
Simulación y Optimización del Balanceo de una Línea de Producción de Envases Plásticos mediante Python y Metodologías Lean Six Sigma, 2025

Simulation and Optimization of Line Balancing in a Plastic Container Production Line Using Python and Lean Six Sigma Methodologies, 2025

Jorge Luis Delgado Batista
Universidad de Panamá, Facultad de ingeniería. Panamá
jorge.delgado-b@up.ac.pa
<https://orcid.org/0009-0006-2866-5380>

Jorge Luis Martínez Ramírez
Universidad de Panamá, Facultad de Ingeniería, Panamá
jorgel.martinez@up.ac.pa
<https://orcid.org/0000-0002-1036-6167>

Recibido: 9/2/2026 Aceptado: 10/5/2026

DOI <https://doi.org/10.48204/reicit.v6n1.10118>

RESUMEN

La industria de envases plásticos enfrenta crecientes exigencias en términos de productividad, estabilidad del proceso y control de calidad, lo que exige la implementación de metodologías de mejora continua apoyadas en herramientas de análisis cuantitativo y simulación digital. El objetivo de esta investigación es analizar el desempeño integral de una línea de producción de envases plásticos con capacidad de 1,200 unidades por turno de 8 horas, mediante la simulación de su comportamiento operativo y la evaluación de indicadores clave de desempeño (KPIs), con el fin de identificar brechas frente a parámetros de referencia industriales y determinar oportunidades de mejora en productividad, estabilidad y eficiencia del sistema productivo. La metodología empleada integra herramientas de simulación desarrolladas en Python mediante el entorno Google Colab, combinadas con técnicas de análisis propias de Lean Manufacturing y Six Sigma. El modelo permitió analizar variables

operativas como Takt Time, Cycle Time, eficiencia de balanceo de línea, throughput, scrap, First Pass Yield (FPY), índice de capacidad del proceso (Cpk), disponibilidad física, así como indicadores de confiabilidad de mantenimiento y eficiencia laboral. Se desarrollaron escenarios comparativos para evaluar el comportamiento del sistema frente a objetivos industriales establecidos. Los resultados evidencian la presencia de desbalances entre estaciones de trabajo, restricciones asociadas a cuellos de botella y variabilidad en los tiempos de ciclo que afectan la eficiencia global de la línea. El análisis de indicadores muestra desviaciones respecto a los valores de referencia en métricas como OEE, eficiencia de balanceo y estabilidad estadística del proceso, lo que confirma la existencia de oportunidades significativas de optimización mediante redistribución de cargas operativas, reducción de actividades no generadoras de valor y mejoras en la confiabilidad del equipo. Se concluye que la simulación digital combinada con enfoques Lean Six Sigma constituye una herramienta eficaz para diagnosticar el desempeño de sistemas productivos, apoyar la toma de decisiones basada en datos y fortalecer la competitividad de la industria de manufactura de envases plásticos en entornos de alta demanda y variabilidad operativa.

PALABRAS CLAVE: Lean Manufacturing, Six Sigma, simulación industrial, balanceo de líneas, indicadores de desempeño.

ABSTRACT

The plastic packaging industry faces increasing demands in terms of productivity, process stability, and quality control, which require the implementation of continuous improvement methodologies supported by quantitative analysis and digital simulation tools. The objective of this research is to analyze the overall performance of a plastic container production line with a capacity of 1,200 units per 8-hour shift by simulating its operational behavior and evaluating key performance indicators (KPIs), in order to identify performance gaps relative to industry benchmark values and determine improvement opportunities to enhance productivity, process stability, and system efficiency. The methodology integrates simulation tools developed in Python using the Google Colab environment, combined with analytical approaches derived from Lean Manufacturing and Six Sigma methodologies. The simulation model allowed the evaluation of operational variables such as Takt Time, Cycle Time, line balancing efficiency, throughput, scrap rate, First Pass Yield (FPY), Process Capability Index (Cpk), physical availability, as well as maintenance reliability and labor efficiency indicators. Comparative scenarios were developed to analyze system performance against established industrial targets. The results reveal imbalances among workstations, bottleneck constraints, and variability in cycle times that negatively affect the overall efficiency of the production line. KPI analysis indicates deviations from benchmark values in metrics such as Overall Equipment Effectiveness (OEE), line balancing efficiency, and statistical process stability, confirming the presence of significant opportunities for operational optimization through workload redistribution, reduction of non-value-added activities, and improvements in

