



Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), Noviembre-Diciembre 2025,
Volumen 9, Número 6.

https://doi.org/10.37811/cl_rcm.v9i6

EFFECTOS DE LOS RETRASOS EN TIEMPOS DE ENTREGA CON EL USO DE APRENDIZAJE AUTOMÁTICO Y ANÁLISIS DE DECISIONES MULTICRITERIO

**EFFECTS OF DELIVERY TIME DELAYS WITH THE USE OF
MACHINE LEARNING AND MULTICRITERIA DECISION ANALYSIS**

Ulises Mercado Valenzuela

Universidad Nacional Autónoma de México

Francisco Quiroz Aguilar

Tecnológico de Estudios Superiores de Coacalco, México

Oliverio Cruz Mejía

Universidad Nacional Autónoma de México

Efectos de los Retrasos en Tiempos de entrega con el Uso de Aprendizaje Automático y Análisis de Decisiones Multicriterio

Ulises Mercado Valenzuela¹

ulisesmv@comunidad.unam.mx

<https://orcid.org/0009-0004-4737-0479>

Universidad Nacional Autónoma de México
México

Francisco Quiroz Aguilar

francisco_quiroz@tesco.edu.mx

<https://orcid.org/0000-0001-8801-6872>

Tecnológico de Estudios Superiores de Coacalco
México

Oliverio Cruz Mejía

oliverio.cruz.mejia@comunidad.unam

<https://orcid.org/0000-0001-7362-6408>

Universidad Nacional Autónoma de México
México

RESUMEN

Los retrasos en los tiempos de entrega generan riesgos significativos en la producción, sobre todo en sistemas justo a tiempo (JIT), donde las interrupciones disparan los costos, alargan los plazos y disminuyen la satisfacción del cliente. Las mitigaciones tradicionales son reactivas y a menudo no logran optimizar las compensaciones entre coste, resistencia y servicio. En este trabajo se plantea un marco integrado de aprendizaje automático (AA) para el modelado predictivo y análisis de decisiones multicriterio (ADMC) para la selección de estrategias prescriptivas. Con datos históricos de un proveedor de autopiezas, los modelos de AA predijeron con exactitud la probabilidad y duración de los retrasos (Random Forest: 87 % de exactitud; Gradient Boosting: $R^2 = 0.78$). La fiabilidad de los proveedores y la volatilidad logística fueron los principales factores predictivos. Las estrategias —abastecimiento dual, contratos con proveedores, envíos urgentes— se jerarquizaron con AHP-TOPSIS, siendo el abastecimiento dual la mejor solución a largo plazo. Los resultados muestran la importancia de combinar AA y ADCM para establecer soluciones proactivas, data-driven y estratégicamente alineadas a los retrasos en los tiempos de entrega en la manufactura.

Palabras clave: aprendizaje automático (AA), análisis de decisiones multicriterio (ADMC), demora de tiempos de espera, sistemas de manufactura,

¹ Autor principal

Correspondencia: ulisesmv@comunidad.unam.mx

Effects of Delivery Time Delays with the use of Machine Learning and Multicriteria Decision Analysis

ABSTRACT

Lead-time delays generate significant risks in production, especially in just-in-time (JIT) systems, where disruptions drive up costs, lengthen lead times, and decrease customer satisfaction. Traditional mitigations are reactive and often fail to optimize trade-offs between cost, resilience, and service. This paper proposes an integrated machine learning (ML) framework for predictive modeling and multi-criteria decision analysis (MCDA) for selecting prescriptive strategies. Using historical data from an auto parts supplier, ML models accurately predicted the probability and duration of delays (Random Forest: 87% accuracy; Gradient Boosting: $R^2 = 0.78$). Supplier reliability and logistics volatility were the main predictors. Strategies—dual sourcing, supplier contracts, expedited shipments—were ranked using AHP-TOPSIS, with dual sourcing being the best long-term solution. The results demonstrate the importance of combining ML and MDCA to establish proactive, data-driven, and strategically aligned solutions to manufacturing lead-time delays.

