

# ALGORITMO EVOLUTIVO MULTIOBJETIVO BASADO EN DESCOMPOSICIÓN PARA LA OPTIMIZACIÓN DEL PROCESAMIENTO POR LOTES DE PEDIDOS

FABIO M. MIGUEL<sup>1</sup> - MARIANO FRUTOS<sup>2,3,4</sup> - MÁXIMO MÉNDEZ<sup>5</sup> - BEGOÑA GONZÁLEZ<sup>5</sup>

<sup>1</sup>Sede Alto Valle y Valle Medio, Universidad Nacional de Río Negro, CONICET, Argentina.

<sup>2</sup>Departamento de Ingeniería, Universidad Nacional del Sur (UNS), Argentina.

<sup>3</sup>Instituto de Investigaciones Económicas y Sociales del Sur (IIESS UNS-CONICET), Argentina.

<sup>4</sup>Instituto de Ingeniería (II UNS-CIC), Argentina.

<sup>5</sup>Instituto Universitario SIANI, Universidad de Las Palmas de Gran Canaria (ULPGC), España.

*fmiguel@unrn.edu.ar - mfrutos@uns.edu.ar - maximo.mendez@ulpgc.es - bego.landin@ulpgc.es*

Fecha recepción: marzo 2024    Fecha aprobación: octubre 2024

ARK CAICYT: <https://id.caicyt.gov.ar/ark:/s18539777/ok4i6st63>

## RESUMEN

La demanda de prácticas logísticas sostenibles junto al auge del comercio electrónico, ha generado mayores exigencias en cuanto a la eficiencia y calidad en el procesamiento de pedidos. En este marco, y con el propósito de estudiar los métodos más adecuados para abordar el problema de agrupación y preparación de pedidos, se presenta una variante del JOBPRP con dos objetivos: los costos operativos y la distribución equilibrada de la carga de trabajo. En este contexto, los algoritmos evolutivos son buenas alternativas para la búsqueda multiobjetivo, pero pueden enfrentar obstáculos relacionados con la convergencia o la diversidad al abordar frentes de Pareto irregulares. Por esto se ha estudiado el desempeño del *Algoritmo Evolutivo Multiobjetivo Basado en Descomposición*, MOEA/D. Se realizó un análisis comparativo de su rendimiento utilizando diferentes métodos de escalarización en un conjunto exhaustivo de pruebas experimentales aplicadas a instancias de diferentes tamaños del problema abordado. Se emplearon como indicadores de desempeño el hipervolumen, la distancia promedio a la solución ideal y la dispersión de las soluciones no dominadas. Los resultados indican que el MOEA/D basado en el método de AASF ofrece un buen desempeño en términos de hipervolumen promedio y dispersión de soluciones a lo largo de los frentes.

**PALABRAS CLAVE:** METAHEURÍSTICAS - ALGORITMO EVOLUTIVO - JOBPRP.

## ABSTRACT

The demand for sustainable logistics practices, coupled with the rise of e-commerce, has led to greater requirements for efficiency and quality in order

processing. Within this framework, and with the aim of studying the most suitable methods to address the problem of order grouping and preparation, a variant of the JOBPRP is presented with two objectives: operational costs and balanced workload distribution. In this context, evolutionary algorithms are strong alternatives for multi-objective search, yet they may face challenges related to convergence or diversity when dealing with irregular Pareto fronts. Therefore, the performance of the Multi-Objective Evolutionary Algorithm Based on Decomposition (MOEA/D) was studied. A comparative analysis of its performance was conducted using different scalarization methods across an extensive set of experimental tests applied to instances of various sizes of the problem under consideration. Performance indicators such as hypervolume, the average distance to the ideal solution, and the dispersion of non-dominated solutions were used. The results indicate that the MOEA/D based on the AASF method demonstrates strong performance in terms of average hypervolumes and solution dispersion across the fronts.

**KEYWORDS:** METAHEURISTICS - EVOLUTIONARY ALGORITHM - JOBPRP.

## 1. INTRODUCCIÓN

El incremento en la demanda de prácticas logísticas sostenibles, junto con el auge del comercio electrónico, ha generado mayores exigencias en cuanto a la eficiencia y calidad en el procesamiento de pedidos. Según Sancaklı et al. (2022), la eficiencia en las operaciones de almacenamiento es clave para el desempeño general de una organización (Miguel et al., 2019; Miguel et al., 2021; Tsai et al., 2008; van Gils et al., 2018). El proceso de preparación de pedidos *constituye* entre el 50% y el 70% de los costos operativos en los centros de distribución, con una alta demanda de mano de obra en los sistemas manuales y una significativa inversión de capital en los sistemas automatizados.

El proceso de preparación de pedidos implica la recolección de productos desde áreas específicas de almacenamiento en respuesta a solicitudes hechas por los clientes (De Koster et al., 1999; De Koster et al., 2007; Hofmann & Visagie, 2021; Scholz et al., 2017; Ten Hompel & Schmidt, 2007). Esta actividad representa una de las tareas más costosas en la mayoría de los almacenes, ya que implica el retiro de los artículos de sus ubicaciones de almacenamiento y su posterior transporte hacia el área destinada para la preparación y envío (Grosse & Glock, 2015; Žulj et al., 2018). Los productos recolectados se agrupan y organizan en distintos paquetes (como cajas, palets, contenedores, entre otros) para su posterior despacho (Chen & Wu, 2005; Henn et al., 2012). A menudo, las cargas unitarias incluyen varios productos, los cuales deben ser etiquetados y marcados adecuadamente. Además, se verifica que las cargas coincidan con los pedidos, y se preparan los documentos necesarios para su envío. Finalmente, las mercancías se cargan en los medios de transporte correspondientes (Miguel et al., 2022).

La mejora de la agrupación de pedidos reduce el tiempo total de

preparación de pedidos necesario para recoger los artículos solicitados. En este contexto, la agrupación de pedidos estáticos (por ejemplo, problemas de selección por olas, agrupación y secuenciación), está basada en la suposición de que todos los pedidos de los clientes se conocen antes de su programación.

Los costos asociados a estas tareas están directamente relacionados con el tiempo que se invierte en procesar los pedidos y con la utilización de los recursos. En este sentido, cumplir rigurosamente con los plazos de entrega puede extender los tiempos de procesamiento y llevar a una subutilización de las capacidades de los preparadores de pedidos asignados para estas tareas (Miguel et al., 2022). Por otro lado, la asignación equilibrada de carga de trabajo a los preparadores es un aspecto relevante del factor humano a integrar en los sistemas de preparación de pedidos (Grosse et al., 2017; Zhang et al., 2017), que debe tenerse en cuenta para mejorar el rendimiento de forma sostenible.

