Información Tecnológica
Vol. 32(3), 121-130 (2021)
<http://dx.doi.org/10.4067/S0718-07642021000300121>

Optimización por colonia de hormigas para el ruteo de la preparación de pedidos en almacenes de múltiples bloques

Jose A. Cano^{1*}, Emiro A. Campo², Alexander A. Correa-Espinal³ y Rodrigo A. Gómez-Montoya^{2,4}

(1) Facultad de Ciencias Económicas y Administrativas, Universidad de Medellín, Cra. 87 # 30-65, Medellín – Colombia.

(2) Escuela Superior en Administración de Cadena de Suministro, Calle 4 # 18-55, Medellín – Colombia.

(3) Facultad de Minas, Universidad Nacional de Colombia, Av. 80 # 65 - 223, Medellín – Colombia.

(4) Facultad de Administración, Politécnico Colombiano Jaime Isaza Cadavid, Cra. 48 # 7-15, Medellín – Colombia.

(Correo-e: jacano@udem.edu.co; eacampo@unal.edu.co; alcorrea@unal.edu.co; ragomez@elpoli.edu.co)

* Autor a quien debe ser dirigida la correspondencia

Recibido Nov. 19, 2020; Aceptado Ene. 13, 2021; Versión final Ene. 30, 2021, Publicado Jun. 2021

Resumen

Este artículo tiene como objetivo minimizar la distancia total recorrida para la preparación de pedidos (PRP), considerando almacenes 2D de múltiples bloques. La PRP se encarga de planificar la forma como se visitarán las diferentes posiciones de almacenamiento para satisfacer los requerimientos de cada orden del cliente. Para esto, aquí se formulan las distancias mínimas entre cada par de posiciones de almacenamiento a visitar en un tour. Se propone un algoritmo de optimización por colonia de hormigas (ACO, en inglés), al cual se le ajustan parámetros para garantizar un mejor desempeño. Con base en experimentos computacionales, se establece que el ACO propuesto brinda soluciones de alta calidad y genera ahorros satisfactorios frente a una metaheurística y dos heurísticas, requiriendo tiempos de computación viables para ambientes de simulación y ambientes de operación real de almacenes y centros de distribución. Se concluye que el algoritmo ACO propuesto para solucionar la PRP genera soluciones de alta calidad en tiempos de computación razonables.

Palabras clave: preparación; pedidos; ACO; ruteo; almacenes multibloque; metaheurística

Ant colony optimization for picker routing in multiple block warehouses

Abstract

This study aims to minimize the total traveled distance for the picker routing problem (PRP) by assessing 2D multi-block warehouses. The PRP is responsible for planning tours to visit different storage positions to satisfy the requirements of each customer order. Therefore, the minimum distances between each pair of storage locations to visit on a tour are formulated. An ant colony optimization (ACO) algorithm is proposed and adjusted to improve performance. Based on computational experiments, it is established that the proposed ACO provides high-quality solutions. It also generates satisfactory savings when compared to a metaheuristic and to two widely used heuristics, requiring viable computing times for simulation environments and real warehouse operation environments. It is concluded that the proposed ACO algorithm for PRPs provides high-quality solutions within reasonable computational time.

Keywords: order picking; ACO; routing; multi-block warehouses; metaheuristics

INTRODUCCIÓN

Los almacenes y centros de distribución (CEDIS) son componentes esenciales para la gestión de la cadena de suministro y la logística debido a que afectan significativamente el cumplimiento de tiempos, servicio al cliente, los costos y la eficiencia de toda la cadena de suministro (Chen et al. 2015; Cano et al. 2018; Henríquez-Fuentes et al. 2018). Dentro de las operaciones de los almacenes y CEDIS, la preparación de pedidos (*picking*) es la más costosa al representar 50%–70% del costo operativo total de un almacén (De Koster et al. 2007), debido a que es una operación altamente repetitiva e intensa en el uso de mano de obra en sistemas de preparación de pedidos manuales, denominados también como sistemas *picker-to-parts* (Grosse et al. 2017).

