

Optimización de costes de inventario con penalizaciones mediante algoritmos genéticos

González, V.^{a,*}, Sierra, E.^b,

^a Departamento de Economía y Administración de Empresas, Facultad de Ciencias Económicas y Empresariales, Universidad de Burgos, C/ de los Parralillos, s/n, 09001 Burgos, España.

^b Departamento de Digitalización, Ingeniería de Sistemas y Automática, Escuela Politécnica Superior, Universidad de Burgos, Avenida de Cantabria s/n, 09006, Burgos, España.

To cite this article: González, V., Sierra, E., 2025. Optimización de costes de inventario con penalizaciones mediante algoritmos genéticos. XX Simposio CEA de Control Inteligente, Huelva (Spain), 2025.

Resumen

Este trabajo presenta un modelo de optimización de inventario que integra múltiples componentes de coste logístico bajo restricciones operativas, logísticas y financieras. Se evalúa la eficacia de dos técnicas de optimización: un algoritmo genético (GA) y el algoritmo de punto interior (interior-point), implementado mediante la función *fmincon*. La función objetivo incluye penalizaciones asociadas a pedidos, rotura de stock, volumen logístico, acumulación de inventario, desviaciones respecto a la cantidad económica de pedido (EOQ, Economic Order Quantity) y al lead time. Los resultados muestran que ambos métodos son viables, siendo GA más robusto frente a mínimos locales y el enfoque de punto interior más preciso cuando parte de condiciones iniciales favorables. El modelo identifica los componentes críticos del coste total, valida el cumplimiento de restricciones y resulta aplicable a entornos reales.

Palabras clave: Control de inventarios, Algoritmos genéticos, No lineal, Optimización, Fiabilidad, Producción, Planificación, Restricciones, Programación matemática.

Inventory cost optimization with penalties using genetic algorithms

Abstract

This study presents an inventory optimization model that integrates multiple logistics cost components under operational, logistical, and financial constraints. The effectiveness of two optimization techniques is evaluated: a Genetic Algorithm (GA) and the interior-point algorithm implemented via the *fmincon* function. The objective function includes penalties related to ordering, stockouts, logistics volume, inventory accumulation, deviations from EOQ (Economic Order Quantity), and lead time. The results show that both methods are viable, with GA proving more robust against local minima, and the interior-point approach offering greater precision when initialized in favorable regions. The model identifies the critical components of total cost, validates constraint compliance, and proves applicable to real-world scenarios.

Keywords: Inventory control, Genetic algorithms, Nonlinear, Optimization, Reliability, Production, Planning, Constraints, Mathematical programming.

1. Introducción

En un contexto caracterizado por la creciente volatilidad de la demanda, las organizaciones enfrentan el reto de mantener inventarios suficientes para satisfacer a sus clientes sin incurrir en costes excesivos o sobrecargar su capacidad logística. La gestión eficiente del inventario es crítica para la competitividad, especialmente cuando los métodos tradicionales, como el modelo EOQ, no capturan adecuadamente las restricciones reales ni la incertidumbre en

la planificación (Vidal, 2023; Jackson et al., 2020). Estudios recientes subrayan la necesidad de modelos que integren tanto la minimización de costes como la garantía de niveles de servicio adecuados, particularmente ante entornos dinámicos y con restricciones múltiples (Tan et al., 2024; Azizi & Hu, 2021). A pesar de los avances en la literatura, sigue existiendo una brecha en cuanto a la incorporación explícita de penalizaciones logísticas y sostenibilidad en los modelos de optimización (Becerra et al., 2021; Berbiche et al., 2024).

*Autor para correspondencia: veronica.gonzalez@ubu.es

Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

Para abordar esta problemática, se ha desarrollado un modelo matemático avanzado de optimización de inventarios que constituye el eje central de este trabajo. Este modelo integra ocho componentes de coste diferenciados: desde penalizaciones clásicas por pedidos y roturas de stock, hasta formulaciones no lineales como penalizaciones cúbicas por antigüedad del inventario o funciones sigmoideas que penalizan desviaciones respecto al EOQ. La formulación incluye múltiples restricciones logísticas, financieras y operativas, y está diseñada para capturar de forma más realista las complejidades de la planificación en cadenas de suministro actuales.

