cuales constituyen el corpus documental analizado en la sección de Resultados y Discusión.

Como se observa en la figura 2, Scopus concentró el mayor número de artículos seleccionados, representando la principal fuente de evidencia científica utilizada en esta revisión sistemática. Esto evidencia que dicha base de datos posee una amplia cobertura de investigaciones relacionadas con Machine Learning, Lean Manufacturing, Industria 4.0 y Heijunka. En segundo lugar, Web of Science aportó investigaciones de alta calidad metodológica, mientras que ScienceDirect y SciELO complementaron la revisión con estudios especializados y de acceso abierto.

El diagrama expuesto en la figura 3, muestra de forma clara todo el proceso de selección que seguimos, desde que identificamos los primeros estudios hasta los que finalmente elegimos. Se puede ver cómo fuimos filtrando la información en cada etapa.

Los 20 estudios que seleccionamos nos proporcionan información muy valiosa sobre cómo Machine Learning puede integrarse en el sistema de Heijunka. A continuación presentamos los principales resultados de forma visual para que se puedan entender fácilmente las relaciones entre los diferentes beneficios que encontramos:

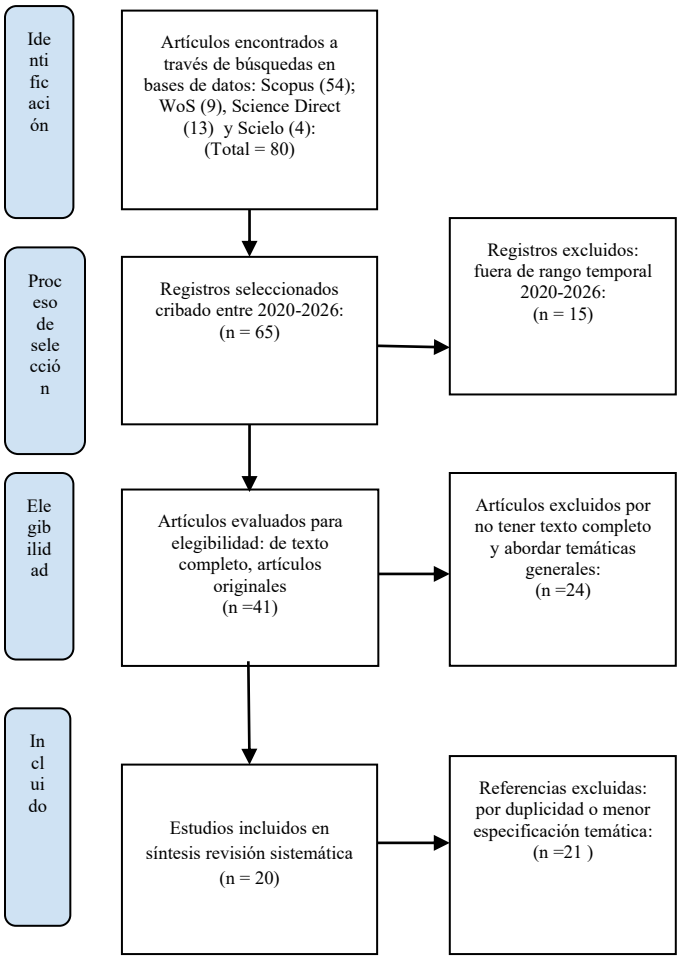



Figura. 2 Diagrama PRISMA

**Procesamiento de selección de estudios (Diagrama Prisma)**

La búsqueda ejecutada en las diferentes bases de datos como fueron Scopus, Web of Science, ScienceDirect y SciELO, finalmente fueron 20 artículos seleccionados con un enfoque predominantemente tecnológico.

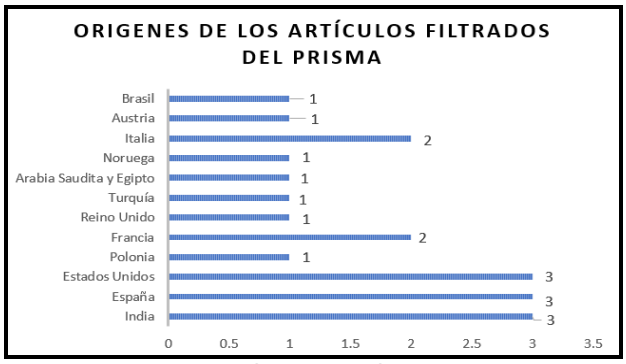



Figura. 3. Selección de artículos relacionados con Machine Learning aplicado a Heijunka en el sector automotriz

La figura 3, detalla la distribución geográfica de los artículos científicos seleccionados tras aplicar la metodología PRISMA, evidenciando una notable dispersión global con una producción liderada equitativamente por la India, España y Estados Unidos, aportando cada uno tres publicaciones a la muestra. A este grupo principal le siguen Francia e Italia con dos artículos cada uno, mientras que el resto de las contribuciones provienen de Polonia, Reino Unido, Turquía, la colaboración entre Arabia Saudita y Egipto, Noruega, Austria y Brasil, registrando una única publicación por país o bloque. Esta distribución refleja que el grueso de la literatura filtrada se concentra en instituciones norteamericanas, europeas y asiáticas, con una participación minoritaria de América Latina.

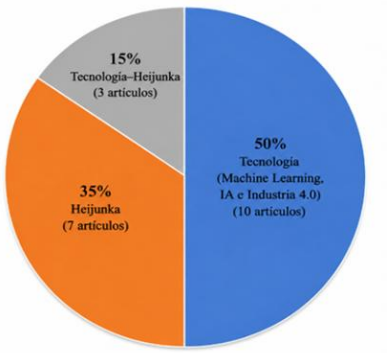



Figura 4. Porcentaje de enfoque de Estudio

La figura 4, muestra la clasificación de 20 publicaciones científicas según su enfoque de estudio, evidenciando una clara inclinación hacia las herramientas digitales avanzadas, concentrándose exclusivamente en el ámbito tecnológico, abordando conceptos de Machine Learning, Inteligencia Artificial, Heijunka e Industria 4.0.

Posteriormente, se procedió a consolidar las investigaciones seleccionadas para la presente revisión de la literatura científica. En la Tabla III, se pueden observar las publicaciones recopilidas en fomato de artículo científico.