En resumen, en este contexto no se puede hablar de un único criterio de optimalidad; más bien, se busca identificar un conjunto de soluciones de Pareto, del cual el planificador podría elegir la alternativa más adecuada según las circunstancias específicas. Este problema de agrupación y preparación de pedidos, es NP-Hard (De Koster et al., 2007; Ten Hompel & Schmidt, 2007). Los criterios a optimizar incluyen minimizar los costos operativos asociados al proceso de recolección, directamente relacionados con la longitud de las rutas y la cantidad de artículos en cada lote; y equilibrar el balanceo de carga de trabajo de los preparadores.

En vista de las discusiones anteriores y una revisión de la literatura, es importante destacar que existen trabajos en la literatura que investigan el uso de diferentes parámetros de las funciones de escalarización descritas para variar la presión de selección y tratar con diferentes tipos de problemas. Sin embargo, hasta donde sabemos no han sido explorados en el contexto del problema objeto de estudio (Pardo et al., 2024).

La principal contribución de este trabajo pasa por el estudio del tratamiento integrado y multicriterio del problema planteado y la comparación del desempeño de MOEA/D basado en descomposición, utilizando distintos métodos de escalarización para la obtención de las soluciones eficientes.

Se utiliza un abordaje de optimización multiobjetivo (MOO) para generar soluciones de Pareto óptimas, empleando un algoritmo evolutivo basados en descomposición, MOEA-D (Zhang & Li, 2007). Finalmente, el rendimiento de estos procedimientos se compara evaluando sus resultados mediante un conjunto de métricas al aplicarlos sobre instancias generadas con la metodología de referencia de Tsai et al. (2008).

La organización del presente artículo es la siguiente: en la Sección 2 se describe el problema y se realiza una revisión de la literatura relevante. Las Secciones 3 y 4 desarrolla la metodología. La Sección 6 incluye los experimentos computacionales llevados a cabo para resolver el problema, y en la Sección 7 se discuten los resultados obtenidos y se plantean posibles líneas de investigación futuras.

## 2. DESCRIPCIÓN DEL PROBLEMA

Este trabajo se centra en el análisis del desempeño de un algoritmo evolutivo aplicado al problema conocido como Joint Order Batching and Picker Routing Problem (JOBPRP). Es una variante biobjetivo de la formulación matemática del JOBPRP presentada en Kulak et al. (2012). Consiste en determinar de manera óptima la secuencia y composición de cada lote de picking, buscando simultáneamente dos objetivos: primero, minimizar el costo operativo total, directamente relacionado con el tiempo de picking; y segundo, equilibrar la carga de trabajo entre los equipos de picking. Las restricciones consideradas incluyen la capacidad de los equipos y el cumplimiento de los plazos máximos de despacho de cada pedido bajo diferentes configuraciones del layout de un centro de distribución.

El desafío de optimizar el proceso de preparación de pedidos minimizando tanto el tiempo como los recursos necesarios puede dividirse en tres subproblemas principales de planificación. El primero se refiere a cómo *asignar adecuadamente las ubicaciones* de almacenamiento para los artículos recibidos. El segundo abarca cómo *organizar los pedidos en lotes* de manera eficiente para facilitar el proceso de picking. El tercero se centra en la *secuenciación de la recolección*, de manera que los artículos sean entregados al área de expedición en tiempo y forma (Henn et al., 2012).

El primer subproblema, la asignación de almacenamiento, se relaciona con la planificación a mediano plazo y se considera parte de la planificación táctica. En cambio, los otros dos subproblemas, que son la consolidación de pedidos y la secuenciación de los preparadores, pertenecen al nivel operativo de la planificación. Este estudio pone énfasis en abordar integralmente los dos últimos problemas, cuyo tratamiento adecuado mejorará la eficiencia en las operaciones del almacén. Estas actividades constituyen una parte significativa de los costos operativos en un centro de distribución, debido a su alta demanda de equipo y mano de obra (Olmos et al., 2022).

En este contexto, el proceso de preparación de pedidos inicia con la recepción de órdenes de diversos clientes, donde cada pedido especifica las cantidades de los productos solicitados y los plazos de disponibilidad en la zona de envío. Un equipo de preparadores se encarga de extraer los productos correspondientes desde sus posiciones de almacenamiento. Cada equipo procesa un conjunto de artículos, que pueden pertenecer a múltiples pedidos (Ardjmand et al., 2018; Scholz et al., 2017). Los pedidos pequeños pueden completarse en un solo lote, lo que reduce los desplazamientos. Esto sugiere que los pedidos más grandes podrían dividirse en otros más pequeños para optimizar el tiempo del proceso de agrupamiento. Alternativamente, varios pedidos pequeños pueden consolidarse en uno más grande. En ambos casos, se requiere un enfoque integrado que permita reducir tanto los costos de recolección como los de picking, cumpliendo con las restricciones de tiempo establecidas para la entrega (Cergibozan & Tasan, 2019).

Este problema incluye dos desafíos de planificación NP-Hard: el agrupamiento de pedidos y la secuenciación de la recolección. El primero trata de determinar la mejor manera de agrupar pedidos dentro de las limitaciones

de capacidad y tiempo de entrega. El segundo implica encontrar la secuencia óptima para la recolección de artículos, minimizando la distancia recorrida y el tiempo de procesamiento, asegurando que cada ubicación de almacenamiento se visite una sola vez. La combinación de ambos desafíos será referida como JOBPRP en este documento (Kulak et al., 2012).

Diversos estudios han abordado estos problemas desde diferentes enfoques. Por ejemplo, algunos autores han aplicado métodos heurísticos para resolver el problema de agrupamiento de pedidos (Ho & Tseng, 2006), mientras que otros han utilizado algoritmos exactos (Diefenbach et al., 2022) y heurísticos para la optimización del picking (Henn et al., 2012). Los avances en esta área incluyen la aplicación de algoritmos genéticos (F. M. Miguel et al., 2024), búsqueda local iterada (Henn & Schmid, 2013) y métodos de optimización basados en lógica difusa (Lam et al., 2014), entre otros. También se ha investigado el uso de enfoques dinámicos para resolver el problema de secuenciación de recolección en situaciones complejas, como almacenes con múltiples niveles o dimensiones (Lu et al., 2016).