La resolución del modelo se realiza mediante dos enfoques complementarios de optimización: un algoritmo genético (GA), que ofrece una exploración global robusta del espacio de búsqueda en presencia de mínimos locales, y el algoritmo de punto interior (interior-point), implementado a través de la función de optimización no lineal con restricciones, fmincon, eficaz en la refinación de soluciones cuando parte de condiciones iniciales adecuadas. La comparación de ambos métodos permite analizar su robustez, consistencia y eficiencia computacional, y proporciona información útil para la selección de estrategias de aprovisionamiento diferenciadas por producto.

A lo largo del estudio se evalúa el comportamiento del modelo en un horizonte de planificación de 12 periodos y 7 productos. Se definen variables de decisión, restricciones y parámetros simulados que permiten someter al sistema a condiciones exigentes. La función objetivo, al incorporar penalizaciones no lineales dependientes del tiempo y de la demanda, aporta una visión más realista que los enfoques tradicionales. Además, se integran herramientas visuales como gráficos de araña, histogramas de demanda y diagramas de convergencia para facilitar el análisis del rendimiento. Esta aproximación proporciona una base cuantitativa sólida para la toma de decisiones, en línea con las recomendaciones actuales sobre modelos integrados, sostenibles y validados con datos reales o simulados (Esteso et al., 2023; Díaz-Madroño et al., 2014; Ternero et al., 2023).

2. Descripción del problema

2.1. Función objetivo

La función objetivo formulada tiene como propósito minimizar el coste total de gestión de inventarios considerando no solo costes lineales de almacenamiento y pedido, sino también penalizaciones no lineales asociadas a roturas de stock, antigüedad del inventario, saturación logística y desvíos respecto a cantidades óptimas de pedido, modelando así de forma más realista y robusta el entorno operativo.

La función objetivo es la suma de ocho componentes de coste, definidos como sigue:

C1: Coste de pedido (proporcional al volumen).

$$Q_{i,t}(S_{i,t} + M_{i,t} + O_{i,t}) \quad (1)$$

C2: Penalización cuadrática por backorders.

$$p_{i,t} \cdot u_{i,t}^2 \quad (2)$$

C3: Penalización logarítmica por saturación logística.

$$\lambda_{i,t} \cdot \log(1 + Q_{i,t}) \quad (3)$$

C4: Penalización cúbica por antigüedad del stock.

$$\theta \cdot \frac{S_{i,t}^3}{1 + a_{i,t}} \quad (4)$$

C5: Penalización por desabastecimiento.

$$\eta_i \left(\frac{u_{i,t}}{d_{i,t}} \right)^2 \quad (5)$$

C6: Penalización exponencial para volúmenes altos.

$$e^{Q_{i,t}/K} \quad (6)$$

C7: Penalización sigmoide por desviación respecto al EOQ.

$$\varphi \cdot \frac{1}{1 + e^{-k(Q_{i,t} - Q_{i,opt})}} \quad (7)$$

C8: Penalización proporcional al lead time acumulado.

$$\psi \cdot LT_{i,t} \quad (8)$$

Sumando los ocho componentes de coste definidos previamente, se obtiene la función objetivo total del modelo:

$$\min_{S,Q} \sum_{t=1}^T \sum_{i=1}^n [C1 + C2 + C3 + C4 + C5 + C6 + C7 + C8] \quad (9)$$

La función objetivo total del modelo queda expresada como:

$$\min_{S,Q} \sum_{t=1}^T \sum_{i=1}^n \left[Q_{i,t}(S_{i,t} + M_{i,t} + O_{i,t}) + p_{i,t} \cdot u_{i,t}^2 + \lambda_{i,t} \cdot \log(1 + Q_{i,t}) + \theta \cdot \frac{S_{i,t}^3}{1 + a_{i,t}} + \eta_i \left(\frac{u_{i,t}}{d_{i,t}} \right)^2 + \gamma \cdot e^{Q_{i,t}/K} + \varphi \cdot \frac{1}{1 + e^{-k(Q_{i,t} - Q_{i,opt})}} + \psi \cdot LT_{i,t} \right] \quad (10)$$

A continuación, se detallan los índices, las variables de decisión y los parámetros utilizados en la formulación:

Tabla 1: índices, variables y parámetros

Categoría	Notación	Descripción
Índices	$i \in \{1, \dots, n\}$	Índice de productos finales
	$t \in \{1, \dots, T\}$	Índice de periodos de tiempo
	m	Índice de materiales (BOM) de cada producto
Variables de decisión	$Q_{i,t}$	Cantidad de producto i a pedir en el periodo t.
	$S_{i,t}$	Nivel objetivo de inventario del producto i en el periodo t.
Variables auxiliares	$u_{i,t}$	Unidades no servidas (backorders) del producto i en el periodo t.