Tabla III
Análisis de 20 artículos científicos sometidos a estudio

| N° | Base de datos | Título / Autor(es) / Año | Objetivo | Resultados | Conclusiones | Vacíos encontrados o deficiencias | Propuesta o recomendaciones | País | Enfoque |
|---|---|---|---|---|---|---|---|---|---|
| 11 | Scopus | Industry 4.0 technologies integration with lean production tools: a review /Hirendra Singh y Bhim Singh/ 2024 | Revisar la literatura científica para examinar la integración de los conceptos y herramientas de manufactura esbelta (Lean Manufacturing) con las plataformas impulsadas por tecnologías de la Industria 4.0 (I4.0). | Tras analizar sistemáticamente 195 estudios, se demostró que integrar I4.0 con Lean es un método sumamente eficaz. Permite a las empresas mejorar su productividad, flexibilidad, velocidad y precisión eliminando las actividades que no agregan valor en la cadena de suministro. | La digitalización de la manufactura esbelta mediante IA, aprendizaje automático e IoT transforma el sistema de producción. Esta sinergia optimiza las operaciones, facilita la personalización y promueve una mejora continua. | La revisión general de este campo indica una necesidad de mayor investigación empírica sobre los desafíos prácticos de implementación y la cuantificación precisa de los beneficios en sectores industriales específicos. | Se recomienda imperativamente a las organizaciones globales integrar las tecnologías I4.0 con las prácticas Lean como estrategia principal para sobrevivir, innovar y mantener su competitividad en el mercado moderno. | India | Tecnología |
| 12 | Sciencedirect | Applications of artificial intelligence in industry 4.0 and smart manufacturing" / Audrey Cerqueus, Alexandre Dolgui, Dmitry Ivanov, Alexandr Klimtchik, David Lemoine, Anatol Pashkevich / 2025 | Presentar un número especial enfocado en las aplicaciones de la inteligencia artificial, optimización y programación en la Industria 4.0, robótica y planificación de producción. | Tras un proceso de revisión por pares, se seleccionaron 27 artículos que abordan aplicaciones de IA en programación de producción, control de maquinaria, robótica inteligente y optimización de procesos | Una amplia gama de problemas complejos en la manufactura inteligente se resuelven exitosamente empleando técnicas de IA, mejorando el control robusto, la logística y la colaboración humano-robot | Se identificaron desafíos como la falta de transparencia en modelos de toma de decisiones ("caja negra"), muestras desequilibradas en detección de defectos superficiales y sesgos en predicciones a largo plazo debido a variables dinámicas acopladas. | Explorar futuras direcciones de investigación que incluyan el aprendizaje supervisado y no supervisado, la transferencia de aprendizaje, la detección de anomalías y la aplicación de metodologías híbridas de aprendizaje profundo en contextos industriales complejos. | Francia | Tecnología |
| 13 | Scopus | Secuenciación Heijunka en líneas de ensamblaje con opciones de producto, sobrecarga de trabajo y duración variable de la jornada laboral. Joaquín Bautista-Valhondo Rocío Alfaro-Pozo,Amaia Lusa. Año: 2026 | Optimizar la secuenciación Heijunka en líneas de ensamblaje mediante un modelo MILP para reducir la sobrecarga de trabajo. | La eliminación de buffers y la reducción de la jornada laboral ocasionaron pérdidas entre 8 400 y 52 000 euros diarios. | Heijunka mejora el equilibrio productivo, pero ciertas restricciones reducen significativamente la producción. | No incorpora IA, no analiza el factor humano y se limita a un caso específico | Integrar IA, ampliar su aplicación a otros sectores y evaluar factores humanos y escenarios reales. | España | Heijunka |
| 14 | Scopus | Mejora de las operaciones mediante un paradigma de IA ajustada: una visión de la fabricación ajustada asistida por IA a través de una red neuronal convolucional versátil.Mohammad Shahin, Mazdak Maghanaki, Ali Hosseinzadeh y F. Frank Chen. Año: 2024. | Analizar cómo la integración de la Inteligencia Artificial (IA) y las herramientas Lean Manufacturing puede optimizar los procesos productivos, reducir desperdicios y mejorar la eficiencia operativa mediante el uso de redes neuronales convolucionales (CNN) | La combinación de IA y Lean permitió automatizar herramientas como 5S, Kanban y el Mapeo de Flujo de Valor. Se evidenció una mejora en el mantenimiento predictivo, el control de calidad, la toma de decisiones en tiempo real y la optimización de los procesos productivos. Además, se desarrollaron siete casos de estudio que demostraron beneficios en la manufactura | La integración entre Lean Manufacturing e IA puede transformar la manufactura tradicional, elevando la productividad, reduciendo desperdicios y estableciendo nuevos estándares de excelencia operativa. Sin embargo, su éxito depende de la disponibilidad de datos confiables y de una correcta implementación tecnológica. | Existen problemas relacionados con la calidad de los datos, el sesgo algorítmico, la falta de transparencia en algunos modelos de IA (efecto "caja negra"), la necesidad de personal capacitado y los altos costos de implementación en algunas empresas. | Implementar sistemas de gestión de datos de alta calidad, capacitar al personal, integrar gradualmente la IA con las herramientas Lean y desarrollar modelos más transparentes y explicables para generar confianza en la toma de decisiones. | Estados Unidos | Tecnología |
| 15 | Web Of Science | Multivariate simulation analysis of production leveling (heijunka) – a case study Korytkowski, P.; Wisniewski, T.; Rymaszewski, S. 2013 | Evaluar mediante simulación de eventos discretos y análisis multivariado (MANOVA) cómo la nivelación heijunka-kanban reduce el tiempo de ciclo y el trabajo en proceso en una línea de ensamblaje de microelectrónica. | La disposición óptima de heijunka redujo significativamente el tiempo de ciclo promedio y el inventario en proceso; se identificó que la combinación kanban + heijunka es superior a usar solo kanban en estado estacionario. | Heijunka aplicado correctamente estabiliza el flujo productivo y elimina el efecto bullwhip. La simulación discreta es una herramienta válida para calibrar parámetros óptimos antes de implementar en planta. | El estudio se realiza en microelectrónica , no en automotriz. No integra ML ni técnicas de IA. Demanda considerada estacionaria, sin variabilidad real de mercado | Extender el modelo a entornos con demanda variable y múltiples referencias. Incorporar aprendizaje automático para ajustar parámetros heijunka en tiempo real. | Polonia | Tecnología / Heijunka |
| 16 | Web Of Science | ML and Deep Learning in automotive manufacturing: Systematic literature review (Toyota France) Plantec, Q.; Deval, M.A.; Hooge, S.; Weil, B. 2025 | Revisar sistemáticamente 257 artículos (de 2786) sobre aplicaciones de ML y DL en manufactura automotriz en cinco dominios: cadena de suministro, | El mantenimiento de equipos concentra el 31% de los estudios. Random Forest y LSTM son los algoritmos más frecuentes. La optimización de la cadena de suministro es el área con mayor crecimiento reciente | ML y DL transforman la manufactura automotriz en todos sus dominios. La integración con Industry 4.0 y gemelos digitales representa la | No aborda explícitamente la integración de ML con herramientas lean como heijunka. Cobertura limitada a artículos en inglés. Falta de | Investigar la fusión de herramientas lean (heijunka, kanban) con modelos ML para nivelación inteligente de producción. Desarrollar marcos de | Francia | Tecnología |

| | | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| | | | mantenimiento, calidad, eficiencia productiva y energía. | (2022–2025). | frontera de investigación más activa | análisis de barreras de implementación en países en desarrollo. | implementación para PYMEs del sector automotriz. | | | |
| 17 | Web Of Science | Industry 4.0 in manufacturing: lean to product design (CPS Heijunka + DVSM) Chan, F.T.S.; Lau, H.C.W.; Ip, R.W.L.; Chan, H.K.; Kong, S. 2022 | Integrar Heijunka con sistemas CPS e Industry 4.0 mediante Dynamic Value Stream Mapping (DVSM) para lograr manufactura esbelta adaptativa en tiempo real. | DVSM captura mejoras a nivel de proceso individual, complementando el VSM tradicional. CPS Heijunka ajusta estrategias en entornos cambiantes y mejora el balance de línea en tiempo real. | La digitalización de heijunka mediante CPS y DVSM permite responder dinámicamente a fluctuaciones de demanda, superando las limitaciones del heijunka estático tradicional | No implementa ML/IA directamente sobre heijunka. Validación limitada a un solo caso de estudio. No evalúa el costo computacional del sistema CPS en tiempo real. | Incorporar algoritmos de ML para predicción de demanda integrada al CPS-Heijunka. Ampliar validación a plantas automotrices de múltiples líneas. | Reino Unido | Tecnología |
| 18 | Scopus | Heijunka-Levelling customer orders: a systematic literature review Boutbagha, Meryem; El Abbadi, Laila 2024 | Dar una idea sobre las áreas de investigación más importantes relacionadas con Heijunka y proponer una agenda para investigación futura mediante revisión sistemática de literatura | Se revisaron 60 artículos con criterios de inclusión/exclusión; Heijunka recibió poca atención en literatura académica; Existimiento de 3 temas principales: (1) Implementación de Heijunka y beneficios, (2) Resolución de problemas relacionados con Heijunka usando optimización, (3) Heijunka y tecnologías Industry 4.0 | Heijunka es concepto central del Sistema de Producción Toyota que mantiene flexibilidad y estabilidad produciendo misma cantidad de productos cada intervalo de tiempo; Heijunka recibió poca atención en literatura académica; Existen 3 áreas principales de investigación: implementación/ beneficios, optimización para resolución de problemas, tecnologías Industry 4.0; Revisión puede tener limitaciones relacionadas con número de artículos revisados | Proponer agenda para investigación futura en Heijunka; Investigar más sobre implementación de Heijunka y beneficios; Explorar optimización para resolución de problemas relacionados con Heijunka; Estudiar integración de Heijunka con tecnologías Industry 4.0; Aumentar atención académica al concepto Heijunka (actualmente poco estudiado) | Heijunka recibió poca atención en literatura académica; Falta de investigación sobre Heijunka; Concepto central del Sistema Toyota con poca exploración académica; Necesidad de agenda de investigación futura; Limitaciones en número de artículos revisados; Posible exclusión uninte ntional de artículos importantes | España | Heijunka |
| 19 | Scopus | Enfoque de programación multiobjetivo para el problema de nivelación de producción: un ejemplo de subindustria auto motriz Tutumlu, Büşra; Aydoğan Baş, S.; Kocakalay, Ş. 2024 | Aplicar método Heijunka de producción nivelada en empresa que produce espuma de moldes; proponer modelo matemático lineal multiobjetivo que incluye elementos de nivelación de producción, secuencia y estabilidad de trabajo; resolver con método de suma ponderada usando GAMS/CPLEX | Se obtuvo solución donde valor Heijunka fue 4 con modelo propuesto, mientras valor Heijunka en sit uação actual fue 2; Esto indica efecto positivo de método Heijunka en empresa y proceso de producción más equilibrado; Modelo confrontado con situación actual; Se calcularon valores Heijunka de dos situaciones para mostrar éxito del modelo | En este estudio, método Heijunk a de producción nivelada fue examinado en empresa de producción de espuma de moldes; Se propuso modelo matemático lineal multiobjetivo que incluye nivelación de producción, secuencia y estabilidad de trabajo; Se solucionó con método de suma ponderada debido a multiobjetivo; Comparación con situación actual mostró efecto positivo de Heijunka en empresa y proceso más equilibrado | Implementar Heijunka en industria automotriz; modelo multiobjetivo con nivelación/secue ncia/estabilidad; suma ponderada; confrontar con situación actual; calcular valores Heijunka | Proceso de producción no equilibrado en situación actual; Valor Heijunka de 2 indica producción irregular; Falta de nivelación de producción (no aplica Heijunka); Sin secuencia óptima de producción; Estabilidad de trabajo insuficiente; Israeli en empresa de producción de espuma de moldes | Turquía | Heijunka |
| 20 | Scopus | To develop Lean Systems in Electronic Automotive Parts Manufacturing: A dynamic systems modeling approach. Shetty, Doraiswamy K. 2019 | Investigar desafíos de implementación de producción nivelada (Heijunka) en fabricación de piezas electrónicas automotrices mediante enfoque de modelización dinámica de sistemas | Se propone enfoque de modelización dinámica de sistemas para investigar desafíos de implementación de producción nivelada; Se desarrolló modelo usando dinámica de sistemas; Análisis de implementación de Lean en industria automotriz electrónica | La modelización dinámica de sistemas es enfoque efectivo para investigar implementación de producción nivelada; Los desafíos de implementación de Lean en industria automotriz electrónica pueden ser analizados mediante dinámica de sistemas; Enfoque puede extrapolarse para otras industrias | Aplicar modelización dinámica de sistemas para investigar implementación de producción nivelada; Usar dinámica de sistemas para analizar desafíos de Lean en industria automotriz; Extrapolara enfoque para otras industrias de fabricación | Industria automotriz electrónica sin producción nivelada (sin Heijunka); Desafíos de implementación de Lean no identificados; Falta de modelización dinámica para análisis; Implementación de Lean ineficiente | Usa | Tecnología / Heijunka |

| | | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| 21 | Scopus | Reduce the delivery time and relevant costs in a chaotic requests system via lean-Heijunka model to enhance the logistic Hamiltonian route / Ahmed M. Abed, Ali AlArjani, Laila F. Seddek, Samia Elattar / 2024 | Optimizar la gestión de cadenas de suministro en línea (OSCM) ante flujos de datos masivos y desorganizados provenientes de los usuarios. Específicamente, busca disminuir los tiempos de entrega y los costes logísticos asociados en entornos de demanda inestables (caóticos) mediante la integración de un modelo predictivo basado en principios Lean (Smart Lean Heijunka) y tecnologías del Internet de las Cosas (IoT), para trazar una ruta óptima (Hamiltoniana) de recojo y distribuc… | Los experimentos demostraron que el algoritmo de machine learning XGBoost superó a AdaBoost en un 14.352% en la precisión para pronosticar las solicitudes del cliente, mientras que una regla heurística basada en NWBS mejoró el rendimiento del algoritmo FP-Growth sobre ECLAT en un 7.648% al estructurar la matriz Heijunka. | La convergencia de herramientas de la Industria 4.0 (como sensores IoT) con modelos avanzados de Deep Learning y la filosofía Lean es altamente eficaz para resolver la volatilidad logística en el comercio electrónico moderno. Al estabilizar los flujos de recojo y entrega sincrónicamente, el modelo demuestra que se puede erradicar la variabilidad operativa de última milla, garantizando rutas comerciales más eficientes, menor desperdicio de tiempo y un incremento directo en la… | Se identificó que las cadenas de suministro tradicionales carecen de sistemas dinámicos de comunicación y predicción en tiempo real capaces de procesar de manera eficiente volúmenes masivos y desordenados de solicitudes de clientes. Esta deficiencia genera una severa inestabilidad operativa y un constante "caos logístico" cuando se requiere prestar múltiples servicios de forma simultánea —como la recogida y entrega concurrente de paquetes en un mismo punto geográfico— debido… | La investigación propone el desarrollo del marco estructural OSCM (Online Supply Chain Management), el cual utiliza Deep Learning en una primera fase para pronosticar la variabilidad de la demanda en una matriz Heijunka inteligente de zonas de servicio, seguido de una fase de asignación física y rastreo en tiempo real mediante IoT. | Arabia Saudita Y Egipto | Heijunka |
| 22 | Scopus | Heijunka 4.0 – Key Enabling Technologies for Production Levelling in the Process Industry / Håkon Strømfjord Kjellsen, Quentin Jean-Louis Ramillon, Heidi Carin Dreyer, Daryl John Powell / 2021 | Investigar cómo los métodos tradicionales de nivelación de la producción Lean (específicamente Heijunka) se pueden aplicar de manera más eficaz en la compleja industria de procesos masivos y semi-continuos mediante el soporte estratégico de las tecnologías habilitadoras clave de la Industria 4.0. | A través del análisis operativo de la integración tecnológica se demostró que herramientas avanzadas como el Internet de las Cosas (IoT) y la Analítica de Grandes Datos (Big Data Analytics) proveen flujos continuos de información precisa sobre las características físicas del entorno de manufactura. | La convergencia entre la manufactura esbelta (Lean) y la transformación digital, concebida como un ecosistema Lean 4.0, es indispensable para las organizaciones industriales que enfrentan entornos de alta volatilidad. La adopción de tecnologías inteligentes no compite con los principios clásicos de optimización, sino que actúa como un catalizador que potencia las prácticas tradicionales. | Se identificó que el concepto tradicional de Heijunka fue diseñado originalmente para entornos de manufactura discreta con tiempos de preparación muy cortos, por lo que históricamente se ha considerado inaplicable o inviable en la industria de procesos continuos debido a sus extensos tiempos de cambio y rigidez en las líneas de producción. | La investigación propone un marco conceptual basado en la interconexión del Internet de las Cosas (IoT), Big Data Analytics y la integración profunda de los sistemas informáticos (IT) corporativos para dotar de una mayor confiabilidad y visibilidad a los materiales, equipos y pronósticos de demanda. | Noruega | Heijunka |
| 23 | Scopus | Digitalization of Lean Tools and Techniques: Enhancing Efficiency and Quality in Modern Industries / Gohitha Maheshwari J, Vivekanand S Gogi, Inchara N Aradhya, Shankaramma / 2024 | Analizar el proceso de digitalización de las herramientas y técnicas Lean tradicionales mediante la adopción de tecnologías avanzadas de la Industria 4.0 (como el Internet de las Cosas, la Inteligencia Artificial y la automatización), con el fin de evaluar cómo estas innovaciones transforman los métodos operativos principales para maximizar la eficiencia, eliminar desperdicios y optimizar el control de calidad. | Mediante el análisis profundo de casos de estudio detallados en corporaciones líderes globales como Toyota, Ford, Amazon, Boeing, Honda, Intel, Nestlé, Starbucks, General Electric, e instituciones de salud como el Mayo Clinic y Kaiser Permanente, la investigación demostró de manera cuantitativa y cualitativa el impacto de la transformación digital sobre metodologías clásicas como Kanban, VSM, Heijunka, SMED y Poka-Yoke. | La digitalización de las metodologías Lean no reemplaza sus principios tradicionales de optimización, sino que actúa como un catalizador que los revoluciona y adapta para la era digital. La transición hacia un ecosistema digitalizado permite que herramientas que históricamente dependían de registros estáticos o manuales pasen a operar bajo dinámicas reactivas en tiempo real. | Se identificó que las herramientas Lean tradicionales en su formato analógico original adolecen de una naturaleza estática y dependen excesivamente del factor humano para la recopilación de datos, lo que limita gravemente la visibilidad operativa en tiempo real y ralentiza la toma de decisiones críticas ante variaciones imprevistas en la línea de producción o flujos de servicio. | El documento propone un marco integral de referencia y una guía estratégica para la digitalización sistemática de más de una docena de herramientas clave de la manufactura esbelta mediante el despliegue de soluciones basadas en IoT, Inteligencia Artificial y automatización de procesos. | India | Tecnología / Heijunka |
| 24 | Scopus | Investigating the Potential of Machine Learning and Deep Learning Models in Probabilistic Supply Risk Forecasting: A Case Study in the Automotive Sector / Matteo Gabellini, Alberto Regattieri, Marco Bortolini, Francesco G. Galizia / 2025 | Evaluar y comparar el rendimiento de los modelos tradicionales, de Machine Learning y de Deep Learning para realizar predicciones probabilísticas sobre el riesgo de suministro y la puntualidad de los proveedores en el sector | Proponer un modelo lineal multiobjetivo que integra la nivelación de producción (Heijunka), la secuenciación y la estabilidad laboral en una empresa de fabricación de esponjas para moldes del sector automotriz, logrando equilibrar el proceso productivo y duplicar el indicador de | El estudio concluye que transicionar de los enfoques deterministas hacia modelos predictivos de corte probabilístico para el pronóstico de riesgos es una estrategia fundamental y altamente valiosa para las | Se identificó que la gran mayoría de las investigaciones previas en la gestión de riesgos de suministro se han limitado casi exclusivamente a examinar la capacidad de las herramientas de IA para generar predicciones estrictamente | La investigación propone un marco metodológico comparativo enfocado en la cadena de suministro automotriz que introduce la evaluación holística de modelos predictivos mediante métricas | Italia | Tecnología |

| | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|
| | | | automotriz, considerando horizontes de pronóstico tanto a corto como a largo plazo. | eficiencia Heijunka en comparación con la situación actual. | empresas que operan bajo sistemas Just-in-Time (JIT) o de Manufactura Esbelta (Lean). | deterministas (valores fijos de cumplimiento o retraso). | avanzadas de validación por intervalos y parámetros de eficiencia computacional. | | |
| 25 | Web Of Science | Assessing the transition from mass production to lean manufacturing using a hybrid simulation model of a LEGO® automotive assembly line / Michail Katsigiannis, Minas Pantelidakis, Konstantinos Mykoniatis / 2024 | Evaluar el efecto del uso de técnicas de manufactura esbelta (Lean Manufacturing) y el proceso de transición desde una instalación de producción en masa mediante la aplicación de un enfoque de simulación híbrido (eventos discretos y agentes) en una línea de ensamblaje automotriz educativa de LEGO. | El enfoque de simulación híbrida modeló con éxito la instalación, demostrando que el escenario alternativo (JIT + Heijunka) mejoró significativamente todas las métricas operativas analizadas: el tiempo de entrega general del sistema se redujo en un 47.37%, el rendimiento o capacidad de producción se incrementó en un 5.99%, y el inventario en procesoacumulado en las estaciones de trabajo disminuyó drásticamente hasta en un 56.73%. | Se concluye que el modelado y simulación híbrida funcionan eficazmente para analizar instalaciones manufactureras, demostrando que la transición hacia estrategias JIT combinadas con la nivelación Heijunka optimiza notablemente los flujos y el rendimiento frente a la producción en masa tradicional. | Al desarrollarse el estudio sobre una línea de ensamblaje educativa basada en piezas LEGO, el modelo no incluye la complejidad real de una planta industrial real, como fallas mecánicas imprevistas pesadas o retrasos externos de proveedores. | Se propone extrapolar este enfoque innovador de simulación híbrida para modelar de forma predictiva y segura la transición de producción en masa a manufactura esbelta en otras instalaciones y sectores industriales de gran escala. | Estados Unidos | Heijunka |
| 26 | Scopus | Data-Driven Value Stream Analysis using Process Mining and Machine Learning / Tomidei, L., Sick, N., Mathieson, L. / 2024 | Desarrollar un método para identificar flujos de valor a partir de datos de producción utilizando técnicas de Process Mining y Machine Learning. | El método permite identificar familias de productos y operaciones de trabajo, facilitando la visualización de modelos de procesos para la planificación de la producción. | La integración de minería de procesos y aprendizaje automático mejora significativamente la visualización de flujos productivos complejos. | Existe una falta de estandarización en los sistemas de recolección de datos industriales, lo que limita la calidad del análisis. | Se recomienda mejorar la infraestructura de datos digital antes de aplicar soluciones avanzadas de aprendizaje automático. | Austria | Tecnología |
| 27 | Scopus | Machine Learning-Based Predictive Modeling and Control of Lean Manufacturing in Automotive Parts Manufacturing Industry / Solke, N.S. , Shah, P. , Sekhar, R. , Singh, T.P. / 2022 | Desarrollar un modelo basado en Machine Learning para mejorar el control de procesos de Lean Manufacturing en una empresa de autopartes del sector automotriz. | El modelo predictivo mejoró el control de los procesos, redujo desperdicios y defectos, y aumentó la eficiencia y productividad de la producción. | Machine Learning fortalece la implementación de Lean Manufacturing al optimizar la toma de decisiones y mejorar el desempeño de los procesos productivos. | No aborda la aplicación de Heijunka, ni la optimización de la logística o la cadena de suministro. El estudio se limita a una sola empresa. | Integrar Machine Learning con Heijunka y la gestión logística para optimizar la planificación de la producción y la cadena de suministro en el sector automotriz. | India | Tecnología |
| 28 | Scopus | Does Industry 4.0 improve productivity? Evidence from the Italian automotive supply chain / Calabrese G.G.,Falavigna G./ 2022 | Analizar el impacto de la implementación de tecnologías de Industria 4.0 en la productividad de la cadena de suministro automotriz italiana. | La adopción de Industria 4.0 mostró mejoras en algunos procesos y empresas, aunque el impacto en la productividad no fue uniforme en toda la cadena de suministro. | La productividad depende no solo de la incorporación de tecnologías digitales, sino también de factores organizacionales , capacidades empresariales y el nivel de digitalización de cada empresa. | No analiza la aplicación de Machine Learning ni de Heijunka. Tampoco desarrolla modelos predictivos para la planificación de la producción o la logística. | Investigar la integración de Machine Learning e Inteligencia Artificial con estrategias Lean e Industria 4.0 para optimizar la producción, la logística y la cadena de suministro en el sector automotriz. | Italia | Tecnología |
| 29 | Scopus | Exact and heuristic procedures for the Heijunka-flow shop scheduling problem with minimum makespan and job replicas / Joaquín Bautista-Valhondo / 2021 | Resolver el problema de secuenciación tipo Heijunka-flow shop con reglas de no unicidad de demanda, minimizando el tiempo total de finalización (Cmax) mediante programación lineal entera mixta y un procedimiento metaheurístico. | Ambos procedimientos (programación lineal entera mixta y metaheurística basada en Multistart y búsqueda local) lograron soluciones de alta calidad en tiempos de cómputo reducidos. El caso de estudio en la planta de motores Nissan de Barcelona reveló un ahorro promedio de 1162,83 euros diarios al transformar la línea de ensamblaje actual en un Heijunka-Flow Shop. | La transformación de líneas de ensamblaje tradicionales hacia esquemas Heijunka-flow shop es económica y organizacionalmente viable, permitiendo fabricar más unidades en la misma jornada laboral sin sacrificar la mezcla de producción. | El modelo no incorpora el factor de actividad de los operarios ni la posibilidad de bloqueo del flujo productivo entre estaciones de trabajo, limitando su aplicación a escenarios más realistas y dinámicos. | Incorporar en futuros modelos el factor de actividad de los operarios y algoritmos de aprendizaje automático que permitan ajustar dinámicamente la secuenciación Heijunka ante variaciones reales de la demanda. | España | Heijunka |
| 30 | Scopus | A Deep Learning-Based Computer Vision System for Automated Screw Detection in Vehicle Wheel Boxes: Enhancing Automotive Quality Control with Industry 4.0 / Decio Tomio Sakuma, Carlos Marcelo Gurjão de Godoy, Regina Celia Coelho / 2025 | Desarrollar un sistema de visión por computadora basado en aprendizaje profundo para detectar automáticamente tornillos instalados en cajas de ruedas de vehículos en una línea de ensamblaje en movimiento, mejorando el control de calidad automotriz. | El sistema, que combina un montaje de adquisición de imágenes personalizado con el algoritmo de detección de objetos YOLOv8 y datos sintéticos de entrenamiento, alcanzó una precisión de detección de tornillos del 92%, frente al 71% obtenido mediante inspección visual tradicional. | Los enfoques basados en Inteligencia Artificial pueden mejorar significativamente los procesos de aseguramiento de calidad en la manufactura automotriz, especialmente en entornos de producción de ritmo acelerado donde la inspección humana resulta insuficiente. | El sistema se valida únicamente para la detección de tornillos en cajas de ruedas, sin extenderse a otros componentes críticos de ensamblaje ni evaluar su integración con sistemas de nivelación de producción como Heijunka. | Se recomienda extender el sistema de visión por computadora a otros puntos críticos de la línea de ensamblaje automotriz y explorar su integración con sistemas Heijunka para vincular el control de calidad inteligente con la nivelación de la producción. | Brasil | Tecnología |

De la tabla III, se puede observar que en cada investigación seleccionada se indica los criterios necesarios para ser incluidos en la revisión de la literatura científica. Sintetizando 20 estudios seleccionados, integrando de manera sistemática, información clave como los objetivos, los resultados, las conclusiones, los vacíos identificados y las recomendaciones, lo que permite visualizar de forma clara cómo la tecnología fortalece el sistema Heijunka dentro del sector automotriz.

## IV. **DISCUSIÓN**

La revisión sistemática permitió analizar las evidencias científicas sobre la aplicación del Machine Learning en los sistemas de nivelación de la producción **(**Heijunka) dentro del sector automotriz, identificando los avances alcanzados, las limitaciones y las oportunidades de investigación existentes. Los hallazgos evidencian que la transformación digital impulsada por la Industria 4.0 ha favorecido la incorporación de tecnologías como la Inteligencia Artificial, el Internet de las Cosas (IoT), Big Data y el aprendizaje automático para optimizar la manufactura esbelta; sin embargo, la integración específica entre Machine Learning y Heijunka, aún evidencia un bajo nivel de desarrollo.