equipment reliability. The study concludes that digital simulation combined with Lean Six Sigma approaches constitutes an effective tool for diagnosing the performance of production systems, supporting data-driven decision-making, and strengthening the competitiveness of the plastic packaging manufacturing industry in environments characterized by high demand and operational variability.

KEYWORDS: Lean Manufacturing, Six Sigma, industrial simulation, line balancing, performance indicators.

INTRODUCCIÓN

La industria de envases plásticos desempeña un papel estratégico en las cadenas globales de suministro al proveer soluciones de empaque para sectores como alimentos, farmacéutica, cosmética y bienes de consumo masivo. Estos sectores demandan envases que cumplan estrictos estándares de calidad, estabilidad dimensional, seguridad e inocuidad, lo que obliga a las plantas manufactureras a mejorar continuamente su eficiencia productiva y el control de sus procesos (Plastics Europe, 2023). En este contexto, las organizaciones enfrentan el desafío de incrementar la productividad, reducir la variabilidad operativa y optimizar el uso de recursos, adoptando metodologías de mejora continua y herramientas de análisis basadas en datos (Womack & Jones, 2003 p.8).

Dentro de los sistemas de manufactura, el balanceo de líneas de producción es un elemento clave para sincronizar las estaciones de trabajo y garantizar un flujo operativo estable. Indicadores como Takt Time, Cycle Time y Line Balancing Efficiency permiten evaluar la relación entre la demanda del mercado y la capacidad productiva del sistema, mientras que la identificación de cuellos de botella facilita el análisis de restricciones que afectan el throughput de la línea (Hopp & Spearman, 2013). Asimismo, la Efectividad Global del Equipo (OEE) se ha consolidado como un indicador integral para medir el desempeño de los sistemas productivos a partir de la disponibilidad, el rendimiento y la calidad del proceso. Complementariamente, indicadores como First Pass Yield (FPY), Cpk, MTBF y MTTR permiten evaluar la estabilidad del proceso, la confiabilidad de los equipos y la capacidad del sistema para cumplir con los requisitos de calidad (Montgomery, 2020, p.14).

A pesar de la disponibilidad de estos indicadores, muchas plantas manufactureras presentan desbalances entre estaciones, variabilidad en los tiempos de ciclo y restricciones de capacidad que afectan la eficiencia operativa y el cumplimiento de la demanda. En estos casos, la toma de decisiones basada únicamente en observaciones empíricas limita la capacidad de identificar de forma precisa las causas de las ineficiencias del sistema productivo.

En este contexto, la simulación computacional se ha consolidado como una herramienta eficaz para analizar sistemas productivos complejos, permitiendo modelar el comportamiento

de los procesos, evaluar diferentes escenarios operativos y estimar el impacto de acciones de mejora sin afectar la operación real de la planta. El uso de Python en el entorno Google Colab facilita el desarrollo de modelos de simulación reproducibles y escalables, alineados con los principios de la Industria 4.0 y la digitalización de la manufactura (Davenport & Harris, 2017, p.6).

El objetivo de esta investigación es analizar el desempeño de una línea de producción de envases plásticos mediante simulación computacional y evaluación de indicadores Lean Six Sigma, con el propósito de identificar desbalances operativos, restricciones del sistema y oportunidades de mejora que permitan optimizar la eficiencia productiva y la estabilidad del proceso. Se plantea como hipótesis que la aplicación de simulación computacional integrada con metodologías Lean Six Sigma permite identificar restricciones operativas y mejorar el desempeño de la línea de producción, optimizando indicadores clave como la eficiencia de balanceo, el throughput y la efectividad global del equipo.