En cuanto a los criterios de optimización, estudios recientes han considerado no solo la distancia recorrida, sino también factores como el peso de los artículos (Ardjmand et al., 2020), tiempos de preparación y espera (Pan et al., 2012), así como el impacto físico en los recolectores (Battini et al., 2016). Además, se han propuesto modelos para minimizar los costos asociados al cumplimiento de pedidos en operaciones de comercio electrónico, considerando la conservación de productos perecederos y otras variables operativas. Estos desarrollos han demostrado ser cruciales para mejorar la eficiencia en la gestión de almacenes y centros de distribución (Vanheusden et al., 2023).

Finalmente, solo un par de autores han propuesto soluciones similares al problema integrado que se aborda en este trabajo, estudiando diferentes enfoques para minimizar la tardanza de los pedidos y mejorar la secuenciación en sistemas con múltiples recolectores. Una clasificación detallada de estos problemas se puede ver en (Pardo et al., 2024).

### 3. METODOLOGÍA

#### 3.1 Modelo utilizado para el JOBPRP

En este punto se presenta una variante de la formulación matemática del JOBPRP presentada en (Kulak et al., 2012) con dos objetivos basado en una formulación de programación no lineal de enteros mixtos que utiliza los siguientes conjuntos, parámetros y variables.

Conjuntos:

$o \in O$  Conjunto de órdenes o pedidos

$b \in B$  Conjunto de lotes o batches

$i, j \in \mathcal{L}$  Conjunto de posiciones de almacenamiento de artículos en pedidos

Parámetros:

- $D$  Matriz de distancias
- $p_{i,o}$  asume el valor 1 si la posición  $i$  está en la orden  $o$ .
- $v$  es la velocidad del equipo de picking.
- $t_{ij}$  es el tiempo de traslado entre la posición  $i$  y  $j$ .  $t_{ij} = D_{ij}/v$
- $w_o$  es el peso de la orden  $o$ .
- $C$  es la capacidad del preparador.
- $\zeta$  es el costo operativo por unidad de tiempo.
- $t_{pick}$  es el tiempo de picking por ítem.
- $q_o$  es la cantidad de ítems en la orden  $o$ .

Variables:

- $x_{o,b}$  Es 1 si la orden  $o$  está en el lote  $b$  y 0 en otro caso
- $y_{i,j,b}$  Es 1 si la posición  $i$  se visita inmediatamente antes de  $j$  en el lote  $b$  y 0 en otro caso.
- $z_{i,b}$  Es 1 si la posición  $i$  es visitada en la secuencia del lote  $b$ .

Modelo:

$$\min f_1: CT = \left[ \frac{\sum_{b \in B} \sum_{i \in \mathcal{L}} \sum_{j \in \mathcal{L}} D_{ij} \cdot y_{ijb}}{v} + \sum_{\substack{p \in \mathcal{P} \\ q \in \mathcal{Q}}} q_p \cdot t_{pick} \right] \cdot \zeta \quad (1)$$

$$\min f_2: \Delta W = STD \left[ \sum_{o \in O} w_o \cdot x_{o,b} \right] \quad \forall b \in B \quad (2)$$

s.a.:

$$\sum_{j \in V, j \neq i} y_{i,j,b} = z_{i,b} \quad \forall b \in B, i \in \mathcal{L} \quad (3)$$

$$\sum_{j \in V, i \neq j} y_{i,j,b} = z_{j,b} \quad \forall b \in B, j \in \mathcal{L} \quad (4)$$

$$\sum_{i \in S, j \in V \setminus S} y_{i,j,b} \geq z_{i,b} \quad \forall b \in B, S \subset \mathcal{L} \quad (5)$$

$$z_{i,b} \geq p_{i,o} \cdot x_{o,b} \quad \forall b \in B, i \in \mathcal{L}, o \in O \quad (6)$$

$$\sum_{b \in B} x_{o,b} = 1 \quad \forall o \in O \quad (7)$$

$$\sum_{o \in O} w_o \cdot x_{o,b} \leq C \quad \forall b \in B \quad (8)$$

$$\sum_{i \in \mathcal{L}} \sum_{j \in \mathcal{L}} t_{ij} \cdot y_{i,j,b} + \sum_{o \in O} q_o \cdot t_{pick} \leq dd_o \cdot x_{o,b} + M \cdot (1 - x_{o,b}) \quad \forall b \in B \quad (9)$$

$$x_{o,b}, y_{i,j,b}, x_{o,b} \in 0,1 \quad \forall i, j \in \mathcal{L}, o \in \mathcal{O}, b \in \mathcal{B} \quad (10)$$

La primera función objetivo (1), indica que el primer objetivo representa el costo operativo total del proceso de preparación, expresado en unidades monetarias, correspondiente a la recolección de lotes. El segundo objetivo (2) representa la variabilidad en la carga de trabajo de los preparadores. Los tiempos de viaje  $t_{ij}$  en la primera función objetivo se obtienen de la distancia entre posiciones y velocidad del preparador. Los conjuntos de restricciones (3) y (4) garantizan que cada ubicación tenga exactamente un predecesor y un sucesor, siempre que la ubicación sea visitada en el lote respectivo. El conjunto (5) representan las restricciones de eliminación de subtours del problema secuenciación, garantizan que las soluciones consistan en un solo recorrido que conecte todas las ubicaciones de un lote. El conjunto de restricciones (6) indica que si la posición  $i$  se encuentra en la orden  $o$  y la orden  $o$  se encuentra en el lote  $b$ , entonces la posición  $i$  debe tener su predecesor en el lote  $b$ . El conjunto de restricciones (7) aseguran que cada orden sea asignada a exactamente un lote. El conjunto de restricciones (8) garantizan que no se sobrepase la capacidad del preparador. El conjunto de restricciones (9) limita los retrasos. Finalmente, (10) define los dominios de las variables.

### 3.2 Método de resolución

En el contexto del problema de optimización multiobjetivo (POM) planteado, el decisor usualmente no busca tener un número excesivamente elevado de soluciones óptimas en el frente de Pareto (FP). En su lugar, se priorizan aquellas soluciones que sean representativas del frente, facilitando así la toma de decisiones. En este contexto, los algoritmos evolutivos multiobjetivo (MOEA) son muy utilizados, exhibiendo un rendimiento notable al resolver problemas de optimización difíciles (Coello Coello, 2006). Estos algoritmos no garantizan la determinación de los frentes Pareto-Óptimos exactos, pero sus resultados están muy cerca de las soluciones exactas.