### A. La Inteligencia Artificial en la Industria 4.0

Los estudios que analizan la relación entre Lean Manufacturing**,** la Industria 4.0 y la Inteligencia Artificial coinciden en señalar que la transformación digital se ha convertido en un elemento clave para fortalecer la competitividad de los sistemas productivos [11], [12], [14], [16], [23], [27], [28], [30]. En conjunto, estas investigaciones buscaron comprender de qué manera las tecnologías inteligentes potencian las herramientas tradicionales de Lean, mejoran la planificación de la producción y favorecen un control de calidad más eficiente. Los resultados respaldan esta tendencia con datos concretos. Según [11], tras analizar 195 estudios, concluyeron que la integración entre Lean e Industria 4.0 incrementa la productividad, la flexibilidad y la precisión de los procesos. En la misma línea, los autores [12] revisaron 27 investigaciones que demostraron aplicaciones exitosas de la inteligencia artificial en áreas como la programación de la producción, la robótica inteligente y la optimización de procesos industriales.

La evidencia también muestra un crecimiento sostenido del uso del Machine Learning en la manufactura. Para [16], después de examinar 257 artículos seleccionados entre 2786 publicaciones, encontraron que el 31 % de las investigaciones se concentra en mantenimiento predictivo y que los algoritmos Random Forest **y** LSTM son los más empleados en el ámbito automotriz. De forma complementaria, los investigadores [27], comprobaron que un modelo basado en aprendizaje automático permitió disminuir desperdicios y defectos, al mismo tiempo que mejoró la eficiencia de los procesos productivos. Resultados igualmente relevantes fueron obtenidos por [30], quienes desarrollaron un sistema de visión artificial apoyado en YOLOv8, alcanzando una precisión del 92 % en la detección automática de tornillos, una mejora considerable frente al 71 % logrado mediante inspección visual tradicional.

En conjunto, estas investigaciones permiten afirmar que la Inteligencia Artificial no reemplaza la filosofía Lean, sino que amplía sus capacidades al incorporar análisis de datos en tiempo real, automatización y modelos predictivos que favorecen una toma de decisiones más rápida y precisa.

### B. **Heijunka frente a la variabilidad de la demanda**

Un segundo grupo importante de investigaciones se centra en Heijunka como estrategia para mejorar la nivelación de la producción, confirmando que sigue siendo una de las herramientas más representativas de la manufactura esbelta [13], [15], [18], [19], [20], [22], [25], [29]. Aunque cada estudio aborda el problema desde enfoques distintos, como modelos matemáticos, simulaciones híbridas o algoritmos de secuenciación, todos persiguen un mismo propósito, que es reducir la variabilidad del sistema productivo y lograr un flujo de trabajo más estable. Los resultados respaldan claramente esta idea. Para [13], evidenciaron que ciertas restricciones operativas pueden generar pérdidas económicas que oscilan entre 8 400 y 52 000 euros por día, lo que pone de relieve el impacto que tiene una secuenciación inadecuada. En una línea similar, [15] comprobaron mediante simulación que la combinación de Kanban y Heijunka disminuye de forma significativa el tiempo de ciclo y el inventario en proceso en comparación con el uso exclusivo de Kanban.

La evidencia también muestra que el interés científico por Heijunka ha ido creciendo, aunque todavía existen vacíos importantes. Según [18], tras revisar 60 investigaciones, concluyeron que este tema continúa siendo poco explorado dentro de la literatura especializada, especialmente si se compara con otras herramientas Lean. A su vez, [19] obtuvieron resultados alentadores al incrementar el indicador Heijunka de 2 a 4**,** duplicando el nivel de equilibrio de la producción respecto a la situación inicial. Del mismo modo, [25] reportaron mejoras muy significativas al integrar Just in Time con Heijunka: el tiempo total de entrega se redujo en 47,37 %**,** la capacidad productiva aumentó en 5,99 % y el inventario en proceso disminuyó hasta en 56,73 %**.** Estos resultados se complementan con el estudio de [29], quien estimó ahorros promedio de 1 162,83 euros diarios tras implementar un esquema Heijunka-Flow Shop en una planta del sector automotriz.

Más allá de estos beneficios, los estudios revisados coinciden en que Heijunka está atravesando una etapa de evolución. Ya no se trata únicamente de una herramienta para distribuir la producción de forma equilibrada; ahora el reto consiste en hacerla capaz de responder a escenarios mucho más dinámicos y cambiantes. En este sentido, varios autores proponen incorporar Inteligencia Artificial, Machine Learning, gemelos digitales y sistemas ciberfísicos para ajustar la programación de la producción en tiempo real [13], [15], [22], [29]. Esta visión marca un cambio importante, la nivelación deja de basarse exclusivamente en reglas fijas y pasa a apoyarse en modelos predictivos que aprenden del comportamiento de la demanda. En consecuencia, Heijunka comienza a evolucionar hacia un Heijunka 4.0, donde la información generada en tiempo real permite anticiparse a las fluctuaciones del mercado, reducir la incertidumbre y tomar decisiones de producción mucho más ágiles y precisas. Esta transición resulta especialmente relevante para la industria automotriz, donde la creciente diversidad de modelos y la volatilidad de la demanda exigen sistemas de planificación cada vez más inteligentes y adaptativos.

### C. Heijunka inteligente, convergencia entre nivelación de la producción e Industria 4.0

Un tercer grupo importante de investigación se ha orientado a explorar cómo la integración de Heijunka con las tecnologías de la Industria 4.0 puede potenciar los sistemas de producción, mostrando que ambas estrategias generan mejores resultados cuando trabajan de manera conjunta que cuando se aplican por separado [17], [21], [22], [23]. En términos generales, estos estudios buscaron incorporar herramientas como el Internet de las Cosas (IoT)**,** Big Data**,** sistemas ciberfísicos, minería de procesos y modelos de aprendizaje profundo para fortalecer la nivelación de la producción y hacer más eficientes las cadenas de suministro. La evidencia respalda este planteamiento. Para [17], comprobaron que el uso de Dynamic Value Stream Mapping (DVSM)**,** integrado con sistemas ciberfísicos, mejora el balance de las líneas de producción en tiempo real frente al Value Stream Mapping tradicional. Por su parte, [21] obtuvieron resultados igualmente prometedores al demostrar que el algoritmo Extreme Gradient Boosting (XGBoost) alcanzó una precisión 14,352 % superior a Adaptive Boosting (AdaBoost) en la predicción de solicitudes de los clientes. Además, una heurística basada en el algoritmo Neighborhood-Based Weighted Search (NWBS) mejoró en 7,648 % el rendimiento de Frequent Pattern Growth (FP-Growth) respecto de Equivalence Class Transformation (ECLAT), optimizando la configuración de la matriz Heijunka para la logística de última milla.

Los avances no se limitan únicamente a los algoritmos predictivos. Según [22] evidenciaron que la integración de IoT **y** Big Data proporciona información continua y confiable que facilita la toma de decisiones y fortalece la nivelación de la producción. En la misma dirección, [23], a partir del análisis de casos desarrollados en empresas como Toyota, Ford, Amazon, Boeing e Intel, observaron que la digitalización está transformando herramientas tradicionales de Lean Manufacturing, entre ellas Heijunka, en sistemas inteligentes con capacidad para adaptarse, prácticamente en tiempo real, a las variaciones del entorno productivo. En conjunto, estos resultados muestran que la incorporación de tecnologías digitales no solo incrementa la eficiencia operativa, sino que también mejora la capacidad de respuesta frente a escenarios cada vez más dinámicos.