MÉTODO Y MATERIALES

Enfoque metodológico

La presente investigación se desarrolló bajo un enfoque cuantitativo de tipo aplicado, orientado al análisis del desempeño operativo de una línea de producción de envases plásticos mediante la simulación computacional de su comportamiento productivo. Este tipo de estudios permite evaluar variables operativas y analizar el desempeño de sistemas productivos a partir de modelos analíticos y simulaciones que representan el funcionamiento real del proceso (Banks, Carson, Nelson & Nicol, 2010, p.4).

El estudio se fundamentó en la integración de herramientas de simulación computacional, análisis estadístico y metodologías de mejora continua, específicamente Lean Manufacturing y Six Sigma, con el propósito de evaluar indicadores clave de desempeño (KPIs) asociados a la eficiencia operativa, calidad del proceso y confiabilidad del sistema productivo (Womack & Jones, 2003; Montgomery, 2020, p.3).

El método de investigación consistió en el desarrollo de un modelo de simulación computacional que reproduce el comportamiento de la línea de producción a partir de variables operativas como tiempos de ciclo, distribución de carga entre estaciones, niveles de scrap, disponibilidad del equipo y volumen de producción. Este tipo de modelos permite analizar el desempeño de sistemas productivos complejos y evaluar escenarios operativos sin intervenir directamente en el sistema real (Law, 2015, p.8).

Descripción del sistema productivo analizado

El sistema objeto de estudio corresponde a una línea de producción de envases plásticos con capacidad nominal de 1,200 unidades por turno de 8 horas, equivalente a una demanda

promedio de 150 unidades por hora. La línea está compuesta por diversas estaciones de trabajo interdependientes que participan en el proceso de transformación del material plástico hasta la obtención del envase terminado.

Para el análisis del sistema productivo se consideraron variables operativas relacionadas con el flujo de producción y el desempeño de los equipos, entre ellas:

- tiempos de ciclo por estación
- tiempo takt del sistema
- distribución de carga de trabajo
- inventario en proceso (WIP)
- tasas de scrap
- disponibilidad del equipo
- confiabilidad del sistema productivo

Estas variables son ampliamente utilizadas en el análisis de sistemas de manufactura para evaluar el comportamiento del flujo productivo y la eficiencia operativa de las líneas de producción (Hopp & Spearman, 2013, p.9).

Técnicas de análisis y simulación

Para el análisis del sistema productivo se aplicaron técnicas de simulación computacional y evaluación de indicadores Lean Six Sigma. El modelo de simulación fue desarrollado utilizando el lenguaje de programación Python, implementado en el entorno de computación en la nube Google Colab, lo que permitió realizar procesamiento de datos, cálculos de indicadores y visualización de resultados mediante herramientas de análisis estadístico.

El modelo permitió evaluar indicadores clave de desempeño utilizados en la gestión de operaciones y en la mejora continua de procesos productivos, entre ellos:

- Overall Equipment Effectiveness (OEE), indicador que integra disponibilidad, rendimiento y calidad del proceso (Nakajima, 1988).
- Line Balancing Efficiency, utilizado para medir el grado de equilibrio entre estaciones de trabajo en una línea de producción (Groover, 2015).
- Cycle Time y Takt Time, empleados para analizar la relación entre la capacidad del sistema y la demanda del mercado (Hopp & Spearman, 2013).

- Throughput, indicador del volumen de producción obtenido por unidad de tiempo (Goldratt & Cox, 2004).
- First Pass Yield (FPY) y Process Capability Index (Cpk), indicadores asociados a la calidad y estabilidad estadística del proceso (Montgomery, 2020).
- Mean Time Between Failures (MTBF) y Mean Time To Repair (MTTR), utilizados para evaluar la confiabilidad y mantenibilidad del equipo (Mobley, 2002).