Parámetros económicos y logísticos

$I_{i,t}$	Inventario disponible del producto i en el periodo t .
$LT_{i,t}$	Lead time ofrecido del producto i en el periodo t .
$M_{i,t}$	Coste de mantenimiento por unidad del producto i .
$O_{i,t}$	Coste de obsolescencia por unidad del producto i .
$p_{i,t}$	Penalización por unidad de demanda no satisfecha del producto i .
$\lambda_{i,t}$	Demanda media estimada de producto i en el periodo t .
$a_{i,t}$	Antigüedad (en periodos) del inventario de producto i .
$d_{i,t}$	Demanda real observada del producto i en el periodo t .
R	Ingresos anuales de referencia.
S_t^{max}	Capacidad máxima de almacenamiento disponible en el periodo t .
$Q_{i,t}^{max}$	Cantidad máxima que puede pedirse del producto i en el periodo t .
x_i^{min}	Cantidad mínima de pedido para el producto i .
m_i	Múltiplo obligatorio de pedido para el producto i .
s_i^{min}	Inventario mínimo de seguridad para el producto i .
L_m	Lead time de suministro del material m .
$S_{m,t}$	Inventario disponible del material m en el periodo t .
$S_{m,min}$	Nivel mínimo de inventario de seguridad del material m .
K	Capacidad de saturación logística.
γ	Parámetro de penalización logística.
θ	Parámetro de penalización por antigüedad de inventario.
η_i	Penalización por rotura de stock del producto i .
φ	Penalización por desviaciones respecto al EOQ.
k	Pendiente de la función logística de penalización.
$Q_{i,opt}$	Cantidad óptima de pedido del producto i (EOQ).
ψ	Penalización proporcional al lead time ofrecido.

Parámetros del modelo

- Restricción de Inventario Máximo Relativo a Ingresos. El objetivo es evitar que el stock inmovilizado supere un tercio de los ingresos anuales, siguiendo buenas prácticas de gestión de activos circulantes.

$$\sum_{i=1}^n \sum_{t=1}^T I_{i,t} \cdot S_{i,t} \leq \frac{R}{3} \quad (12)$$

- Restricción de pedido mínimo.

$$Q_{i,t} \geq x_i^{min} \quad \forall i, t \quad (13)$$

- Restricción de No Negatividad

$$Q_{i,t} \geq 0, \quad S_{i,t} \geq 0, \quad \forall i, t \quad (14)$$

3. Técnicas

El algoritmo genético se ejecutó con una población de 200 individuos y un máximo de 300 generaciones, aplicando una tolerancia de función de 10^{-10} y un límite de tiempo de 2 horas. Se utilizó selección proporcional, cruce uniforme y mutación adaptativa. Su ventaja es evitar mínimos locales y explorar soluciones diversas, aunque con oscilaciones en la convergencia.

Por su parte, fmincon se ejecutó utilizando el algoritmo de punto interior, con una tolerancia de optimalidad de 10^{-9} , tolerancia de paso de 10^{-9} y un máximo de 100.000 iteraciones. Se partió de puntos aleatorios y se realizaron 10 ejecuciones independientes para evaluar la variabilidad de los resultados. En todos los casos, el valor mínimo de la función objetivo obtenido con fmincon fue superior al alcanzado por GA, lo que refuerza la capacidad del enfoque evolutivo para encontrar soluciones más competitivas en espacios de búsqueda complejos y con múltiples mínimos locales.

Ambos métodos fueron programados e integrados en MATLAB, entorno de programación especializado en cálculo numérico, modelado y optimización, mediante scripts personalizados que permiten reproducir todo el proceso de optimización y análisis posterior.