En los sistemas de preparación de pedidos manuales, los operarios de preparación de pedidos recorren los pasillos de un almacén, ya sea caminando o utilizando un vehículo, con el fin de recuperar los productos de las posiciones de almacenamiento para satisfacer las órdenes de los clientes (Gómez et al. 2016; Zhang et al. 2019). En consecuencia, es prioritario mejorar el desempeño de la preparación de pedidos tanto en empresas tradicionales o compañías de comercio electrónico B2C (empresa-a-consumidor), especialmente a través de la minimización de distancias y tiempos de recorrido (Scholz y Wäscher 2017), debido a que representan más del 50% del costo de la preparación de pedidos (De Koster et al. 2007), y aproximadamente el 90% del tiempo total de la preparación de pedidos (Li et al. 2017).

Dentro de las configuraciones de los almacenes, la consideración de múltiples pasillos transversales permite aumentar la eficiencia de los recorridos de la preparación de pedidos (Roodbergen y De Koster 2001), disminuyendo la distancia recorrida necesaria para cambiar de un pasillo a otro. Estas configuraciones de almacenes dividen los almacenes en múltiples bloques, y requieren del desarrollo o adaptación de métodos de solución para brindar soluciones de alta calidad en tiempos cortos de computación. Por su naturaleza, el problema del ruteo de la preparación de pedidos en sistemas low-level picker-to-parts (almacenes 2D) se clasifica como un Steiner TSP, donde algunos nodos no tienen que ser visitados y otros nodos pueden ser visitados más de una vez (De Koster et al. 2007). Por lo tanto, el PRP se considera NP-hard (Fu et al. 2011), requiriendo de métodos de solución eficientes tales como las metaheurísticas poblacionales (Damayanti et al. 2018), entre las cuales se pueden mencionar la optimización de colonia de hormigas y algoritmos genéticos (Jiménez-Carrión 2018), que no garantizan la obtención de un óptimo global, pero permiten encontrar una solución o un conjunto de soluciones de alta calidad (López-Lezama, 2015).

Para solucionar el PRP, se destaca en la literatura el uso de la optimización de colonia de hormigas (ACO) por brindar ahorros en distancia recorrida respecto a métodos empíricos empresariales (Xu et al. 2014), presentar mejor desempeño respecto a políticas de ruteo como la S-Shape, Largest Gap y Combine (Fu et al. 2011; Chen et al. 2013, 2016), generar menor tiempo de preparación de pedidos respecto al PSO (Wang et al. 2012) y algoritmos genéticos (Jin et al. 2017), y ofrecer buenos resultados comparados con problemas óptimos de programación lineal entera mixta. Otras técnicas inteligentes como el recocido simulado (Grosse et al., 2014) y búsqueda tabú (Liu et al. 2017) se han empleado para solucionar el PRP, sin embargo, el ACO prevalece como la mejor alternativa debido a su enfoque constructivista dedicado a la creación de caminos más cortos (Chen et al. 2019).

Entre los estudios que más se destacan para solucionar el PRP a través del ACO en almacenes 2D de múltiples bloques, se destacan los aportes de Chen et al. (2013), Chen et al. (2016), y Chen et al. (2019) que consideran congestión en pasillos, apoyándose para el cálculo del tiempo y distancia de recorrido de preparación de pedidos, sin embargo, estos estudios no modelan las distancias entre cada par de posiciones de almacenamiento que pertenecen a un mismo bloque o a múltiples bloques, por lo cual no se garantiza que el tiempo y distancia de recorrido entre cualquier par de posiciones a visitar en un tour sea mínima. Respecto al estudio de De Santis et al. (2018), quienes presentan ACO adaptado con el algoritmo Floyd–Warshall, el presente estudio ofrece una formulación de distancia de recorrido adaptada para configuraciones de almacenes de múltiples bloques 2D.

Por lo tanto, este estudio tiene como objetivo solucionar el PRP para almacenes 2D de múltiples bloques a través de un ACO, con el fin de brindar soluciones de alta calidad en tiempos cortos de cómputo, generando así un algoritmo que brinde soluciones satisfactorias en calidad de la solución y en tiempos de computación. Para esto, en la Sección 2 se presentan los supuestos y la formulación del PRP a abordar. La Sección 3 introduce el algoritmo propuesto. El ajuste de parámetros del ACO y la planificación de experimentos se detalla en la Sección 4. En la Sección 5 se presentan los resultados de los experimentos, y la Sección 6 reúne las principales conclusiones de este estudio.