En este trabajo se estudia la utilización de diferentes métodos de escalabilidad en un algoritmo evolutivo multiobjetivo para la obtención del frente de Pareto aproximado del problema objeto de estudio, el Algoritmo el Evolutivo Multiobjetivo basado en Descomposición (MOEA/D) (Q. Zhang & Li, 2007)

#### 3.2.1 MOEA/D:

El MOEA/D, descompone un problema de optimización multiobjetivo en un número finito de subproblemas de optimización escalar y los resuelve simultáneamente mediante la evolución de una población de soluciones. Para realizar la descomposición del problema se utilizan métodos de escalarización. Estos métodos de escalarización desempeñan un papel clave en el desempeño del algoritmo. Se ha descubierto que métodos como el método de Chebyshev (CHE), el método de *Penalized Boundary Intersection* (PBI) y el método

*Augmented Achievement Scalarizing* (AASF) son alternativas que se han demostrado eficaces en otros problemas de optimización multiobjetivo para lograr tanto la convergencia al frente de Pareto como una distribución uniforme de soluciones a lo largo del mismo (Pescador-Rojas & Coello, 2018)

Un proceso esencial al utilizar estos métodos, es la determinación de dos elementos: un vector de referencia (o vector de pesos) y un punto de referencia, que puede ser el origen o un punto específico del vector de referencia. Mediante estos elementos, estos métodos buscan identificar una solución en el PF que esté lo más próxima posible al punto ideal, siguiendo la dirección de su vector de referencia correspondiente.

Es necesario normalizar el espacio de los objetivos antes de realizar cualquier cálculo dado que los dos objetivos pueden tener escalas muy diferentes. En este trabajo se utilizará la normalización lineal (ecuación 11), ya que conserva las relaciones de dominancia entre los puntos del espacio.

$$f_i^{\text{norm}} = \frac{(f_i - f_{\min,i})}{(f_{\max,i} - f_{\min,i})} \quad i = 1, 2, \dots, M \quad (11)$$

donde  $f_{\min,i}$  y  $f_{\max,i}$  son los valores más bajos y más altos, respectivamente, del  $i$ -ésimo objetivo  $f_i$ , y  $M$  es la cantidad de objetivos.

La solución ideal,  $z^*$ , consistente en el mejor valor de cada objetivo, en el caso de un problema de optimización con dos objetivos a minimizar, se establece en  $(0,0)$  en el espacio de los objetivos normalizado. En adelante, se supone que siempre operamos en el espacio de los objetivos normalizado, por lo que al hablar de  $f_i$  se hace referencia a  $f_i^{\text{norm}}$ .

De esta manera, si se establece el punto de referencia  $z$  como la solución ideal, entonces tenemos  $z_1 = z_2 = 0$ . Respecto a la generación de vectores de peso en el presente trabajo generarán de forma uniforme mediante el método *Uniform Design* (Fang & Wang, 1993).

Los métodos de escalarización implementados en el MOEA/D son: *Tchebycheff* [TCH], *Augmented Achievement Scalarizing* [AASF] y *Penalty-Based Boundary Intersection* [PBI].

### 3.2.2 Tchebycheff (TCH):

El problema de Tchebycheff ponderado fue introducido por Bowman en 1976. La función se define en la ecuación 12.

$$\begin{aligned} \min: & \max_{1 \leq i \leq k} (w_i |f_i(\vec{x}) - z_i|) \\ \text{s. a.}: & \vec{x} \in S \end{aligned} \quad (12)$$

donde  $w$  es un vector de pesos,  $z$  es un punto de referencia,  $x$  es un vector de decisión,  $f(x)$  es la evaluación del MOP, y  $S$  es la región factible.

### 3.2.3 Augmented Achievement Scalarizing Function (ASF):

Las funciones de escalarización de logros fueron introducidas en



(Wierzbicki, 1980). Estas funciones se basan en la proyección de un punto de referencia arbitrario  $z \in R^k$  que implica niveles de aspiración deseables sobre el conjunto de soluciones óptimas de Pareto. De esta manera, soluciones óptimas de Pareto diferentes se pueden obtener con distintos puntos de referencia. En este método no se utiliza una métrica de distancia y el punto de referencia no debe ser fijado como el vector objetivo ideal. Esto permite obtener soluciones óptimas de Pareto independientemente de cómo se seleccione el punto de referencia en el espacio de objetivos.

Para un conjunto de funciones objetivo, la forma más usada para calcular ASF (Wierzbicki, 1980) se muestra en la ecuación 13.

$$\begin{aligned} \min: & \max_{1 \leq i \leq M} (w_i (f_i(\vec{x}) - z_i)) \\ \text{s. a.}: & \vec{x} \in S \end{aligned} \tag{13}$$

donde  $w$  es un vector de pesos,  $z$  es un punto de referencia,  $x$  es un vector de decisión,  $f(x)$  es la evaluación del MOP, y  $S$  es la región factible.

Este método creaba un escenario de clasificación potencialmente no deseado en los casos donde una solución domina débilmente a otra. Para evitar este problema en el manejo de puntos débilmente dominados, se propuso una versión aumentada del ASF (Miettinen, 1998). La AASF se calcula como se muestra en la siguiente ecuación, añadiendo un término a la función ASF original.  $\rho$  se toma como una constante.

$$\begin{aligned} \min: & \max_{1 \leq i \leq k} (w_i (f_i(\vec{x}) - z_i)) + \rho \sum_{i=1}^k w_i (f_i(\vec{x}) - z_i) \\ \text{s. a.}: & \vec{x} \in S \end{aligned} \tag{14}$$

donde  $w$  es un vector de pesos,  $z$  es un punto de referencia,  $x$  es un vector de decisión,  $f(x)$  es la evaluación del POM,  $\rho$  es el coeficiente de aumento y  $S$  es la región factible

### 3.2.4 Penalty-Based Boundary Intersection PBI:

El método de *intersección penalizada en el borde* (PBI) fue propuesto en (Zhang & Li, 2007) para usarla en el algoritmo evolutivo multiobjetivo basado en descomposición (MOEA/D). La función usa un conjunto de líneas que emergen del vector ideal  $z^*$ , permitiendo obtener las intersecciones con el FP. La función PBI se define en la siguiente ecuación.