Keywords: lead time delays, manufacturing systems, machine learning (ML), multi-criteria decision analysis (MCDA)

*Artículo recibido 15 noviembre 2025
Aceptado para publicación: 15 diciembre 2025*



INTRODUCCIÓN

El cumplimiento de los plazos de entrega es desde hace tiempo un elemento de competitividad de la industria manufacturera. En el mundo empresarial actual, cada vez más globalizado e incierto, los retrasos en los tiempos de entrega pueden causar serios problemas, como el aumento de los costos operativos, interrupciones en los plazos de producción, insatisfacción del cliente y debilitamiento de la resiliencia de la cadena de suministro (Treville et al., 2014). En industrias con flujos justo a tiempo (JAT), como la automotriz, electrónica o farmacéutica, la variabilidad en los tiempos de entrega es un riesgo estratégico que debe ser controlado (Singh et al, 2013).

Las maneras tradicionales de controlar los retrasos en los tiempos de entrega (políticas de stock de seguridad, envíos urgentes, etc.) son reactivas y frecuentemente se sostienen en hipótesis estáticas (Thürer et al, 2023). Si bien estas acciones pueden disminuir las interrupciones, pueden no capturar la complejidad e interdependencia de las cadenas de suministro actuales (Nielsen et al, 2017). Además, quienes deciden se enfrentan a un equilibrio entre rentabilidad, nivel de servicio, flexibilidad y sostenibilidad, convirtiendo así el problema de gestión de retrasos en entregas en un problema de decisiones o multicriterio (Mohammed & Mandal, 2023; Wyrembek & Baryannis, 2024).

Los últimos avances en AA permiten modelar de forma predictiva la fabricación (Chen et al, 2021). Haciendo acopio de datos históricos de producción, proveedores y logística, el AA puede anticipar la probabilidad y magnitud de retrasos en el tiempo de entrega y de esta manera preverlo (Niitya et al, 2023). No obstante las predicciones por sí solas no son suficientes; los gerentes necesitan marcos de referencia con la finalidad de contrastar y seleccionar las mejores estrategias de mitigación (Dutta et al, 2022).

En este artículo se propone un la integración de AA y ADMC con la finalidad de anticiparse y responder a retrasos en los tiempos de entrega en la fabricación. El módulo AA da alertas tempranas de posibles retrasos y el módulo ADMC evalúa entre distintas opciones estratégicas según criterios múltiples de decisión, garantizando que las respuestas elegidas se alineen con los objetivos de la organización. El marco llena la brecha entre el análisis predictivo y la toma de decisiones prescriptivas en la gestión de la manufactura.



Antecedentes

Los retrasos en los plazos de entrega dependen de la fiabilidad de los proveedores, los cuellos de botella en la producción, las averías de la maquinaria, la escasez de mano de obra, los problemas de transporte y la volatilidad de la demanda (De Treville et al, 2004; Chang & Lin, 2019). La literatura concerniente a la cadena de suministro denota que incluso pequeñas variaciones en los tiempos de entrega se amplifican a medida que avanzan por la cadena, creando el efecto látigo y desestabilizando el proceso de planeación de la producción (Burrows et al, 2023; Bandaly & Shanker, 2016). Las estrategias de mitigación tradicionales (reservas, diversificación de proveedores, reprogramación) carecen de rigor analítico y no optimizan las compensaciones entre prioridades en competencia (Um & Han, 2021).

El AA se está abriendo camino en la fabricación para todo, desde el mantenimiento predictivo hasta el control de calidad, la previsión de la demanda y la gestión de riesgos en la cadena de suministro (Qin et al, 2022; Meng et al, 2020). Algoritmos como Random Forest, SVM, Gradient Boosting y redes neuronales se han utilizado en datos reales a escala para descubrir relaciones no lineales y encontrar patrones de riesgo (Yan et al, 2024; Domladovac, 2021). Sobre los retrasos en los tiempos de entrega, el AA puede anticipar demoras basándose en factores como el tamaño del pedido, el historial del proveedor, las rutas de envío o el uso de la maquinaria (Schneckenreither et al, 2021). Las metodologías predictivas de AA superan los métodos estadísticos convencionales para modelar la incertidumbre y los datos de alta dimensión (Paraschos et al, 2024).