Adicionalmente, se analizaron indicadores relacionados con la eficiencia del flujo productivo, tales como Work in Process (WIP), actividades de valor agregado (VA) y actividades que no agregan valor (NVA), conceptos ampliamente utilizados en la filosofía Lean para identificar desperdicios y mejorar el flujo de los procesos (Womack & Jones, 2003).

Instrumentos y herramientas utilizadas

El desarrollo del estudio se apoyó en los siguientes instrumentos y herramientas:

- **Python:** lenguaje de programación utilizado para el desarrollo del modelo de simulación y el análisis de datos. Python se ha consolidado como una herramienta ampliamente utilizada en análisis de datos, simulación y ciencia de datos aplicada a sistemas industriales (McKinney, 2022).
- **Google Colab:** plataforma de computación en la nube que permite ejecutar código Python sin requerir infraestructura local, facilitando la reproducibilidad de los modelos analíticos y la colaboración en entornos de investigación (Bisong, 2019).
- **Bibliotecas de análisis de datos en Python:** utilizadas para manipulación de datos, cálculos estadísticos y visualización de resultados.
- **Indicadores Lean Six Sigma:** utilizados como marco analítico para evaluar el desempeño del sistema productivo y orientar la identificación de oportunidades de mejora (George, 2003, p.2).

RESULTADOS

Los resultados obtenidos coinciden con estudios recientes que muestran que el balanceo de líneas puede incrementar la eficiencia operativa entre 5 % y 15 % en sistemas de manufactura discreta (Buer, 2018). En comparación con el escenario Actual, el escenario Balanceado incrementa el Overall Equipment Effectiveness (OEE) desde un rango de 91–98 % hasta 97–

99 %, mientras que la eficiencia de balanceo de línea aumenta de 85–90 % a 94–97 %, superando el estándar industrial de referencia del 92 %.


Asimismo, el Cycle Time se estabiliza entre 22.9 s y 24.3 s, manteniéndose cercano al Takt Time (≈ 24 s) y reduciendo la variabilidad observada en el escenario actual (23.0 s – 25.5 s). Esta mejora se refleja en el throughput, que pasa de 141–157 unidades por hora a 148–162 unidades por hora, alcanzando o superando el objetivo productivo de 150 unidades por hora en la mayoría de los turnos.

Desde el punto de vista de calidad, el scrap se reduce de 2.3–3.8 % a 1.7–2.9 %, mientras que el First Pass Yield (FPY) aumenta de 94.8–96.8 % a 96.5–98.2 %. De igual forma, el índice de capacidad del proceso (Cpk) presenta una mayor concentración en valores ≥ 1.33 , indicando una menor variabilidad del proceso.

En términos de confiabilidad, el MTBF aumenta de 1.8–7.3 horas a 3.5–7.6 horas, mientras que el MTTR disminuye de un promedio de 0.26 horas a 0.17 horas, lo que representa una reducción aproximada del 35 % en el tiempo de recuperación ante fallas. Estos resultados demuestran que el balanceo de línea mejora la estabilidad del flujo productivo incrementa la capacidad efectiva de la línea y reduce pérdidas asociadas a variabilidad operativa, fallas de equipo y desperdicio de material.

Figura 1

OEE (Overall Equipment Effectiveness)




Nota: El análisis del comportamiento del Overall Equipment Effectiveness (OEE) durante los diez turnos evaluados muestra diferencias significativas entre ambos escenarios.

En el escenario Actual, el OEE oscila entre 91 % y 98 %, evidenciando variabilidad en los componentes de disponibilidad, rendimiento y calidad. En contraste, el escenario Balanceado presenta un desempeño más estable con valores entre 97 % y 99 %, superando consistentemente el umbral de referencia industrial del 82.5 %. Esta mejora indica que el balanceo de línea contribuye a reducir pérdidas operativas y estabilizar los tiempos de ciclo, fortaleciendo la productividad global del sistema productivo. Estos resultados son consistentes con la literatura sobre evaluación del desempeño productivo mediante OEE, indicador que integra disponibilidad, rendimiento y calidad del proceso (Zhou, 2025).