El parámetro de penalización  $\theta$  es una entrada del usuario para cuantificar la penalización aplicada a la solución por la desalineación con respecto al vector de referencia. El PBI se calcula como se muestra en la ecuación 15.

$$\begin{aligned} \min: & d_1 + \theta \cdot d_2 \\ \text{s. a.}: & \vec{x} \in S \end{aligned} \tag{15}$$

donde,

$$d_1 = \frac{\|(\vec{f}(\vec{x}) - \vec{z}^*) \cdot \vec{w}\|}{\|\vec{w}\|}$$

$$d_2 = \|\vec{f}(\vec{x}) - (\vec{z}^* + d_1 \vec{w})\|$$

Donde  $w$  es un vector de pesos,  $x$  es un vector de decisión,  $f(x)$  es la evaluación del POM,  $\epsilon$  es un parámetro de penalización que debe ser mayor que 0, y  $S$  es la región factible. Sea  $L$  la línea con dirección  $w$  que pasa por  $z^*$ , e  $y$  la proyección de  $f(x)$  en  $L$ . Entonces,  $d_1$  es la distancia entre el punto de referencia  $z^*$  e  $y$ . Y  $d_2$  es la distancia entre  $f(x)$  y  $L$ .

En cuanto a la caracterización del algoritmo evolutivo multiobjetivo, se utiliza una representación basada en permutaciones de números enteros, común en la resolución de este tipo de problemas combinatorios. Cada cromosoma consta de dos genomas: el primero contiene la información sobre los artículos de cada lote, mientras que el segundo define la secuencia de selección de cada lote. Cada elemento del primer genoma indica a qué lote pertenece cada artículo, y cada elemento del segundo genoma representa la posición en la secuencia asignada al preparador a cada lote. La dimensión del primer genoma corresponde a la cantidad de órdenes, mientras que la del segundo está relacionada con el número de posiciones diferentes en la lista de órdenes. (Miguel et al., 2024).

En este trabajo, se utiliza como operador de cruce el *Two Point Crossover [SBX]* y como operador de mutación el *Polynomial Mutation (PM)*. Se utiliza un método híbrido constructivo basado en la heurística del  $k$ -vecino más cercano como métodos de mejora.

La satisfacción de las restricciones se asegura mediante los operadores genéticos y la representación adoptada. Para garantizar un nivel adecuado de diversidad inicial, la población es generada de manera aleatoria. El proceso concluye cuando se cumple un criterio de parada, el cual restringe el número máximo de iteraciones.

### 3.2.5 Medidas de rendimiento:

Aplicamos cuatro métricas para comparar el rendimiento de los procedimientos (Karimi et al., 2010; Zitzler et al., 2003):

**Distancia ideal media (MID):** Mide la cercanía entre el frente de Pareto y la solución ideal (0,0) como:

$$MID = \frac{\sum_{i=1}^n c_i}{n} \quad (16)$$

Donde,  $n$  es el número de soluciones no dominadas y  $c_i = \sqrt{f_{1i}^2 + f_{2i}^2}$  siendo  $f_{1i}$  y  $f_{2i}$  los valores de la primera y segunda funciones objetivo para la solución no dominada. Un valor más bajo de MID indica una mejor solución.

**Spread of non-dominance solution (SNS):** Es una medida de la diversidad de las soluciones de frontera de Pareto. Está dado por:

$$SNS = \sqrt{\frac{\sum_{i=1}^n (MID - c_i)^2}{n - 1}} \quad (17)$$

**Hipervolumen (HV):** mide el tamaño de la región dominada por el frente de Pareto (FP) y limitada por un punto de referencia dominado por el frente. Tiene en cuenta tanto la convergencia hacia el frente de Pareto como la distribución de soluciones:

$$HV = \left\{ \left\{ \bigcup_{i=1}^n A(x_i) : \forall x_i \in P \right\} \right\} \quad (18)$$

donde  $x_i$  es una solución en el FP,  $n$  es el número de soluciones no dominadas en FP, y  $A(x_i)$  es el área rectangular entre los puntos  $x_i$  y un punto de referencia. Si el frente de Pareto  $FP_A$  es una mejor aproximación del frente real que el frente de Pareto  $FP_B$ , entonces  $HV(FP_A) > HV(FP_B)$

## 4. EXPERIMENTACIÓN Y RESULTADOS

### 4.1 Conjuntos de datos y configuración de parámetros

Para estudiar el desempeño del MOEA/D con los tres métodos de escalarización descriptos en el contexto del JOBPRP bi-objetivo, se generan seis tamaños de instancias. Chicas, medianas y grandes, con 2 y 3 dimensiones, siguiendo la metodología propuesta por Tsai et al. (2008).

Cada pedido tiene una fecha de entrega distribuida uniformemente dentro del rango de tiempo desde las 10:00 a.m. hasta las 6:00 p.m.

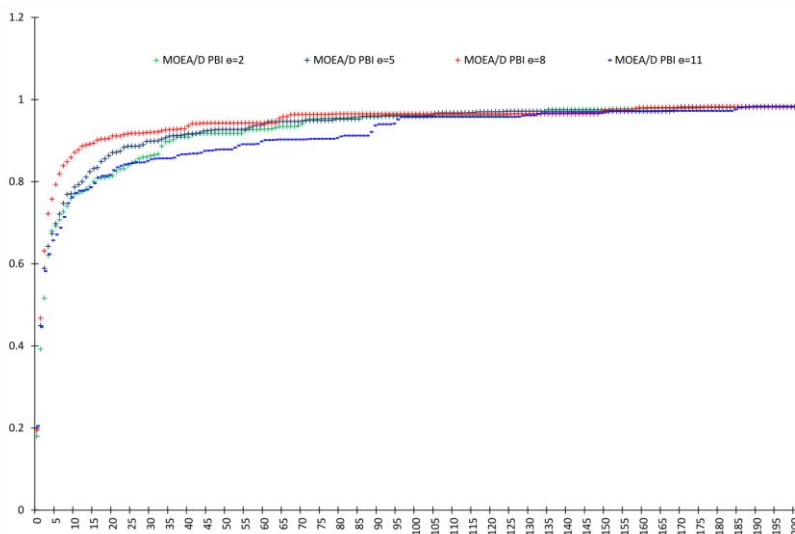
La distribución uniforme U(1,10) describe las cantidades requeridas  $q$  de un artículo  $p$  por un cliente  $i$ . La distribución de probabilidad del número de artículos distintos por pedido sigue una distribución normal, con una media de 10 artículos distintos por pedido y una desviación estándar de cinco artículos por pedido. Cada artículo tiene un peso unitario distribuido uniformemente entre 8 y 24 kg. También suponemos una velocidad promedio de 2 m/s, un tiempo medio de recolección de cualquier artículo de 15 s, un costo de viaje por unidad de tiempo 0.05, y una capacidad dependiente de la instancia.