La decisión a nivel productivo generalmente involucra varios objetivos en conflicto, tales como minimizar costos, maximizar el nivel de servicio, disminuir el riesgo y aumentar la sostenibilidad (Castañé et al, 2023). De acuerdo con Feria et al (2024) el ADMC, implica metodologías con un alto grado de estructuración tales como “AHP, TOPSIS, PROMETHEE o VIKOR”, que permiten ordenar y evaluar las alternativas según las ponderaciones y criterios establecidos con anterioridad. Las aplicaciones del ADMC en la industria manufacturera abarcan la evaluación de proveedores, la planificación de la capacidad y la selección de tecnología (De Felice, 2012). Pero los marcos ADMC generalmente se basan en datos estáticos y no aprovechan las señales predictivas de datos en tiempo real (De Montis et al, 2000).



Mientras que el AA se usa para pronosticar y el ADMC para valorar, poco se ha hecho que los integre para la toma de decisiones en la manufactura (Yska & Guedes, 2022). Algunos trabajos recientes abordan marcos híbridos, pero por lo general se enfocan en áreas como la gestión energética o la toma de decisiones en salud (Yang et al, 2024; Liao et al, 2025). El AA combinado con el ADMC en la manufactura es un área emergente para abordar incertidumbres como los retrasos en el tiempo de entrega. Esta integración permite a los gerentes anticipar riesgos y probar estrategias en tiempo real, alineadas con las políticas organizacionales.

METODOLOGÍA

La metodología se diseñó con un enfoque transversal, cualitativo y cuantitativo de tal forma que sea posible medir y evaluar el impacto de los retrasos en los tiempos de entrega en procesos de fabricación específicos con la ayuda del AA con el auxilio del ADMC. El enfoque consta de tres etapas clave:

- a) Recopilación y preprocesamiento de datos,
- b) Modelado predictivo mediante aprendizaje automático.
- c) Evaluación de estrategias de mitigación mediante análisis de decisiones multicriterio (ADMC). La integración de estas etapas proporciona información a futuro y orientación para los responsables de la toma de decisiones.

Los datos para este análisis se pueden obtener de sistemas "Enterprise Resources Planning (ERP), registros de producción y desempeño de proveedores.

La captura de datos debe incluir:

- a) Variables independientes: tamaño del pedido, tasa de utilización de la maquinaria, índices de fiabilidad del proveedor, plazos de entrega de transporte, disponibilidad de mano de obra y volúmenes históricos de producción.
- b) Variables dependientes: El modelo de aprendizaje automático predice la probabilidad y duración de los retrasos en los plazos de entrega.

Para lo anterior se proponen dos modelos:

- a) Modelos de clasificación: para predecir si un pedido se va a demorar o no el cual se puede expresar mediante la ecuación 1.

$$P(y = 1 | \mathbf{x}) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}}$$

Donde:

$y = 1$ pedido demorado

$y = 0$ pedido a tiempo

$\mathbf{x} = (x_1, x_2, \dots, x_n)$: características de entrada

β_i = Parametros estimados del modelo tomados de los datos iniciales

b) El modelo se entrena con métricas estándar:

Categoría: El modelo predice el numero de dias de demora, como se muestra en la ecuación 2.

$$\hat{y} = f(x_1, x_2, \dots, x_n)$$

Donde:

\hat{y} = Dias de demora preecidos

$f(\cdot)$ = funcion de regresion obtenida mediante al AA.

El desarrollo de las ecuaciones (1) y (2), se puede medir mediante las siguientes métricas:

Error absoluto medio (MAE):

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

Error cuadrático medio (RMSE),:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

R^2 :

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

El análisis llevado a cabo debe dar una idea acerca de las variables que más impactan en las demoras de los tiempos de entrega con la finalidad de que los encargados de la toma de decisiones puedan enfocarse y controlar las variables de mayor relevancia.

Cuando se prevén retrasos, los responsables deben elegir la mejor manera de gestionarlos. El ADMC proporciona a esta evaluación un marco estructurado que analiza más de un criterio a la vez, para lo cual se consideran las siguientes opciones.

a) Alternativas (estrategias de mitigación)

- Añadir más existencias de seguridad.
- Utilizar dos fuentes.
- Utilizar una programación flexible para la fabricación.
- Consultar con los proveedores sobre las garantías de rendimiento.
- Enviar la información rápidamente.

b) Criterios de evaluación:

- Efecto en el coste.
- Reducción del riesgo.
- Nivel de atención al cliente.
- Fácil de implementar.
- Efectos en el medio ambiente.