OTROS ANTECEDENTES

El PRP para almacenes 2D, al clasificarse como un Steiner TSP, puede formularse como un TSP clásico si se calculan previamente las distancias mínimas entre cada par de ubicaciones de almacenamiento i y j (d_{ij}), lo cual

se puede lograr a través de matrices de distancia entre todas las posiciones de almacenamiento (Cano et al. 2017). Para esto, dadas dos posiciones de almacenamiento $i=(x_i, y_i)$ y $j=(x_j, y_j)$, la coordenada y de la parte trasera del bloque al que pertenecen i y j se representan respectivamente por B^i y B^j , y la coordenada y de la parte frontal del bloque al que pertenecen i y j se representan respectivamente F^i y F^j . La Figura 1, muestra el diseño de un almacén 2D de 3 bloques, ilustrando las posiciones de almacenamiento i y j , y las coordenadas que representan la parte trasera y frontal del bloque al que pertenece cada posición de almacenamiento, es decir, $(0, B^i)$ y $(0, F^i)$ para i , y $(0, B^j)$ y $(0, F^j)$ para j .

Fig.1: Diseño de un almacén 2D de múltiples bloques.

De esta forma, la distancia de Manhattan d_{ij} entre i y j tal que $1 \leq i, j \leq L$ se calcula a través de la Ecuación (1) cuando i y j pertenecen al mismo pasillo y bloque. La Ecuación (1) igualmente se utiliza cuando i y j pertenecen a diferentes bloques, indiferente del pasillo en que se encuentren. Cuando i y j pertenecen a diferentes pasillos en el mismo bloque, es decir $F^i=F^j=F$ y $B^i=B^j=B$, la Ecuación (2) se emplea, garantizando las distancias mínimas entre i y j .

$$d_{ij} = |x_i - x_j| + |y_i - y_j| \quad (1)$$

$$d_{ij} = |x_i - x_j| + \min\{|y_i - T| + |T - y_j|, |y_i - F| + |F - y_j|\} \quad (2)$$

A través de la Ecuación (1) y Ecuación (2) se puede realizar el cálculo de la matriz de distancias mínimas para cada par de posiciones de almacenamiento i y j . Adicionalmente, se consideran los siguientes supuestos para el PRP en almacenes 2D de múltiples bloques: 1) todos los recorridos inician y terminan en un mismo punto denominado *Depot*; 2) los ítems almacenados en diferentes posiciones de almacenamiento se considerarán como diferentes ítems; 3) los operarios de preparación de pedidos pueden atravesar los pasillos en ambas direcciones; 4) el sistema de preparación de pedidos valida que los ítems a recoger en un recorrido no superan la capacidad de carga del vehículo de preparación de pedidos; y 5) no se considera congestión dentro de los pasillos del almacén.

$$\text{Min } Z = \sum_{b \in B} \sum_{i \neq j \in L} \sum_{j \neq i \in L} d_{ij} * Y_{ij} \quad (3)$$

$$\sum_{j \in L, j \neq i} Y_{ij} = Z_i \quad \forall b \in B, i \in L \quad (4)$$

$$\sum_{i \in L, i \neq j} Y_{ij} = Z_j \quad \forall b \in B, j \in L \quad (5)$$

$$\sum_{i \in S, j \in L \setminus S} Y_{ij} \geq Z_i \quad \forall b \in B, S \subset L \quad (6)$$

$$Y_{ij}, Z_i \in \{0,1\} \quad \forall i, j \in L \quad (7)$$

La función objetivo (3) minimiza la distancia total recorrida. Las restricciones (4) y (5) aseguran que cada posición de almacenamiento pueda visitarse a lo sumo una vez en cada ruta, y garantizan solo un predecesor y sucesor a cada posición de almacenamiento. Las restricciones (6) evitan cualquier sub-tour para que las soluciones representen un solo tour. La Ecuación (7) define las restricciones de dominio de las variables.

METODOLOGÍA

A pesar que muchas metaheurísticas se han presentado en la literatura, la optimización por colonia de hormigas (ACO) es la metaheurística más popular para solucionar el PRP (Chen et al. 2019), y brinda mejor desempeño que otras metaheurísticas para diferentes tipo de TSP (De Santis et al. 2018). El ACO se caracteriza por ser una metaheurística constructivista que genera soluciones a medida en que el algoritmo avanza, brindando en cada iteración un número de soluciones igual al número de hormigas considerado, y dichas hormigas se guían bajo un proceso de retroalimentación y sinergia (Colomi et al. 1991; Dorigo et al. 1996). Por un lado, el sistema de hormigas promueve la explotación al aumentar la traza de feromona en los caminos más cortos, aumentando la probabilidad de elegir caminos que previamente fueron elegidos por hormigas en iteraciones anteriores (Chen et al. 2016); y esto se refuerza al evaporarse la traza de feromona de forma proporcional a la longitud de las rutas, eliminando así la aceptación por parte de las hormigas de tomar rutas largas, e incrementando la preferencia de tomar rutas más cortas. Por otro lado, se promueve la exploración cuando algunas hormigas seleccionan caminos con menor traza de feromona, permitiendo encontrar caminos que se acerquen a la solución global (Dorigo et al. 2006).