A partir de estas evidencias, puede afirmarse que la relación entre Lean Manufacturing **e** Industria 4.0 no representa una sustitución de los principios clásicos del Sistema de Producción Toyota, sino una evolución natural de estos. La filosofía Lean mantiene su vigencia; sin embargo, ahora se apoya en herramientas capaces de recopilar, procesar y analizar grandes volúmenes de datos para respaldar decisiones más rápidas y precisas [21], [22], [23]. Este aspecto adquiere una relevancia especial en el sector automotriz, donde la creciente personalización de los vehículos, la complejidad de las cadenas logísticas y la constante variación de la demanda obligan a disponer de sistemas de producción mucho más flexibles. En este contexto, la convergencia entre Heijunka y las tecnologías de la Industria 4.0 sienta las bases para avanzar hacia un modelo de Heijunka inteligente**,** capaz de anticiparse a los cambios del mercado y de optimizar la planificación de la producción de manera continua.

### D. **Machine Learning como catalizador del Heijunka predictivo**.

El último grupo de investigaciones, centra su atención en el uso del Machine Learning y el Deep Learning para fortalecer la gestión predictiva de la manufactura y de las cadenas de suministro [16], [24], [26], [27], [30]. Aunque cada estudio aborda un problema distinto, todos coinciden en un objetivo común: aprovechar el análisis inteligente de datos para anticipar eventos, optimizar la toma de decisiones y mejorar el desempeño de los procesos industriales. Las aplicaciones son diversas e incluyen mantenimiento predictivo, gestión de riesgos, identificación de flujos de valor, control automatizado de calidad y reducción de desperdicios.

Los resultados respaldan claramente este enfoque. Según [16], tras analizar 257 artículos seleccionados de un total de 2786 publicaciones**,** encontraron que el 31 % de las investigaciones sobre Machine Learning en manufactura automotriz se concentra en el mantenimiento predictivo, lo que evidencia el creciente interés por prevenir fallas antes de que afecten la producción. En la misma línea, [24] demostraron que los modelos probabilísticos ofrecen un mejor desempeño que los deterministas para predecir riesgos en las cadenas de suministro del sector automotriz. Por su parte, [26] desarrollaron un método que combina Process Mining con Machine Learning, logrando identificar de manera automática familias de productos y flujos de valor, lo que facilita la planificación de la producción. A estos resultados se suman los obtenidos por [27], quienes reportaron una disminución de desperdicios y una mejora en el control de los procesos gracias al empleo de modelos predictivos. De igual forma, [30] alcanzaron una precisión del 92 % en el control automatizado de calidad mediante un sistema de visión artificial basado en Deep Learning, superando ampliamente la eficacia de los métodos tradicionales de inspección.

En conjunto, estas investigaciones dejan claro que el Machine Learning ha alcanzado un nivel importante de madurez dentro de la manufactura inteligente. Hoy en día ya no se limita a tareas experimentales; por el contrario, se aplica con éxito en actividades críticas como el mantenimiento predictivo, el aseguramiento de la calidad, la gestión logística y la planificación de la producción. Sin embargo, al analizar la literatura desde la perspectiva de esta revisión sistemática, también se observa una limitación evidente: son muy pocos los estudios que integran estas capacidades predictivas con Heijunka para apoyar la nivelación dinámica de la producción.

Precisamente ahí se encuentra uno de los principales aportes de la presente investigación. Si bien la evidencia demuestra que el Machine Learning mejora la precisión de las decisiones y optimiza distintos procesos industriales [16], [24], [26], [27], [30], todavía existe una brecha importante en el desarrollo de modelos que combinen la predicción de la demanda con la nivelación de la producción propuesta por Heijunka. Este vacío resulta especialmente relevante para la industria automotriz, donde la fabricación de modelos mixtos y la creciente volatilidad del mercado exigen sistemas capaces de adaptarse en tiempo real. En este contexto, los resultados de la revisión respaldan la necesidad de evolucionar desde un esquema de nivelación tradicional hacia un Heijunka inteligente, sustentado en algoritmos predictivos que anticipen las variaciones de la demanda y ajusten automáticamente la programación de la producción. Más que reemplazar la filosofía Lean, esta evolución representa una oportunidad para fortalecerla mediante las capacidades que ofrece la Inteligencia Artificial, abriendo nuevas líneas de investigación orientadas al desarrollo de sistemas de manufactura más flexibles, resilientes y competitivos para el sector automotriz.

## IV. **CONCLUSIONES**

El trabajo de investigación permitió evidenciar que el Machine Learning represente un componente clave para la evolución de los sistemas de producción y el fortalecimiento del Heijunka

en el sector automotriz. El análisis de las 80 investigaciones publicadas entre 2020 y 2026 permitió demostrar que las tecnologías asociadas a la Industria 4.0, como la Inteligencia Artificial, el Internet de las Cosas, Big Data y los modelos de aprendizaje automático, generan mejoras concretas en la productividad, la planificación de la producción, el mantenimiento predictivo, el control de calidad y la eficiencia de las cadenas de suministro. Entre los resultados más relevantes destacan reducciones de hasta 56,73 % en los inventarios en proceso, disminuciones del 47,37 % en los tiempos de entrega, niveles de precisión del 92 % en sistemas de inspección automatizada y algoritmos predictivos con desempeños superiores en 14,352 % respecto a enfoques convencionales. En conjunto, estos hallazgos confirman que la incorporación de tecnologías inteligentes no solo incrementa la eficiencia operativa, sino que también fortalece la capacidad de las organizaciones para responder a entornos productivos cada vez más dinámicos y competitivos.

A pesar de estos avances, los resultados también ponen de manifiesto que la integración específica entre Machine Learning **y** Heijunka continúa siendo un campo de investigación emergente. Aunque ambas líneas han demostrado, por separado, resultados favorables para la optimización de los procesos productivos, todavía existe una limitada evidencia sobre modelos que integren la predicción inteligente de la demanda con la nivelación dinámica de la producción en tiempo real. Este vacío representa, precisamente, el principal aporte de este estudio, ya que pone de manifiesto la necesidad de avanzar hacia un Heijunka inteligente, sustentado en algoritmos predictivos capaces de anticipar las variaciones de la demanda y ajustar la programación de la producción en tiempo real. De este modo, la investigación ofrece una base para el desarrollo de futuras propuestas que integren los principios de Lean Manufacturing con las capacidades de la Inteligencia Artificial, favoreciendo sistemas de manufactura más flexibles, resilientes, competitivos y alineados con los desafíos de la transformación digital en la industria automotriz.

## REFERENCIAS


[1] ONUDI. (2023). *Informe sobre el Desarrollo Industrial 2024. Resumen.* Organización de las Naciones Unidas para el Desarrollo Industrial. https://www.unido.org/sites/default/files/unido-publications/2024-02/IDR24-Overview-SP.pdf

[2] Liker J., (2011). Toyota: Cómo el fabricante más grande del mundo alcanzo el éxito. Bogotá, Colombia. Grupo editorial norma

[3] Womack, J. P., & Jones, D. T. (2003). *Lean Thinking: Banish Waste and Create Wealth in Your Corporation* (2nd ed.). Free Press.

[4] Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.