Figura 2.

Eficiencia de Balanceo de Línea (LBL – Line Balancing Loss)




Nota: La comparación de la Eficiencia de Balanceo de Línea muestra una mejora significativa tras la redistribución de tareas entre estaciones.

En el escenario Actual, los valores se sitúan entre 85 % y 90 %, por debajo del estándar de referencia del 92 %, lo que evidencia desbalance entre estaciones y presencia de microcuellos de botella que generan acumulación de Work in Process (WIP) y tiempos ociosos. En el escenario Balanceado, la eficiencia aumenta a valores entre 94 % y 97 %, superando el estándar operativo y reduciendo la brecha en más de 7 puntos porcentuales. Esta mejora favorece la sincronización del flujo productivo y el aprovechamiento de la capacidad instalada, aspectos fundamentales en el diseño de sistemas de manufactura eficientes (Groover, 2015, p.6).

Gráfica 3

Takt Time vs. Cycle Time




Nota: El análisis comparativo entre Takt Time (≈ 24 s) y Cycle Time evidencia diferencias operativas relevantes entre los escenarios evaluados.

En el escenario Actual, el Cycle Time fluctúa entre 23.0 s y 25.5 s, superando el Takt en varios turnos y generando riesgo de incumplimiento de demanda y acumulación de inventario en proceso. En el escenario Balanceado, el Cycle Time se estabiliza entre 22.9 s y 24.3 s, manteniéndose cercano al Takt Time, lo que indica una mayor sincronización entre la capacidad del sistema y el ritmo de demanda del cliente. Esta relación constituye un elemento fundamental en la gestión del flujo productivo en sistemas Lean (Hopp & Spearman, 2013).

Gráfica 4

Throughput o Velocidad de Producción




Nota: El análisis del Throughput evidencia una mejora en la capacidad productiva de la línea tras la optimización del balanceo.

En el escenario Actual, la producción oscila entre 141 y 157 unidades por hora, con varios turnos por debajo del objetivo de 150 unidades por hora. En el escenario Balanceado, el throughput aumenta a valores entre 148 y 162 unidades por hora, superando el estándar en la mayoría de los turnos y reduciendo la variabilidad operativa. Este incremento confirma una mejor sincronización del flujo productivo y un mayor aprovechamiento de la capacidad disponible, factores clave para mejorar el desempeño de sistemas industriales (Goldratt & Cox, 2004).

Gráfica 5

Cuello de Botella (Bottleneck Rate)




Nota: El análisis de la Tasa del Cuello de Botella muestra que en el escenario Actual la estación restrictiva opera entre 129 y 144 unidades por hora, situándose por debajo del requerimiento del sistema (≈ 150 unidades por hora).

Esta limitación condiciona la capacidad total del sistema y genera acumulación de inventario en proceso. En el escenario Balanceado, la tasa del cuello de botella mejora hasta un rango entre 139 y 147 unidades por hora, acercándose al estándar requerido. Esta mejora refleja una redistribución más eficiente de tareas y una mayor estabilidad en el flujo operativo del sistema productivo (Hopp & Spearman, 2013, p.12).

Gráfica 6.

Scrap Rate (Tasa de Desperdicio)




Nota: El análisis del Scrap Rate evidencia una reducción en los niveles de desperdicio tras la optimización del sistema.

En el escenario Actual, el scrap oscila entre 2.3 % y 3.8 %, situándose en la parte alta del rango objetivo de 2–4 %. En el escenario Balanceado, el scrap disminuye a valores entre 1.7 % y 2.9 %, lo que representa una reducción cercana a 1 punto porcentual en varios turnos. Esta disminución refleja una mejora en la estabilidad del proceso y en la consistencia de los parámetros operativos, reduciendo pérdidas económicas asociadas a desperdicio y reproceso (Montgomery, 2020, p.22).

Gráfica 7.