El ACO fue diseñado para solucionar el TSP con el fin de encontrar una longitud cíclica mínima para visitar un nodo cada vez, dado un conjunto de n nodos, donde d_{ij} representa la distancia entre el nodo i y el nodo j , y $\eta_{ij}=1/d_{ij}$ representa la visibilidad del arco ij , que permite elegir con mayor probabilidad al arco ij que tengan mayor visibilidad. Al inicio del ACO, todos los arcos ij tienen la misma cantidad de feromona $\tau_{ij}=\tau_0$ y se lanzan K hormigas a recorrer la red de nodos, partiendo del nodo origen (*Depot*). Cada hormiga busca su propio recorrido, de tal forma que cada hormiga k al estar en un nodo i elige pasar a otro nodo j según una probabilidad definida P_{kij} , que depende de la distancia d_{ij} y de la cantidad de feromona presente en el arco ij (τ_{ij}). Por lo tanto, la Ecuación (8) determina que la probabilidad de selección del arco ij es proporcional a la visibilidad del mismo, y se selecciona con mayor frecuencia los arcos que conectan posiciones de almacenamiento más cercanas en distancia o tiempo.

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha \cdot [\eta_{ij}]^\beta}{\sum_{u \in M_k} [\tau_{iu}(t)]^\alpha \cdot [\eta_{iu}]^\beta} & \text{si } j \notin M_k \\ 0 & \text{en otro caso} \end{cases} \quad (8)$$

De esta forma, el ACO brinda memoria a cada hormiga (M_k) a través de una lista tabú que guarda los nodos que ha visitado la hormiga k y prohíbe volver a estos nodos hasta que se completa un viaje, garantizando siempre soluciones factibles. El parámetro α representa la importancia o influencia de la traza de feromona, que al variar puede enfocar al algoritmo hacia la exploración o explotación, de tal forma que si $\alpha > 0$, a mayor α de genera mayor explotación en la búsqueda, y si $\alpha = 0$ entonces no se toma en cuenta la feromona. El parámetro β determina la influencia de la visibilidad, e igualmente al variar puede cambiar de un enfoque de exploración a uno de explotación, de tal forma que si $\beta = 0$ solo se considera la feromona para el cálculo de P_{kij} , haciendo que todas las hormigas tiendan a construir la misma solución (explotación) dando lugar a convergencias prematuras. Por otro lado, si $\alpha > \beta$ se prioriza la información aprendida en el proceso de constructivismo, y si $\alpha < \beta$ el ACO se aproxima a un constructivismo puro.

Se termina un ciclo en el algoritmo cuando todas las hormigas han realizado un recorrido completo, y luego de esto se calcula la longitud $L = \min\{L_k\}_{k \in K}$ y la visibilidad $\eta = 1/L$ del camino más corto encontrado entre todas las hormigas. Con esta información se actualiza el valor de la feromona τ_{ij} en cada arco ij al reducir dichos valores a través de la evaporación de feromona que se muestra en la Ecuación (9), y al aumentar la cantidad de feromona de los arcos que componen la ruta más corta encontrada entre todas las hormigas, tal y como se muestra en la Ecuación (10). Se destaca que en la Ecuación (9) y Ecuación (10), el parámetro ρ representa la tasa de evaporación de feromona y toma valores tales que $0 \leq \rho \leq 1$. Este parámetro evita la acumulación ilimitada de la traza de feromona en los arcos trazados por las primeras hormigas que entraron al sistema, favoreciendo la exploración de nuevas áreas del espacio de búsqueda. Igualmente, la Ecuación (10) realiza una actualización global de feromona que agrega feromona sólo a los arcos de la mejor ruta con el fin de mejorar el enfoque de explotación. El enfoque de optimización global refuerza el hecho de que si una hormiga tiene éxito al explorar una ruta, esta marca con feromona la ruta más corta encontrada para que dicha ruta sea seguida por otras hormigas, mientras que en los caminos menos eficientes se disipa lentamente el rastro de feromona. El parámetro Q es una constante que permite controlar la proporción de la feromona a adicionar.