En primer lugar, se llevan a cabo procedimientos estándar de ajuste de hiperparámetros. Las evaluaciones de rendimiento de los algoritmos se llevaron a cabo en términos de las métricas descritas, seguidas de la selección de configuraciones que arrojaron los resultados más favorables. Así, el número máximo de generaciones es 200, el tamaño de la población es 100, la probabilidad de mutación es 0.02, y la probabilidad de cruce es 0.8. Cada método se ejecuta 10 veces y cada ejecución es independiente de las otras. Cada instancia de prueba seleccionada de Tsai et al. (2008) se corre bajo las mismas condiciones iniciales, comenzando con una población generada aleatoriamente.

## 4.2 Experimentos numéricos

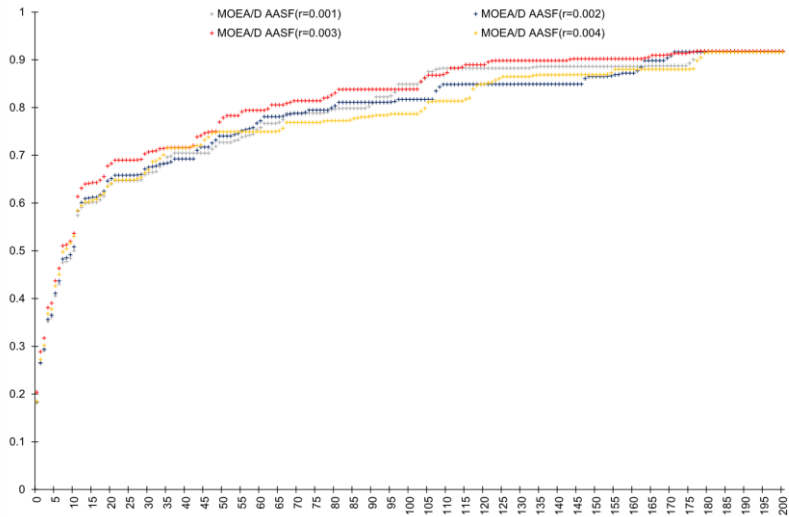
Primero se explora la configuración adecuada de parámetros para los métodos de escalarización PBI y AASF. Cabe destacar que el nivel habitualmente recomendado de  $\epsilon$  es 5 para el método PBI y para AASF, un  $\rho$  de  $10^{10}$ .

Para ello se realizaron para cada instancia, 10 corridas de 200 generaciones del algoritmo MOEA/D con escalarización por PBI para cada  $\epsilon$  en un rango de  $\epsilon$  entre 1 y 14. A continuación se presenta los resultados en términos del hipervolumen para cuatro niveles de ese rango. En la **FIGURA 1** puede verse que el algoritmo converge más rápido en términos de hipervolumen medio normalizado para un nivel del parámetro de penalización de  $\epsilon=8$ .



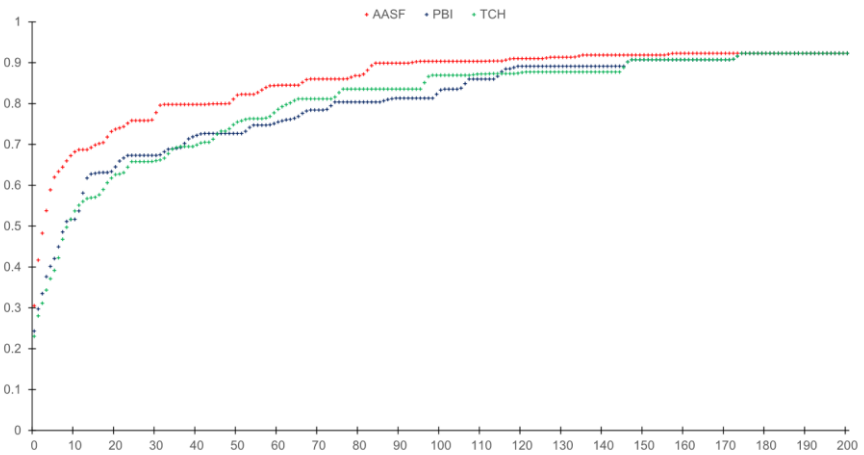
**FIGURA 1.** Evolución del hipervolumen para diferentes parámetros de penalización utilizando PBI como método de escalarización.

En la **FIGURA 2** se observa que el algoritmo converge más rápido en términos de hipervolumen medio normalizado para un nivel del coeficiente de aumento de  $\rho=0.003$ .



**FIGURA 2.** Evolución del hipervolumen para diferentes coeficientes de aumento utilizando AASF como método de escalarización.

A partir de los resultados anteriores, se compara el desempeño en términos de hipervolumen del algoritmo con los tres métodos de escalarización estudiados con las mejores configuraciones de parámetros logradas (FIGURA 3).



**FIGURA 3.** Evolución del hipervolumen para diferentes coeficientes de aumento utilizando AASF como método de escalarización.

En la TABLA 1 se presentan los resultados del desempeño del MOEA/D para todas las métricas de desempeño.

DB1	SNS	HV	MID
Mejor	0.0143	0.8245	0.3805
Mediana	0.0314	0.8004	0.6595
Des.Std	0.0091	0.0197	0.1509

(a)

DB2	SNS	HV	MID
Mejor	0.0147	0.8965	0.7246
Mediana	0.0313	0.8669	1.1783
Des.Std	0.0235	0.0109	0.3527

(c)

DB3	SNS	HV	MID
Mejor	0.0110	0.9184	0.9546
Mediana	0.0153	0.9181	1.2359
Des.Std	0.0137	0.0068	0.2115

(e)

DB4	SNS	HV	MID
Mejor	0.0132	0.8232	0.6340
Mediana	0.0556	0.8344	0.8823
Des.Std	0.0506	0.0172	0.1367

(b)

DB5	SNS	HV	MID
Mejor	0.0121	0.8875	0.3805
Mediana	0.0136	0.8730	0.6127
Des.Std	0.0086	0.0004	0.2884

(d)

DB6	SNS	HV	MID
Mejor	0.0430	0.8101	2.6452
Mediana	0.0510	0.7713	5.5535
Des.Std	0.0120	0.0345	1.5920

(f)

**TABLA 1.** Métricas MOEA/D-AASF( $r=0.003$ ) de las instancias MB1 a MB6.

De los resultados obtenidos en términos de hipervolumen, se observa un mejor desempeño para instancias bidimensionales que en las que consideran almacenamiento en tres dimensiones. Respecto al nivel de dispersión no se observan diferencias significativas. Finalmente, cabe destacar que los tiempos de ejecución estuvieron entre 800 s para instancias chicas y 2400 s para instancias grandes.