Yield o Rendimiento de Primera Pasada (FPY)




Nota: El análisis del First Pass Yield (FPY) muestra mejoras en la calidad del proceso tras la intervención de balanceo. En el escenario Actual, el FPY se sitúa entre 94.8 % y 96.8 %, ligeramente por encima del umbral mínimo recomendado (≥ 95 %).

En el escenario Balanceado, el FPY se incrementa hasta valores entre 96.5 % y 98.2 %, lo que representa una mejora aproximada de 1.2 a 1.5 puntos porcentuales. Este resultado confirma que la reducción del scrap y la estabilización del flujo productivo contribuyen a mejorar la calidad en primera pasada del proceso.

Gráfica 8

Cpk del proceso




Nota: El análisis del Índice de Capacidad del Proceso (Cpk) muestra una mejora en la estabilidad del proceso tras la optimización operativa.

En el escenario Actual, el Cpk fluctúa entre 1.00 y 1.60, presentando turnos por debajo del valor mínimo aceptable de 1.33. En el escenario Balanceado, los valores se sitúan entre 1.20 y 1.70, con una mayor concentración en niveles ≥ 1.33 , lo que evidencia una reducción de la variabilidad del proceso y una mayor capacidad para cumplir con las especificaciones de calidad (Montgomery, 2020, p.4).

Gráfica 9.

MTBF (Mean Time Between Failures)




Nota: El análisis del MTBF revela mejoras en la confiabilidad operativa del sistema. En el escenario Actual, el indicador presenta valores entre 1.8 y 7.3 horas, con un promedio cercano a 3 horas, lo que refleja recurrencia de fallas no programadas.

En el escenario Balanceado, el MTBF aumenta a un rango entre 3.5 y 7.6 horas, superando el objetivo en varios turnos y reduciendo la frecuencia de interrupciones. Este comportamiento indica una mejora en la estabilidad del equipo y en la continuidad operativa del sistema productivo (Mobley, 2002, p.6).

Gráfica 10.

MTTR (Mean Time To Repair)



Nota: El análisis del MTTR muestra una reducción significativa en los tiempos de recuperación ante fallas.

En el escenario Actual, los valores oscilan entre 0.15 y 0.32 horas (9–19 minutos), con un promedio cercano a 0.26 horas. En el escenario Balanceado, el MTTR disminuye a un rango entre 0.00 y 0.23 horas (0–14 minutos), con un promedio aproximado de 0.17 horas, lo que representa una reducción cercana al 35 % en el tiempo requerido para restablecer el funcionamiento del equipo. Esta mejora sugiere una mayor eficiencia en los protocolos de mantenimiento y en la respuesta ante fallas, contribuyendo a mejorar la disponibilidad operativa del sistema.

CONCLUSIONES

- La simulación confirma un incremento potencial del OEE entre +12 % y +18 %, impulsado por mejoras en disponibilidad, rendimiento y calidad, permitiendo atender mayor demanda sin inversiones inmediatas en expansión de capacidad.

- La reducción estimada del scrap entre -25% y -30% , acompañada de un aumento del FPY superior al $+5\%$, proyecta una disminución directa de costos por retrabajo y desperdicio, con ahorros cercanos al 7% del costo operativo total anualizado.
- La aplicación de prácticas SMED permite una reducción del lead time entre -22% y -28% , lo cual generaría una mejora significativa en rotación de inventario y respuesta al cliente, además de disminuir el WIP en -20% como efecto del balanceo y la eliminación de tiempos No-Value Added.
- Las mejoras en confiabilidad operacional muestran un potencial de $+25\%$ en MTBF y una disminución de -15% en MTTR, lo que justifica implementar un programa TPM enfocado en mantenimiento predictivo y autónomo.
- La redistribución de cargas y balanceo de estaciones complementan una estrategia de transformación digital basada en datos, donde Python y Google Colab habilitan modelos predictivos, análisis comparativos y reportes automatizados sin inversión en licencias.
- No intervenir implicaría mantener ineficiencias estructurales, incremento del costo por unidad, mayores tiempos de ciclo, exposición a incumplimiento regulatorio y pérdida de competitividad frente a fabricantes que ya operan bajo enfoque Lean e Industria 4.0.