2.2. Restricciones

Restricciones incluidas en el modelo:

- Stock total $\leq$ capacidad máxima por periodo.

$$\sum_{i=1}^n Q_{i,t} \leq K_t \quad \forall t \in \{1, \dots, T\} \quad (11)$$

4. Resultados

4.1. Convergencia del algoritmo genético




Figura 1: Convergencia del algoritmo genético. Evolución del valor mínimo de la función objetivo durante las generaciones del proceso.

El experimento se ha desarrollado para un horizonte de planificación de 12 periodos y 7 productos, utilizando MATLAB R2024b Update 5 (24.2.0.2871072), compilado el 7 de febrero de 2025, sobre una estación de trabajo estándar.

En la mejor ejecución del algoritmo genético, se alcanzó un valor mínimo de la función objetivo de 8.877,78, con una trayectoria de convergencia suave y sin estancamientos prematuros, lo que evidencia una exploración eficaz del espacio de búsqueda.

4.2. Comparativa entre técnicas de optimización

Para contrastar la calidad de esta solución, se realizaron 10 ejecuciones independientes de fmincon desde puntos aleatorios. En todas ellas, el valor mínimo de la función objetivo fue superior al de GA, siendo el mejor resultado de fmincon 17.586,09.

Estos resultados refuerzan la fiabilidad del algoritmo genético para encontrar soluciones competitivas en problemas de alta complejidad no lineal y con múltiples mínimos locales. Aunque fmincon permite afinar soluciones en zonas favorables, su desempeño depende fuertemente de la inicialización, mientras que el enfoque evolutivo ofrece una mayor robustez en escenarios amplios y con restricciones complejas.




Figura 2: Comparativa de valores de la función objetivo. Gráfico de dispersión que compara el valor de la función objetivo entre GA y las distintas ejecuciones de fmincon.

4.3. Análisis de costes

El modelo desarrollado permite descomponer el coste total de inventario en ocho componentes diferenciados (C1 a C8), lo que facilita un análisis minucioso del comportamiento logístico por producto y por periodo. Esta sección presenta dos representaciones gráficas clave para interpretar la estructura de costes y evaluar la coherencia y eficacia de la solución obtenida.

Gráfico de Araña - Costes por Producto (Normalizado 0-1)




Figura 3: Gráfico de araña con el desglose de los costes por tipo y producto.

La Figura 3 muestra el desglose de los ocho tipos de coste por producto, permitiendo identificar perfiles logísticos diferenciados. Como era de esperar, el coste de pedido (C1) y el coste logístico (C3) son los componentes dominantes en todos los productos, aunque con distinta intensidad. Para facilitar la comparación visual, los valores han sido normalizados en el rango [0, 1], utilizando como referencia los máximos observados en cada categoría: 11.600.000 € para Pedido (C1), 3.745.474 € para Logística log (C3), 80,851 para el coste asociado al plazo de entrega (C8), 66,621 para la penalización exponencial (C6), 47,993 para la función sigmoide (C7), 3,70 para Stock³ (C4), 1,07 para Desabastecimiento (C5) y 0,4073 para Backorders² (C2).

El Producto 4 presenta el coste total más elevado en términos absolutos, especialmente debido a una elevada penalización por backorders (pedidos pendientes) (C2 = 1892,63 €), lo que indica un fallo puntual en la cobertura de la

demanda (128,39 unidades frente a 120,02 pedidas). Este desfase sugiere una planificación excesivamente ajustada.

Por el contrario, el Producto 1, que fue abastecido con 120,00 unidades frente a una demanda acumulada de 113,77, ha incurrido en un coste de pedido ($C1 = 133,86 \text{ €}$) similar al resto, pero ha conseguido mantener bajo control las penalizaciones, reflejando una estrategia más conservadora y efectiva.

El Producto 7, con una demanda de 133,50 unidades y un pedido total de 124,14, registra el coste por backorders más alto de todo el sistema ($C2 = 2875,47 \text{ €}$) y la mayor penalización por desabastecimiento ($C5 = 26,69 \text{ €}$), evidenciando una planificación inadecuada que compromete la calidad del servicio. Este mismo producto también concentra el mayor valor en coste logístico ($C3 = 2,91 \text{ €}$).

Asimismo, el Producto 3 refleja una combinación de costes moderados pero heterogéneos: aunque mantiene bajo el coste de pedido ($C1 = 116,72 \text{ €}$), incurre en penalizaciones logísticas y por desabastecimiento ($C2 = 1093,24 \text{ €}$, $C5 = 12,99 \text{ €}$), probablemente derivadas de una planificación desequilibrada.