El Proceso Analítico Jerárquico (PAJ) se utiliza para determinar el peso relativo de cada criterio comparándolos por pares, lo que muestra las expectativas de las partes interesadas. Tras asignar los pesos, se utiliza la técnica para la ordenación de las preferencias por similitud con la solución ideal (TOPSSI) para encontrar el mejor enfoque para la situación (Lai et al, 1994).

El proceso PAJ se ve reflejado en las siguientes ecuaciones:

$$A = \begin{bmatrix} 1 & \alpha_{12} & \dots & \alpha_{1n} \\ \frac{1}{\alpha_{12}} & 1 & \dots & \alpha_{2n} \\ \alpha_{12} & \vdots & \ddots & \vdots \\ \frac{1}{\alpha_{1n}} & \frac{1}{\alpha_{2n}} & \dots & 1 \end{bmatrix}$$

De manera correspondiente se adjunta el vector de pesos que se muestra en la ecuación :

$$w_i = \frac{(\prod_{j=1}^n a_{ij})^{1/n}}{\sum_{k=1}^n (\prod_{j=1}^n a_{kj})^{1/n}}$$



Donde:

α_{ij} = Importancia relativa del criterio i sobre el criterio j

w_i = peso normalizado del criterio i

En lo relacionado con el método TOPSSI, para encontrar el mejor enfoque para la situación se dan distintas alternativas A_1, A_2, \dots, A_m y los criterios C_1, C_2, \dots, C_n , sujeto a :

Matriz de decisión normalizada.

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}$$

Matriz de pesos normalizados.

$$v_{ij} = w_j \cdot r_{ij}$$

Considerando las soluciones ideales y las no ideales.

$$v_j^+ = \max_i v_{ij}, \quad v_j^- = \min_i v_{ij}$$

Las medidas de separación

$$S_i^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2}, \quad S_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2}$$

Y finalmente la cercanía relativa a la solución ideal:

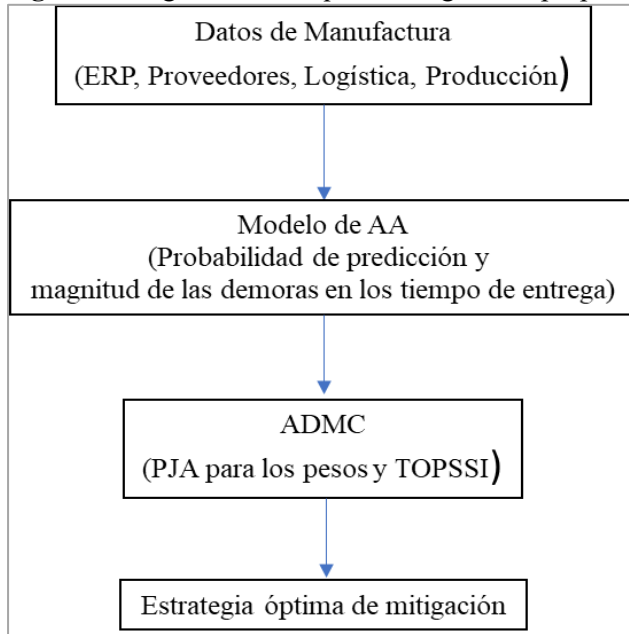
$$C_i = \frac{S_i^-}{S_i^+ + S_i^-}$$

Por lo anterior se espera que la integración del AA-ADMC se formen en dos etapas:

- a) Etapa de predicción: El AA provee de señales de alerta temprana que permitira clasificar ordenes, de riesgo de demora y cuantificar las desviaciones esperadas.
- b) Etapa de decisión: El ADCM evaluara posibles estrategias de mitigación, emparejando las predicciones de AA con las politicas organizacionales.