## 5. CONCLUSIONES

Nuestros resultados preliminares dan lugar a algunas observaciones interesantes respecto a la forma en que se comporta el desempeño de los optimizadores en este problema en función de la configuración de los parámetros de los métodos de escalarización.

En primer lugar, MOEA/D es capaz de encontrar frentes diversificados en este tipo de problemas. En segundo lugar, son relevantes las diferencias en el desempeño de MOEA/D según el método de escalarización utilizado en el ámbito de este problema. En este sentido el método de escalarización AASF, le permite converger más rápidamente al algoritmo en comparación con los otros métodos.

El MOEA/D ha tenido mejor desempeño en instancias bidimensionales en comparación con las que consideran almacenamiento en tres dimensiones.

Como trabajo futuro, y considerando los resultados obtenidos en la presente investigación, consideraremos la implementación de otros operadores genéticos en el MOEA/D, que permitan explorar mejor el espacio de soluciones en el contexto de este tipo de problemas.

## 6. AGRADECIMIENTOS

Los autores expresan su agradecimiento por el financiamiento proporcionado por la Universidad Nacional de Río Negro para el proyecto PI UNRN 40-A-1108, así como a la Secretaría General de Ciencia y Tecnología de la Universidad Nacional del Sur por el apoyo a los proyectos PGI 24/ZJ50 y 24/J086.

## 7. REFERENCIAS

- Ardjmand, E., Shakeri, H., Singh, M., & Sanei Bajgiran, O. (2018). Minimizing order picking makespan with multiple pickers in a wave picking warehouse. *International Journal of Production Economics*, 206, 169-183.  
<https://doi.org/10.1016/j.ijpe.2018.10.001>
- Ardjmand, E., Youssef, E. M., Moyer, A., Young, W. A., Weckman, G. R., & Shakeri, H. (2020). A multi-objective model for minimising makespan and total travel time in put wall-based picking systems. *International Journal of Logistics Systems and Management*, 36(1), 138-176.  
<https://doi.org/10.1504/IJLSM.2020.107230>
- Battini, D., Glock, C. H., Grosse, E. H., Persona, A., & Sgarbossa, F. (2016). Human energy expenditure in order picking storage assignment: A bi-objective method. *Computers & Industrial Engineering*, 94, 147-157.  
<https://doi.org/10.1016/j.cie.2016.01.020>
- Cergibozan, Ç., & Tasan, A. S. (2019). Order batching operations: An overview of classification, solution techniques, and future research. *Journal of Intelligent Manufacturing*, 30(1), 335-349.  
<https://doi.org/10.1007/s10845-016-1248-4>
- Chen, M.-C., & Wu, H.-P. (2005). An association-based clustering approach to order batching considering customer demand patterns. *Omega*, 33(4), 333-343.  
<https://doi.org/10.1016/j.omega.2004.05.003>
- Coello Coello, C. A. (2006). Evolutionary multi-objective optimization: A historical view of the field. *IEEE Computational Intelligence Magazine*, 1(1), 28-36. *IEEE Computational Intelligence Magazine*.  
<https://doi.org/10.1109/MCI.2006.1597059>
- De Koster, M. B. M., Van der Poort, E. S., & Wolters, M. (1999). Efficient orderbatching methods in warehouses. *International Journal of Production Research*, 37(7), 1479-1504.  
<https://doi.org/10.1080/002075499191094>
- de Koster, R., Le-Duc, T., & Roodbergen, K. J. (2007). Design and control of

- warehouse order picking: A literature review. *European Journal of Operational Research*, 182(2), 481-501.  
<https://doi.org/10.1016/j.ejor.2006.07.009>
- Diefenbach, H., Emde, S., Glock, C. H., & Grosse, E. H. (2022). New solution procedures for the order picker routing problem in U-shaped pick areas with a movable depot. *OR Spectrum*, 44(2), 535-573.  
<https://doi.org/10.1007/s00291-021-00663-8>
- Fang, K.-T., & Wang, Y. (1993). *Number-theoretic methods in statistics* (Vol. 51). CRC Press.
- Grosse, E. H., & Glock, C. H. (2015). The effect of worker learning on manual order picking processes. *International Journal of Production Economics*, 170, 882-890.  
<https://doi.org/10.1016/j.ijpe.2014.12.018>
- Grosse, E. H., Glock, C. H., & Neumann, W. P. (2017). Human factors in order picking: A content analysis of the literature. *International Journal of Production Research*, 55(5), 1260-1276.  
<https://doi.org/10.1080/00207543.2016.1186296>
- Henn, S., Koch, S., & Wäscher, G. (2012). Order Batching in Order Picking Warehouses: A Survey of Solution Approaches. En R. Manzini (Ed.), *Warehousing in the Global Supply Chain: Advanced Models, Tools and Applications for Storage Systems* (pp. 105-137). Springer.  
[https://doi.org/10.1007/978-1-4471-2274-6\\_6](https://doi.org/10.1007/978-1-4471-2274-6_6)
- Henn, S., & Schmid, V. (2013). Metaheuristics for order batching and sequencing in manual order picking systems. *Computers & Industrial Engineering*, 66(2), 338-351.  
<https://doi.org/10.1016/j.cie.2013.07.003>
- Ho, Y.-C., & Tseng, Y.-Y. (2006). A study on order-batching methods of order-picking in a distribution centre with two cross-aisles. *International Journal of Production Research*, 44(17), 3391-3417.  
<https://doi.org/10.1080/00207540600558015>
- Hofmann, F. M., & Visagie, S. E. (2021). The Effect of Order Batching on a Cyclical Order Picking System. En M. Mes, E. Lalla-Ruiz, & S. Voß (Eds.), *Computational Logistics* (pp. 252-268). Springer International Publishing. [https://doi.org/10.1007/978-3-030-87672-2\\_17](https://doi.org/10.1007/978-3-030-87672-2_17)
- Karimi, N., Zandieh, M., & Karamooz, H. R. (2010). Bi-objective group scheduling in hybrid flexible flowshop: A multi-phase approach. *Expert Systems with Applications*, 37(6), 4024-4032.  
<https://doi.org/10.1016/j.eswa.2009.09.005>
- Kulak, O., Sahin, Y., & Taner, M. E. (2012). Joint order batching and picker routing in single and multiple-cross-aisle warehouses using cluster-