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) \quad (9)$$

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \rho Q \eta \quad (10)$$

Luego de completar un ciclo en el que todas las hormigas han construido una ruta factible, el proceso del algoritmo se repite hasta alcanzar el máximo número de iteraciones planificadas o hasta llegar a una convergencia del algoritmo.

RESULTADOS Y DISCUSIÓN

En esta sección se presenta el ajuste de parámetros del ACO, para garantizar un mejor desempeño del algoritmo para solucionar el PRP. Igualmente, se presentan las diferentes instancias experimentales que permiten analizar el desempeño del ACO ante diferentes escenarios de simulación, y frente a métodos de comparación para el ruteo en almacenes 2D de múltiples bloques.

Ajuste de parámetros del ACO

En la Tabla 1 se presentan diferentes valores de parámetros del ACO propuestos en la literatura para solucionar el PRP, los cuales se utilizarán como base para el ajuste de parámetro del algoritmo propuesto. A estos valores, se agregan $\rho=0.7$ para ampliar las opciones del parámetro de la tasa de evaporación de feromona. Para la constante Q , se decide tomar por defecto el valor de $Q=1$ utilizado por (Wang et al. 2012). Por lo tanto, se obtienen un total de $2 \times 3 \times 2 \times 2 = 24$ escenarios que corresponden a $(\alpha, \beta) \times \rho \times K \times \text{iteraciones}$, y en cada escenario se ejecutan 10 réplicas, generando así 240 corridas experimentales.

Tabla 1: Valores para los experimentos del ajuste de parámetros

Parámetros	Valores	Autor
α, β	(1, 2)	(Fu et al. 2011; Wang et al. 2012)
	(1, 5)	(Chen et al. 2016, 2019; Jin et al. 2017; Li et al. 2017; De Santis et al. 2018)
ρ	0.5	(Chen et al. 2015; Li et al. 2017)
	0.7	Valor a analizar en este estudio
	0.9	(Fu et al. 2011; Wang et al. 2012; De Santis et al. 2018)
K	20	(Fu et al. 2011; Chen et al. 2015)
	30	(Wang et al. 2012; Chen et al. 2016; Jin et al. 2017)
Iteraciones	30	(Fu et al. 2011)
	50	(Wang et al. 2012; Chen et al. 2015)
Q	1	(Wang et al. 2012)

La configuración del almacén para el ajuste de parámetros consiste en 2 boques, 10 pasillos, 15 posiciones de almacenamiento por pasillo, para un total de 600 posiciones de almacenamiento; y se consideran 20 posiciones de almacenamiento a visitar en cada tour. De los experimentos de ajuste de parámetros, se obtiene que la mayor diferencia en distancia se logra al variar los parámetros α y β , ya que la combinación $(\alpha=1, \beta=2)$ genera 19% más distancia que la combinación $(\alpha=1, \beta=5)$. Al calcular los valores promedio de distancia recorrida y tiempo de computación para las instancias con diferentes valores de feromona ρ , no se observan diferencias relevantes en distancia y tiempos de computación. Respecto al número de hormigas (K), el promedio de distancia recorrida con 20 y 30 hormigas es de 262,2 y 260,2 respectivamente, mientras que el tiempo de computación es de 3,9 y 6,0 en promedio; y al variar el número de iteraciones de 30 a 50, la distancia recorrida solo disminuye en 0,2%, mientras que el tiempo de computación aumenta en 69%. Por lo tanto, es más recomendable parametrizar el ACO con 20 hormigas y 30 iteraciones, obteniendo un desempeño similar en la distancia recorrida, y obteniendo ahorros significativos en tiempos de computación. De esta forma, los valores parámetros sugeridos para el ACO propuesto son $\alpha=1$, $\beta=5$, $\rho=0,7$, $k=20$, $\text{iter}=30$, garantizando un mejor desempeño en distancia recorrida y menores tiempos de computación para el algoritmo.