Esta aproximación dual asegura que la decisión tomada, este alineada con la estrategia organizacional en función de la información capturada, la figura 1 indica la secuencia correcta:

Figura 1. diagrama de bloques del algoritmo propuesto



RESULTADOS Y DISCUSIÓN

Con la finalidad de demostrar la aplicabilidad de la propuesta se propone un caso de estudio desarrollado en una empresa de la zona de Xalostoc, Estado de Mexico, México que se dedica a la fabricación de pernos y tensores automotrices, los cuales son suministrados al mercado de refacción nacional y a las palntas ensambladoras . Debido a este compromiso con la politica de justo a tiempo implementada por la compañía, las variaviones en los teimpos de entrega son de gran impactode forma particular con los proveedores de materias primas tales como los de varillas de acero y revestimientos metálicos.

Los datos utilizados corresponden a la producción propia e información del proveedor de todo un año, considerando 12000 ordenes emitidas. Las variables clave son:

- Características de la orden: Tamaño de la orden, tipo de producto, frecuencia de la orden.
- Factores de producción: Nivel de utilización de la maquinaria, tiempo de inactividad, disponibilidad de la mano de obra.
- Factores relacionados con el proveedor: indice de confiabilidad del proveedor, tasa de entregas a tiempo, tasa de defectos.
- Factores logísticos: Modos de transporte, tiempo de embarque promedio, retrasos en la entrega a los clientes.
- Variables externas: Desviación de los teimpos de entrega actuales mediso en dias.

Modelo de aplicación de AA.

Se desarrollaron dos modelos predictivos

- a) Modelo de clasificación: Se utilizó el algoritmo de “Random Forest”, para predecir la demora de un pedido (considerando entradas binarias).
 - Exactitud: 87%.
 - Precisión: 82%.
 - Retiro: 79%.
 - ABC (Area bajo la curva): 0.89
- b) Modelo de regresión: El regresor de incremento del gradiente estima la magnitud de las demoras (en días).
 - RMSE = 2.1 días.
 - MAE = 1.5 días.
 - $R^2 = 0.78$.

Derrivado de este análisis de importancia, se ha revelado que los factores de mayor importancia son:

- a) Confiabilidad del proveedor (27%).
- b) Variabilidad en el tiempo de transportación (21%)
- c) Utilización de la maquinaria (18%)
- d) Tamaño de la orden (15%)
- e) Disponibilidad de la mano de obra (9%)

Esto indica que el desempeño del proveedor y la logística son los factores de mayor peso en las demoras de los tiempos de entrega.

Basado en las predicciones hechas con el AA, se han considerado 5 estrategias de mitigación.

- a) Incrementar el inventario de seguridad (altos costos de mantenimiento, bajo riesgo de interrupción)
- b) Abastecimiento dual ((Costos medios, mayor resiliencia del sistema)
- c) Calendarización flexible (requiere entrenamiento de la fuerza de trabajo y actualizaciones en el sistema informático)
- d) Desarrollo de nuevos contratos en función del desempeño de los proveedores (mejoras a largo plazo que requieren de cierta negociación).

e) Embarque enviados (Un alto costo que requiere solución en el corto plazo)

Los pesos y los criterios se desarrollaron en base al PJA

- a) Impacto sobre el costo (30%)
- b) Reducción del riesgo (25%)
- c) Nivel de servicio al cliente (20%)
- d) Facilidad de implementación (15%)
- e) Impacto ambiental (10%)

Usando TOPSSI para establecer un rango, las alternativas quedan como se muestra en la tabla 1.

Tabla 1. Rangos establecidos mediante el método TOPSSI

Estrategia	Puntaje	Rango
Abastecimiento dual	0.81	1
Desarrollo de nuevos contratos en función del desempeño de los proveedores	0.76	2
Calendarización flexible	0.68	3
Incrementar e inventario de seguridad	0.55	4
Embarques enviados	0.42	5

Si se combinan las predicciones hechas con AA con el ADMC, el estudio nos da un esquema que implica lo siguiente:

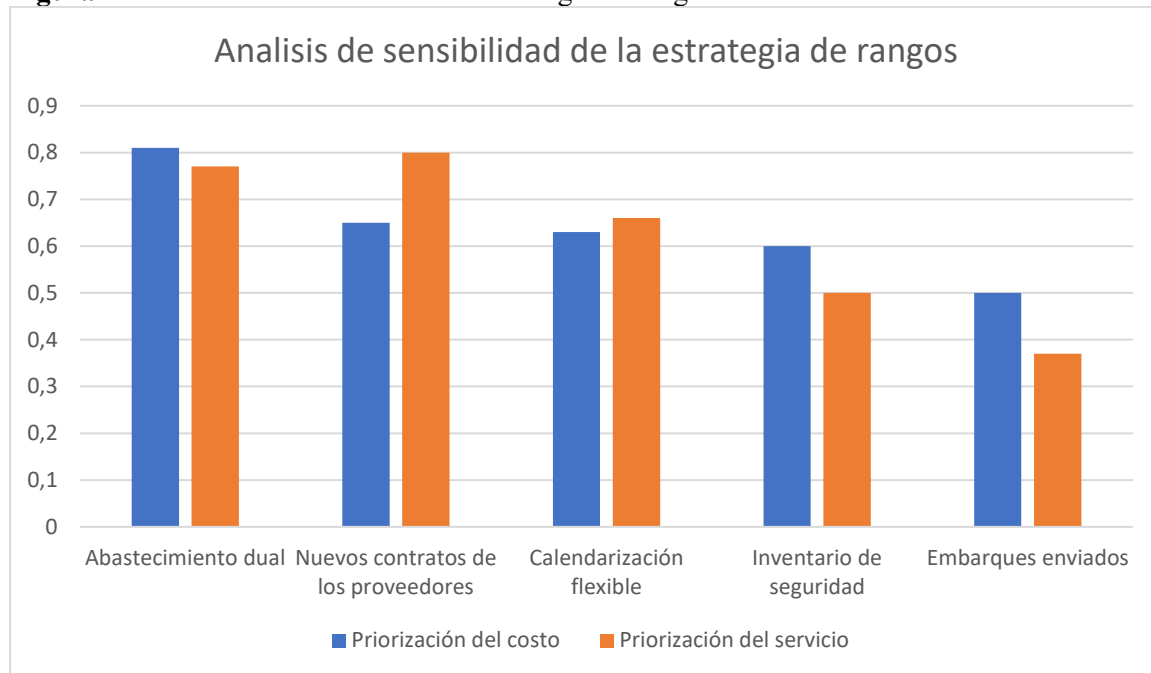
- a) El AA marco al proveedor A con un 40% de probabilidad de demora en el próximo trimestre
- b) ADMC recomienda la utilización del abastecimiento dual como una estrategia óptima de mitigación de las demoras.
- c) Los embarques enviados deben ser reservados para contingencias en el corto plazo.

Por otro lado si lleva a cabo un análisis de sensibilidad como el mostrado en la figura 2, se verá que:

- a) Cuando se priorizan los costos el abastecimiento dual aumenta, mientras que los embarques enviados mejoran ligeramente derivado del beneficio de sus costos inmediatos.
- b) Cuando se prioriza el nivel de servicio al cliente el desarrollo de nuevos contratos en función del desempeño de los proveedores se vuelven prioritarios reflejando el impacto que tienen en la confiabilidad y desempeño de las entregas.



Figura 2. Analisis de sensibilidad de la estrategia de rangos.



CONCLUSIONES

Los modelos de aprendizaje automatico proveen de un pronostico mas certero en relación con los tiempos de demora, no obstante las predicciones por si solas no son suficientes. Al vincular las salidas obtenidas del AA con las evaluaciones del ADMC, las predicciones realizadas se trasladan hacia decisiones de prioridad relevante, lo cual permite evaluar y mitigar el impacto de la demora en los tiempos de entrega en el el area de manufactura.

El caso de estudio esta centrado en la industria automotriz de autopartes ha demostrado que la confiabilidad del proveedor y la logistica son las principales areas responsables de que puedan existir demoras en los tiempos de entrega. El AA ha permitido un alto grado de precision, mientras que el ADMC identifica al abastecimiento dual como la mejor estrategia a largo plazo. De forma conjunto los dos criterios permiten orientar a los gerentes de resolver problemas reactivos a encontrar su solución de forma proactiva a problemas con un alto riesgo.