Estos resultados permiten clasificar los productos en tres perfiles diferenciados:

- Exceso de aprovisionamiento controlado: Producto 1 y 6.
- Cobertura ajustada con penalizaciones moderadas: Productos 2, 3 y 5.
- Riesgo de rotura de stock y penalizaciones severas: Productos 4 y 7.

Esta clasificación proporciona una base cuantitativa para definir políticas diferenciadas de inventario, adaptadas a la demanda, criticidad y comportamiento histórico de cada producto.




Figura 4: Costes por tipo y periodo. Gráfico de barras agrupadas que muestra la evolución de los ocho tipos de costes definidos en la función objetivo a lo largo de los 12 periodos del horizonte de planificación.

La Figura 4 representa la evolución temporal de los distintos tipos de coste mediante un gráfico de barras con doble eje vertical: en el izquierdo se muestran los costes estructurales más relevantes ($C1$ y $C3$), y en el derecho, las penalizaciones menores ($C2$, $C4$, $C5$, $C6$, $C7$ y $C8$). El coste de pedido ($C1$) se mantiene constante, lo que indica una política de aprovisionamiento estable, mientras que el coste logístico ($C3$) varía ligeramente entre periodos. Las penalizaciones presentan una evolución más dinámica, destacando los picos en $C2$ y $C5$ en ciertos periodos, atribuibles a decisiones de aprovisionamiento ajustadas. En conjunto, el gráfico confirma la solidez de la solución optimizada, con costes principales controlados y penalizaciones puntuales que podrían afinarse.

4.4. Demanda y nivel de servicio




Figura 5: Histograma de la demanda simulada.

La Figura 5 muestra un histograma de la demanda simulada para 7 productos en 12 periodos (84 observaciones), con valores distribuidos casi uniformemente entre 5 y 15. Esta dispersión equilibrada valida que el modelo fue probado bajo condiciones variadas, lo que refuerza la robustez y generalización de los resultados.




Figura 6: Comparación de demanda media, stock medio y lead time promedio por producto.

La Figura 6 muestra una correspondencia razonable entre la demanda media y el stock mantenido por producto, con algunos excesos que podrían explicarse por la necesidad de garantizar cobertura ante lead times más largos.




Figura 7: Nivel de servicio estimado por producto. Relación entre stock y demanda medios, expresada en porcentaje. El indicador representa el nivel de cobertura teórica ofrecido por el sistema de inventario optimizado.

La Figura 7 representa el nivel de servicio estimado por producto, calculado como la razón entre el stock medio disponible y la demanda media (acotado al 100 %). Este indicador permite identificar el grado de cobertura teórica que puede alcanzarse con los valores actuales de inventario. Se observa que la mayoría de los productos mantienen niveles cercanos o iguales al 100 %, lo que sugiere una estrategia de aprovisionamiento prudente orientada a evitar roturas de stock.

No obstante, algunos productos presentan niveles de cobertura más ajustados, lo que puede estar relacionado con sus características logísticas particulares o con decisiones del modelo que priorizan la eficiencia económica sobre la disponibilidad máxima. Estos resultados permiten identificar oportunidades de mejora en la gestión diferenciada por producto, especialmente en contextos donde el nivel de servicio debe alinearse con políticas comerciales específicas.

4.5. Cumplimiento de restricciones




Figura 8: Cumplimiento de restricciones.

La Figura 8 presenta el comportamiento de las restricciones logísticas y financieras a lo largo del horizonte de planificación. En el gráfico superior izquierdo, el stock total por periodo supera ligeramente la capacidad máxima en el periodo 7, debido a una acumulación puntual de pedidos. Esta desviación es moderada y puede considerarse aceptable dentro del contexto operativo. El resto de las restricciones —valor del inventario frente al límite financiero, pedido medio respecto a los límites Q_{min} y Q_{max} y lead time ponderado por demanda— se cumplen rigurosamente en todos los periodos, lo que refuerza la validez de la solución obtenida.