Igualmente, se identificaron los valores más apropiados para la feromona inicial, con el fin de obtener mejores resultados en el menor número posible de iteraciones. Para esto, se testearon los valores de $\tau_0=0$, $\tau_0=0,1$, $\tau_0=0,5$, $\tau_0=1$, $\tau_0=10$, y $\tau_0=\eta_{ij}$ para el arco i,j , ejecutando el algoritmo ACO 20 veces para cada valor de τ_0 . Como resultado se obtiene que el peor desempeño del ACO se presenta cuando $\tau_0 = 0$, generando a su vez convergencia prematura en la primera iteración en todas las instancias evaluadas. Por otro lado, el mejor desempeño del ACO se presenta cuando $\tau_0=\tau_{ij}(0)=\eta_{ij}$, lo cual se debe a que al inicio del algoritmo los arcos con menor distancia tendrán un mayor rastro de feromona, haciendo que las hormigas tiendan a elegir los arcos más cortos en la construcción de la ruta de preparación de pedidos. Del mismo modo, cuando se considera $\tau_0=\eta_{ij}$, se requiere un número de iteraciones que varía entre 1 y 9, lo cual permite establecer el parámetro con el cual se activará el operador de cataclismo, que corresponde en este caso a 10 iteraciones consecutivas sin obtener mejoras en la solución global. El operador de cataclismo se utiliza para mejorar la eficiencia del ACO y evitar óptimos locales, de tal forma que, si la solución global del algoritmo no mejora luego de un número determinado de ciclos, la traza de feromona se reinicia la feromona y se le asigna el valor inicial establecido en el algoritmo (Chen et al. 2013).

Experimentos computacionales

Una vez establecidos los parámetros del ACO, se planifican los experimentos para establecer el desempeño del algoritmo bajo diferentes escenarios de operación, y frente a la distancia recorrida que ofrecen otros métodos de ruteo de la preparación de pedidos que se utilizarán como métodos de comparación. La Tabla 4 presenta los parámetros de operación determinados por el número de posiciones de almacenamiento a visitar en un tour, el número de pasillos del almacén, número de posiciones de almacenamiento por lado de cada pasillo, y el número de bloques del almacén. El número de instancias experimentales es igual a $3 \times 3 \times 3 \times 2 = 54$ escenarios, y en cada escenario se corrieron 10 réplicas del ACO, para un total de 540 corridas experimentales. Se aclara que se crean instancias propias de experimentación, debido a que instancias conocidas como las de (Valle et al. 2020) ofrecen instancias experimentales para almacenes con dos bloques y tres pasillos transversales, pero no para almacenes de tres bloques y cuatro pasillo transversales, tal y como se requiere para este estudio.

Tabla 2: Parámetros operativos para la medición de desempeño del ACO

Parámetro	Valores
Posiciones de almacenamiento a visitar	10, 20, 30
Número de pasillos	5, 10, 20
Posiciones de almacenamiento por lado del pasillo	5, 10, 20
Bloques	2, 3

El desempeño del ACO se compara con la heurística de ruteo S-shape y Aisle-by-Aisle para múltiples bloques, y con el algoritmo genético (AG) propuesto por (Cano et al. 2019) debido a que se tiene acceso al código de dicho algoritmo. Se aclara que las heurísticas de ruteo S-shape y Aisle-by-Aisle para múltiples bloques siguen un patrón de ruteo establecido, el cual es independiente de parámetros, tal y como sucede con reglas de prioridad aplicados a problemas combinatoriales (Castrillón et al. 2018). Respecto a los parámetros del AG utilizado para comparar el desempeño del ACO propuesto, estos corresponden a los propuestos por Cano et al (2019). Del AG se omite el uso de la búsqueda local para establecer el efecto generado por la metaheurística poblacional, y establecer así la eficiencia entre la naturaleza del ACO y el GA para solucionar el PRP bajo igualdad de condiciones. La Ecuación (11) se utiliza para calcular el ahorro en distancia recorrida brindado por el ACO respecto a los métodos de comparación, donde $F.O_{Comparación}$ representa el valor de la función objetivo obtenido con los métodos de comparación, y $F.O_{ACO}$ el valor de la función objetivo brindado por el ACO para el PRP. Los algoritmos propuestos se implementaron en Visual Basic Applications, y los experimentos se ejecutaron en un PC (CPU Intel Core i5-2300 2.8 GHz, 8 GB RAM).

$$\text{Ahorro en la } F.O \text{ (\%)} = \frac{F.O_{Comparación} - F.O_{ACO}}{F.O_{Comparación}} \times 100 \quad (11)$$