Este estudio contribuye en dos vertientes el academico y el práctico, vinculando el análisis predictivo y prescriptivo. El trabajo futuro debe centrarse en validar la metodología con datos reales y la exploración de técnicas de ADMC híbridas para mejorar la robustez de las decisiones gerenciales.

REFERENCIAS BIBLIOGRAFICAS

- Bandaly, D., Satir, A., & Shanker, L. (2016). Impact of lead time variability in supply chain risk management. *International Journal of Production Economics*, 180, 88-100.
<https://doi.org/10.1016/j.ijpe.2016.07.014>
- Burrows, T. N., Hamilton, M. A., & Grimsman, D. (2023, December). Who gets the whip? how supplier diversification influences bullwhip effect in a supply chain. In *2023 62nd IEEE Conference on Decision and Control (CDC)* (pp. 7592-7597). IEEE.
<https://doi.org/10.1109/CDC49753.2023.10384291>
- Castañé, G., Dolguí, A., Kousí, N., Meyers, B., Thevenin, S., Vyhmeister, E., & Östberg, P. O. (2023). The ASSISTANT project: AI for high level decisions in manufacturing. *International Journal of Production Research*, 61(7), 2288-2306.
<https://doi.org/10.1080/00207543.2022.2069525>
- Chang, W. S., & Lin, Y. T. (2019). The effect of lead-time on supply chain resilience performance. *Asia Pacific Management Review*, 24(4), 298-309.
<https://doi.org/10.1016/j.apmr.2018.10.004>
- Chen, Y., Zhou, Y., & Zhang, Y. (2021). Machine learning-based model predictive control for collaborative production planning problem with unknown information. *Electronics*, 10(15), 1818.
<https://doi.org/10.3390/electronics10151818>
- De Treville, S., Bicer, I., Chavez-Demoulin, V., Hagspiel, V., Schürhoff, N., Tasserit, C., & Wager, S. (2014). Valuing lead time. *Journal of Operations Management*, 32(6), 337-346.
<https://doi.org/10.1016/j.jom.2014.06.002>
- De Treville, S., Shapiro, R. D., & Hameri, A. P. (2004). From supply chain to demand chain: the role of lead time reduction in improving demand chain performance. *Journal of operations management*, 21(6), 613-627.
<https://doi.org/10.1016/j.jom.2003.10.001>
- Domladovac, M. (2021, September). Comparison of neural network with gradient boosted trees, random forest, logistic regression and SVM in predicting student achievement. In *2021 44th International Convention on Information, Communication and Electronic Technology (MIPRO)*



(pp. 211-216). IEEE.

<https://doi.org/10.23919/MIPRO52101.2021.9596684>

Dutta, G., Kumar, R., Sindhvani, R., & Singh, R. K. (2022). Overcoming the barriers of effective implementation of manufacturing execution system in pursuit of smart manufacturing in SMEs. *Procedia Computer Science*, 200, 820-832.

<https://doi.org/10.1016/j.procs.2022.01.279>

De Felice, F. (2012). Research and applications of AHP/ANP and MCDA for decision making in manufacturing. *International Journal of Production Research*, 50(17), 4735-4737.

<https://doi.org/10.1080/00207543.2012.657963>

De Montis, A., De Toro, P., Droste-Franke, B., Omann, I., & Stagl, S. (2000, May). Criteria for quality assessment of MCDA methods. In 3rd Biennial conference of the European society for ecological economics, Vienna (pp. 3-6). Citeseer.

Ferla, G., Mura, B., Falasco, S., Caputo, P., & Matarazzo, A. (2024). Multi-Criteria Decision Analysis (MCDA) for sustainability assessment in food sector. A systematic literature review on methods, indicators and tools. *Science of the Total Environment*, 946, 174235.

<https://doi.org/10.1016/j.scitotenv.2024.174235>

Lai, Y. J., Liu, T. Y., & Hwang, C. L. (1994). Topsis for MODM. *European journal of operational research*, 76(3), 486-500.

[https://doi.org/10.1016/0377-2217\(94\)90282-8](https://doi.org/10.1016/0377-2217(94)90282-8)

Liao, Y., Miao, S., Fan, W., & Liu, X. (2025). A Novel Hybrid Fuzzy Comprehensive Evaluation and Machine Learning Framework for Solar PV Suitability Mapping in China. *Remote Sensing*, 17(12), 2070.