REFERENCIAS BIBLIOGRÁFICAS

- Banks, J., Carson, J., Nelson, B., & Nicol, D. (2019). Discrete-event system simulation (6th ed.). Pearson.
- Bisong, E. (2019). Building machine learning and deep learning models on Google Cloud Platform. Apress.
- Bhamu, J., & Sangwan, K. (2014). Lean manufacturing: Literature review and research issues. *International Journal of Operations & Production Management*, 34(7), 876–940.

- Chiarini, A. (2013). *Lean organization: From the tools of the Toyota Production System to Lean Office*. Springer.
- Davenport, T. H., & Harris, J. (2017). *Competing on analytics: The new science of winning*. Harvard Business Review Press.
- Deming, W. E. (2000). *Out of the crisis*. MIT Press.
- Dennis, P. (2016). *Lean production simplified* (3rd ed.). CRC Press.
- George, M. L. (2003). *Lean Six Sigma for service*. McGraw-Hill.
- George, M. L., Rowlands, D., Price, M., & Maxey, J. (2005). *The Lean Six Sigma pocket toolbox*. McGraw-Hill.
- Goldratt, E. M., & Cox, J. (2004). *The goal: A process of ongoing improvement* (3rd ed.). North River Press.
- Groover, M. P. (2015). *Automation, production systems and computer-integrated manufacturing* (4th ed.). Pearson.
- Heizer, J., Render, B., & Munson, C. (2020). *Operations management* (13th ed.). Pearson.
- Hopp, W. J., & Spearman, M. L. (2013). *Factory physics* (3rd ed.). Waveland Press.
- Ivanov, D., Dolgui, A., & Sokolov, B. (2021). Digital supply chain twins. *International Journal of Production Research*.
- Krajewski, L., Malhotra, M., & Ritzman, L. (2019). *Operations management: Processes and supply chains* (12th ed.). Pearson.
- Law, A. M. (2015). *Simulation modeling and analysis* (5th ed.). McGraw-Hill.
- Liker, J. K. (2004). *The Toyota way*. McGraw-Hill.
- McKinney, W. (2022). *Python for data analysis* (3rd ed.). O'Reilly Media.
- Mobley, R. K. (2002). *An introduction to predictive maintenance* (2nd ed.). Butterworth-Heinemann.
- Montgomery, D. C. (2020). *Introduction to statistical quality control* (8th ed.). Wiley.
- Pyzdek, T., & Keller, P. (2018). *The Six Sigma handbook* (5th ed.). McGraw-Hill.
- Rother, M., & Shook, J. (2003). *Learning to see: Value stream mapping*. Lean Enterprise Institute.
- Sokovic, M., Pavletic, D., & Pipan, K. (2010). Quality improvement methodologies – PDCA cycle, RADAR matrix, DMAIC and DFSS. *Journal of Achievements in Materials and Manufacturing Engineering*, 43(1), 476–483.
- Stevenson, W. J. (2021). *Operations management* (14th ed.). McGraw-Hill.
- Sunder, M. V. (2016). Lean Six Sigma in higher education institutions. *International Journal of Quality & Reliability Management*, 33(8), 1123–1134.
- Womack, J. P., & Jones, D. T. (2003). *Lean thinking*. Free Press.

- Zhou, D., et al. (2025). Multi-dimensional fusion prediction and sensitivity analysis of overall equipment effectiveness in manufacturing systems. *International Journal of Production Research*.
- Shah, R., & Ward, P. (2007). Defining and developing measures of Lean production. *Journal of Operations Management*, 25(4), 785–805.
- Buer, S. V., Strandhagen, J. O., & Chan, F. T. S. (2018). The link between Industry 4.0 and Lean manufacturing. *International Journal of Production Research*, 56(8), 2924–2940.