- based tabu search algorithms. *Flexible Services and Manufacturing Journal*, 24(1), 52-80. <https://doi.org/10.1007/s10696-011-9101-8>
- Lam, C. H. Y., Choy, K. L., Ho, G. T. S., & Lee, C. K. M. (2014). An order-picking operations system for managing the batching activities in a warehouse. *International Journal of Systems Science*, 45(6), 1283-1295. <https://doi.org/10.1080/00207721.2012.761461>
- Miettinen, K. (1998). *Nonlinear Multiobjective Optimization* (Vol. 12). Springer US. <https://doi.org/10.1007/978-1-4615-5563-6>
- Miguel, F., Frutos, M., Tohmé, F., & Rossit, D. (2019). A memetic algorithm for the integral OBP/OPP problem in a logistics distribution center. *Uncertain Supply Chain Management*, 7(2), 203-214.
- Miguel, F. M., Frutos, M., Méndez, M., & Tohmé, F. (2021). Solving Order Batching/Picking Problems with an Evolutionary Algorithm. En D. A. Rossit, F. Tohmé, & G. Mejía Delgadillo (Eds.), *Production Research* (pp. 177-186). Springer International Publishing. [https://doi.org/10.1007/978-3-030-76307-7\\_14](https://doi.org/10.1007/978-3-030-76307-7_14)
- Miguel, F. M., Frutos, M., Méndez, M., Tohmé, F., & González, B. (2024). Comparison of MOEAs in an Optimization-Decision Methodology for a Joint Order Batching and Picking System. *Mathematics*, 12(8), Article 8. <https://doi.org/10.3390/math12081246>
- Miguel, F. M., Frutos, M., Méndez, M., Tohmé, F., Miguel, F. M., Frutos, M., Méndez, M., & Tohmé, F. (2022). Order batching and order picking with 3D positioning of the articles: Solution through a hybrid evolutionary algorithm. *Mathematical Biosciences and Engineering*, 19(6), Article mbe-19-06-259. <https://doi.org/10.3934/mbe.2022259>
- Olmos, J., Florencia, R., García, V., González, M. V., Rivera, G., & Sánchez-Solís, P. (2022). Metaheuristics for Order Picking Optimisation: A Comparison Among Three Swarm-Intelligence Algorithms. En A. Ochoa-Zezzatti, D. Oliva, & A. E. Hassanien (Eds.), *Technological and Industrial Applications Associated With Industry 4.0* (pp. 177-194). Springer International Publishing. [https://doi.org/10.1007/978-3-030-68663-5\\_13](https://doi.org/10.1007/978-3-030-68663-5_13)
- Pan, J. C.-H., Shih, P.-H., & Wu, M.-H. (2012). Storage assignment problem with travel distance and blocking considerations for a picker-to-part order picking system. *Computers & Industrial Engineering*, 62(2), 527-535. <https://doi.org/10.1016/j.cie.2011.11.001>
- Pardo, E. G., Gil-Borrás, S., Alonso-Ayuso, A., & Duarte, A. (2024). Order batching problems: Taxonomy and literature review. *European Journal*

- of Operational Research*, 313(1), 1-24.  
<https://doi.org/10.1016/j.ejor.2023.02.019>
- Pescador-Rojas, M., & Coello, C. A. C. (2018). Collaborative and Adaptive Strategies of Different Scalarizing Functions in MOEA/D. *2018 IEEE Congress on Evolutionary Computation (CEC)*, 1-8.  
<https://doi.org/10.1109/CEC.2018.8477815>
- Sancaklı, E., Dumlupınar, İ., Akçın, A. O., Çınar, E., Geylani, İ., & Düzgüt, Z. (2022). Design of a Routing Algorithm for Efficient Order Picking in a Non-traditional Rectangular Warehouse Layout. En N. M. Durakbasa & M. G. Gençyılmaz (Eds.), *Digitizing Production Systems* (pp. 401-412). Springer International Publishing. [https://doi.org/10.1007/978-3-030-90421-0\\_33](https://doi.org/10.1007/978-3-030-90421-0_33)
- Scholz, A., Schubert, D., & Wäscher, G. (2017). Order picking with multiple pickers and due dates – Simultaneous solution of Order Batching, Batch Assignment and Sequencing, and Picker Routing Problems. *European Journal of Operational Research*, 263(2), 461-478.  
<https://doi.org/10.1016/j.ejor.2017.04.038>
- Ten Hompel, M., & Schmidt, T. (2007). *Warehouse Management*. Springer.  
<https://doi.org/10.1007/978-3-540-35220-4>
- Tsai, C.-Y., Liou, J. J. H., & Huang, T.-M. (2008). Using a multiple-GA method to solve the batch picking problem: Considering travel distance and order due time. *International Journal of Production Research*, 46(22), 6533-6555.  
<https://doi.org/10.1080/00207540701441947>
- van Gils, T., Ramaekers, K., Braekers, K., Depaire, B., & Caris, A. (2018). Increasing order picking efficiency by integrating storage, batching, zone picking, and routing policy decisions. *International Journal of Production Economics*, 197, 243-261.  
<https://doi.org/10.1016/j.ijpe.2017.11.021>
- Vanheusden, S., Gils, T. van, Ramaekers, K., Cornelissens, T., & Caris, A. (2023). Practical factors in order picking planning: State-of-the-art classification and review. *International Journal of Production Research*.  
<https://doi.org/10.1080/00207543.2022.2053223>
- Wierzbicki, A. P. (1980). The Use of Reference Objectives in Multiobjective Optimization. En G. Fandel & T. Gal (Eds.), *Multiple Criteria Decision Making Theory and Application* (pp. 468-486). Springer.  
[https://doi.org/10.1007/978-3-642-48782-8\\_32](https://doi.org/10.1007/978-3-642-48782-8_32)
- Zhang, J., Wang, X., Chan, F. T. S., & Ruan, J. (2017). On-line order batching and sequencing problem with multiple pickers: A hybrid rule-based algorithm. *Applied Mathematical Modelling*, 45, 271-284.

<https://doi.org/10.1016/j.apm.2016.12.012>

- Zhang, Q., & Li, H. (2007). MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition. *IEEE Transactions on Evolutionary Computation*, 11(6), 712-731. IEEE Transactions on Evolutionary Computation.  
<https://doi.org/10.1109/TEVC.2007.892759>
- Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C. M., & da Fonseca, V. G. (2003). Performance assessment of multiobjective optimizers: An analysis and review. *IEEE Transactions on Evolutionary Computation*, 7(2), 117-132. IEEE Transactions on Evolutionary Computation.  
<https://doi.org/10.1109/TEVC.2003.810758>
- Žulj, I., Glock, C. H., Grosse, E. H., & Schneider, M. (2018). Picker routing and storage-assignment strategies for precedence-constrained order picking. *Computers & Industrial Engineering*, 123, 338-347.  
<https://doi.org/10.1016/j.cie.2018.06.015>