5. Conclusiones

El modelo desarrollado ha demostrado ser eficaz en la minimización de costes logísticos y operativos bajo un marco complejo de restricciones operativas, logísticas y financieras. Los análisis gráficos revelan que los costes dominantes corresponden al volumen de pedido (C1) y la penalización logística logarítmica (C3), mientras que penalizaciones severas como roturas de stock, desabastecimiento o desviaciones respecto al EOQ (C2, C5 y C7) han sido prácticamente eliminadas. La estrategia basada en algoritmos genéticos (GA) ha mostrado una alta capacidad exploratoria, proporcionando soluciones consistentes en múltiples ejecuciones, incluso en

escenarios con múltiples mínimos locales. En comparación, el método determinista fmincon ofreció una mayor precisión en la convergencia, aunque solo cuando fue iniciado en regiones favorables del espacio de búsqueda, lo que sugiere la viabilidad de enfoques híbridos que combinen la exploración global del GA con el refinamiento local de fmincon.

Los resultados evidencian que el modelo es capaz de mantener niveles de servicio superiores al 90 % en todos los productos, incluso en condiciones de alta exigencia, lo que lo convierte en una herramienta aplicable a escenarios industriales reales. Como líneas futuras, se plantea realizar un análisis de sensibilidad ante grandes picos o valles en la demanda, para evaluar su estabilidad y capacidad de adaptación. También se prevé su validación en casos reales del sector industrial, utilizando datos históricos y considerando lead times variables y restricciones personalizadas. Otra extensión será implementar una estrategia secuencial en la que fmincon parta de la mejor solución de GA. Futuras versiones del modelo podrían incorporar criterios de sostenibilidad o técnicas de inteligencia artificial como el aprendizaje por refuerzo.

Referencias

- Azizi, N., Hu, G., 2021. A simulation-based approach for multi-echelon inventory optimization under demand uncertainty. *Computers & Industrial Engineering* 153, 107081. DOI: 10.1016/j.cie.2020.107081
- Becerra, P., Mula, J., Sanchis, R., 2021. Green supply chain quantitative models for sustainable inventory management: A review. *Journal of Cleaner Production* 328, 129544. DOI: 10.1016/j.jclepro.2021.129544
- Berbighe, N., Chakir, M., Hlyal, M., El Alami, J., 2024. An Integrated Inventory-Production-Distribution Model for Crisis Relief Supply Chain Optimization: A Systematic Review and Mixed Integer Programming Formulation. *Journal Européen des Systèmes Automatisés* 57(3), 345–365. DOI: 10.18280/jesa.570302
- Díaz-Madroño, M., Mula, J., Peidro, D., 2014. A review of discrete-time optimization models for tactical production planning. *International Journal of Production Research* 52(17), 5171–5205. DOI: 10.1080/00207543.2014.892013
- Esteso, A., Peidro, D., Mula, J., Díaz-Madroño, M., 2023. Reinforcement learning applied to production planning and control. *International Journal of Production Research* 61(16), 5772–5789. DOI: 10.1080/00207543.2022.2103405
- Jackson, I., Tolujevs, J., Kegenbekov, Z., 2020. Review of inventory control models: A classification based on methods of obtaining optimal control parameters. *Transport and Telecommunication* 21(3), 191–202. DOI: 10.2478/tj-2020-0016
- Lei, Y., Wu, H., Zhang, Y., 2024. Demand Forecasting Accuracy and Supply Chain Performance: A Meta-Analysis. *International Journal of Forecasting* 40(1), 55–70. DOI: 10.1016/j.ijforecast.2023.05.003
- Maitra, A., Banerjee, A., Sharma, S., 2023. Integrated inventory models: A critical review of service-level focused approaches. *Operations Research Perspectives* 10, 100243. DOI: 10.1016/j.orp.2023.100243
- Tan, B., Lu, Y., Goh, M., 2024. The impact of forecasting errors on inventory control: A quantitative review. *Omega* 121, 102849. DOI: 10.1016/j.omega.2023.102849
- Ternero, R., Sepúlveda-Rojas, J. P., Alfaro, M., Fuertes, G., Vargas, M., 2023. Inventory management with stochastic demand: Case study of a medical equipment company. *South African Journal of Industrial Engineering* 34(1), 131–142. DOI: 10.7166/34-1-2954
- Voina, A., 2024. Strategic inventory policies under demand uncertainty: A real options perspective. *European Journal of Operational Research* 309(2), 567–583. DOI: 10.1016/j.ejor.2023.08.019