[5] Bautista-Valhondo, J., Alfaro-Pozo, R., Batalla-García, C., & Cano, A. (2022). *Improving mixed-model sequencing in a Nissan engine plant through Heijunka-flow shop scheduling*. International Journal of Production Research.

[6] López Merel, H. D., Mendoza León, J. G., Santos, F. de A., & Hernández Aguirre, M. A. (2025). *Melhoria do desempenho operacional: Implementação da ferramenta Heijunka para aumentar a produtividade e a capacidade de entrega*. *Revista ENIAC Pesquisa, 14*(2), 414–442. https://doi.org/10.22567/rep.v14i2.1172

[7] Gohitha Maheshwari J, Vivekan S. Gogi, Inchara N. Aradhya y Shankaramma (2024). Digitalization of Lean Tools and Techniques: Enhancing Efficiency and Quality in Modern Industries. Recuperado de: https://doi.org/10.1109/CSITSS64042.2024.10817042

[8] Guilherme Luz T, Tarcísio Abreu Saurin, Moacir Godinho Filho, Daniel, Maneesh Kumar (2021). Conjuntos de prácticas y principios de automatización Lean y su impacto en el rendimiento operativo/Recuperado de:https://doi.org/10.1016/j.ijpe.2021.108106

[9] Steven Young, Pablo Martinez, y Rafiq Ahmad (2022). Cómo adaptar las prácticas lean en las PYMES para apoyar la Industria 4.0 en la fabricación/Adekunle Mofolasayo. Recuperado de: https://doi.bibliotecaupn.elogim.com/10.1016/j.procs.2022.01.291

[10] Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & The PRISMA Group. (2009). Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *PLoS Medicine, 6*(7), e1000097. https://doi.org/10.1371/journal.pmed.1000097

[11] Hirendra Singh y Bhim Singh (2024), Industry 4.0 technologies integration with lean production tools: a review. Recuperado de: https://doi.org/10.1108/TQM-02-2022-0065

[12] Audrey Cerqueus, Alexandre Dolgui, Dmitry Ivanov, Alexandr Klimtchik, David Lemoine, Anatol Pashkevich / (2025). Applications of artificial intelligence in industry 4.0 and smart manufacturing". Recuperado de:https://doi.bibliotecaupn.elogim.com/10.1016/j.engappai.2025.110509

[13] Joaquín Bautista-Valhondo Rocío Alfaro-Pozo, Amaia Lusa (2026). Secuenciación Heijunka en líneas de ensamblaje con opciones de producto, sobrecarga de trabajo y duración variable de la jornada laboral. Recuperado de:https://doi.org/10.1007/978-3-032-10126-6_39

[14] Mohammad Shahin, Mazdak Maghanaki, Ali Hosseinzadeh y F. Frank Chen. (2024). Mejora de las operaciones mediante un paradigma de IA ajustada: una visión de la fabricación ajustada asistida por IA a través de una red neuronal convolucional versátil. Recuperado de:https://doi.org/10.1007/s00170-024-13874-4

[15] Korytkowski, P.; Wisniewski, T.; Rymaszewski, S. (2013). Multivariate simulation analysis of production leveling (heijunka) – a case study. Recuperado de:https://doi.org/10.3182/20130619-3-RU-3018.00285

[16] Plantec, Q.; Deval, M.A.; Hooge, S.; Weil (2025). IML and Deep Learning in automotive manufacturing: Systematic literature review (ToyotaFrance). Recuperado de:https://doi.org/10.1016/j.compind.2025.104263

[17] Chan, F.T.S.; Lau, H.C.W.; Ip, R.W.L.; Chan, H.K.; Kong, S. (2022). Industry 4.0 in manufacturing: lean to product design (CPS Heijunka + DVSM) .Recuperado de:https://doi.org/10.1007/s00170-022-09511-7

[18] Boutbagha, Meryem; El Abbadi, Laila (2024). Heijunka-Levelling customer orders: a systematic literature review. Recuperado de:https://doi.org/10.4995/ijpme.2024.19279

[19] Büşra; Aydoğan Baş, S.; Kocakalay, Ş. (2024). Enfoque de programación multiobjetivo para el problema de nivelación de producción: un ejemplo de subindustria automotriz Tutumlu. Recuperado de:https://doi.org/10.17341/gazimmfd.1341993

[20] Shetty, Doraiswamy K. (2019). To develop Lean Systems in Electronic Automotive Parts Manufacturing: A dynamic systems modeling approach. Recuperado de:https://doi.org/10.1109/ICTM.2019.8776803

[21] Ahmed M. Abed, Ali AlArjani, Laila F. Seddek, Samia Elattar (2024). Reduce the delivery time and relevant costs in a chaotic requests system via lean-Heijunka model to enhance the logistic Hamiltonian route. Recuperado de:https://doi.org/10.1016/j.rineng.2023.101745

[22] Håkon Strømfjord Kjellsen, Quentin Jean-Louis Ramillon, Heidi Carin Dreyer, Daryl John Powell / (2021). Heijunka 4.0 – Key Enabling Technologies for Production Levelling in the Process Industry. Recuperado de: https://doi.org/10.1007/978-3-030-85874-2_77

[23] Gohitha Maheshwari J, Vivekanand S Gogi, Inchara N Aradhya, Shankaramma (2024). Digitalization of Lean Tools and Techniques: Enhancing Efficiency and Quality in Modern Industries. Recuperado de:https://doi.org/10.1109/CSITSS64042.2024.10817042

[24] Matteo Gabellini, Alberto Regattieri, Marco Bortolini, Francesco G. Galizia (2025). Investigating the Potential of Machine Learning and Deep Learning Models in Probabilistic Supply Risk Forecasting: A

Case Study in the Automotive Sector. Recuperado de: https://doi.org/10.1016/j.ifacol.2025.09.497

[25] Michail Katsigiannis, Minas Pantelidakis, Konstantinos Mykoniatis / (2024). Assessing the transition from mass production to lean manufacturing using a hybrid simulation model of a LEGO® automotive assembly line. Recuperado de: https://doi.org/10.1108/IJLSS-07-2022-0165

[26] Tomidei, L., Sick, N., Mathieson, L. (2024). Data-Driven Value Stream Analysis using Process Mining and Machine Learning.

[27] Solke, N.S., Shah, P., Sekhar, R., Singh, T.P. (2022). Machine Learning-Based Predictive Modeling and Control of Lean Manufacturing in Automotive Parts Manufacturing Industry. Recuperado de: https://doi.org/10.1007/s40171-021-00291-9

[28] Calabrese G.G., Falavigna G. (2022). Does Industry 4.0 improve productivity? Evidence from the Italian automotive supply chain. Recuperado de:https://doi.org/10.1504/ijatm.2022.126843

[29] Joaquín Bautista-Valhondo (2021). Exact and heuristic procedures for the Heijunka-flow shop scheduling problem with minimum makespan and job replicas. Recuperado de:https://doi.org/10.1007/s13748-021-00249-z

[30] Decio Tomio Sakuma, Carlos Marcelo Gurjão de Godoy, Regina Celia Coelho (2025). A Deep Learning-Based Computer Vision System for Automated Screw Detection in Vehicle Wheel Boxes: Enhancing Automotive Quality Control with Industry 4.0. Recuperado de:https://doi.org/10.1007/978-3-031-96997-3_1