<https://doi.org/10.3390/rs17122070>

Meng, L., McWilliams, B., Jarosinski, W., Park, H. Y., Jung, Y. G., Lee, J., & Zhang, J. (2020). Machine learning in additive manufacturing: a review. *Jom*, 72(6), 2363-2377.

<https://doi.org/10.1007/s11837-020-04155-y>

Mohammed, I. A., & Mandal, J. (2023). The Impact of Lead Time Variability on Supply Chain Management. *International Journal of Supply Chain Management*, 8(2), 41-55.



<https://doi.org/10.47604/ijsem.3075>

Nielsen, P., Michna, Z., Sørensen, B. B., & Dung, N. D. A. (2017). Lead times—their behavior and the impact on planning and control in supply chains. *Management and Production Engineering Review*.

<https://doi.org/10.1515/mper-2017-0015>

Nithya, T., Kumar, V. N., Deepa, S., CM, V., & Subramanian, R. S. (2023, August). A comprehensive survey of machine learning: Advancements, applications, and challenges. In *2023 Second International Conference on Augmented Intelligence and Sustainable Systems (ICAISS)* (pp. 354-361). IEEE.

<https://doi.org/10.1109/ICAISS58487.2023.10250547>

Paraschos, P. D., Gasteratos, A. C., & Koulouriotis, D. E. (2024). Deep learning model for optimizing control and planning in stochastic manufacturing environments. *Expert Systems with Applications*, 257, 125075.

<https://doi.org/10.1016/j.eswa.2024.125075>

Qin, J., Hu, F., Liu, Y., Witherell, P., Wang, C. C., Rosen, D. W., ... & Tang, Q. (2022). Research and application of machine learning for additive manufacturing. *Additive Manufacturing*, 52, 102691.

<https://doi.org/10.1016/j.addma.2022.102691>

Singh, R. J., Sohani, N., & Marmat, H. (2013). Effect of Lean/JIT Practices and Supply Chain Integration on Lead Time Performance. *Journal of Supply Chain Management Systems*, 2(2).

Schneckenreither, M., Haeussler, S., & Gerhold, C. (2021). Order release planning with predictive lead times: a machine learning approach. *International Journal of Production Research*, 59(11), 3285-3303.

<https://doi.org/10.1080/00207543.2020.1859634>

Thürer, M., Fernandes, N. O., Haeussler, S., & Stevenson, M. (2023). Dynamic planned lead times in production planning and control systems: does the lead time syndrome matter?. *International Journal of Production Research*, 61(4), 1268-1282.

<https://doi.org/10.1080/00207543.2022.2034193>



Um, J., & Han, N. (2021). Understanding the relationships between global supply chain risk and supply chain resilience: the role of mitigating strategies. *Supply chain management: an international journal*, 26(2), 240-255.

<https://doi.org/10.1108/SCM-06-2020-0248>

Wyrembek, M., & Baryannis, G. (2024). Using MCDM methods to optimise machine learning decisions for supply chain delay prediction: A Stakeholder-centric approach. *Logforum*, 20(2).

<https://doi.org/10.17270/J.LOG.001019>

Yang, X., Li, Y. M., Wang, Q., Li, R., & Zhang, P. (2024). Machine learning model based on RCA-PDCA nursing methods and differentiating factors to predict hypotension during cesarean section surgery. *Computers in Biology and Medicine*, 174, 108395.

<https://doi.org/10.1016/j.compbiomed.2024.108395>

Yang, C. L., Yilma, A. A., Woldegiorgis, B. H., Tampubolon, H., & Sutrisno, H. (2024). A Hybrid Manufacturing Process Monitoring Method Using Stacked Gated Recurrent Unit and Random Forest. *Intelligent Automation & Soft Computing*, 39(2).

<https://doi.org/10.32604/iasc.2024.043091>

Yska, S., Bustos, D., & Guedes, J. C. (2022). Machine learning applications for continuous improvement in integrated management systems: a short review. *Occupational and Environmental Safety and Health IV*, 541-551.

https://doi.org/10.1007/978-3-031-12547-8_43