Con base en los experimentos realizados, la Tabla 5 presenta los ahorros promedios en distancia recorrida ofrecidos por el ACO frente a los métodos de comparación propuestos. En este sentido, el ACO ofrece ahorros en promedio del 7,7%, 15,1%, y 22,8% frente al AG, S-shape y Aisle-by-Aisle respectivamente. Igualmente, se identifica que el ACO ofrece ahorros de hasta el 21,0% frente al AG cuando se consideran 3 bloques, 20 pasillos, 20 posiciones por lado del pasillo, y 30 posiciones de almacenamiento a visitar. Respecto al S-shape, el ACO brinda ahorros de hasta el 36,1% para escenarios con 3 bloques, 20 pasillos, 10 posiciones por lado del pasillo, y 20 posiciones de almacenamiento a visitar. Por otro lado, el ACO genera ahorros de hasta el 43,6% frente al Aisle-by-Aisle para escenarios considerando 3 bloques, 5 pasillos, 10 posiciones por lado del pasillo, y 10 posiciones de almacenamiento a visitar.

Tabla 3: Ahorros del ACO en distancia total recorrida

Medida	Ahorros AG	Ahorros S-shape	Ahorros Aisle-by-Aisle
Máximo	21,0%	36,1%	43,6%
Promedio	7,7%	15,1%	22,8%
Mínimo	0,4%	2,0%	2,2%

En la Figura 3 se observa que el ahorro del ACO en distancia recorrida frente al Aisle-by-Aisle y S-shape incrementa a medida en que se requiere visitar un menor porcentaje de las posiciones del almacén en un tour (posiciones a visitar / posiciones de almacenamiento), lo cual implica la generación de rutas de preparación de pedidos más inteligentes por parte del ACO, evitando en ocasiones atravesar completamente cada pasillo del almacén tal y como lo sugieren los métodos de comparación mencionados. Respecto a los ahorros del ACO frente al AG de Cano et al. (2019), se evidencia una tendencia de obtener mayores ahorros cuando aumenta el porcentaje de posiciones del almacén a visitar, lo cual exige visitar la mayoría o totalidad de los pasillos y bloques del almacén, y exige la exploración de un mayor número de combinaciones y rutas posibles para visitar todas las posiciones de almacenamiento requeridas.

Fig. 2: Ahorro promedio del ACO según el porcentaje de posiciones del almacén a visitar.

El efecto del número de bloques sobre el desempeño del ACO se ilustra en la Figura 4, identificando que a mayor número de bloques se obtiene mayores ahorros por parte del ACO frente al AG, S-shape y Aisle-by-Aisle, demostrando la eficiencia del algoritmo propuesto para almacenes de múltiples bloques. Incluso, al pasar de 2 a 3 bloques, el ACO aumenta 2,7 veces el ahorro frente al AG, aumenta 1,9 veces frente al S-shape y 1,6 veces frente al Aisle-by-Aisle. Para validar la significancia de los resultados obtenidos, se aplica una prueba t de Student con la cual se identifica que la media de la distancia recorrida del ACO es significativamente menor (a un nivel de confianza del 95%, valor- $p < 0.05$) a la media brindada por la heurística S-shape y Aisle-by-Aisle, lo cual va en línea con los mayores ahorros en distancia recorrida identificados previamente. Al comparar la media del ACO con la media del GA no se obtienen diferencias significativas a un nivel de confianza del 95%, lo cual representa que ambos métodos son eficientes para solucionar el PRP, sin embargo, se recomienda el uso del ACO al brindar frente al GA ahorros en distancia recorrida de hasta el 21%.

Fig. 3: Ahorro promedio del ACO según el número de bloques.

En cuanto al tiempo de cómputo, la Figura 4 muestra que el ACO requiere de mayor tiempo para encontrar soluciones respecto a lo requerido por el AG. Estos valores son de esperarse, debido a que se ha probado en otros estudios que el ACO induce mayores tiempos de computación que los algoritmos genéticos (Li et al. 2017), debido a su enfoque constructivista que hace que el tiempo de computación en cada iteración se prolongue (Jin et al. 2017). Sin embargo, los tiempos de cómputo obtenidos son viables en entornos de simulación y aplicables a futuros escenarios reales, requiriendo hasta 12,9 segundos para sugerir una ruta de preparación de pedidos que ofrece en promedio un ahorro entre el 7,7% y 22,8% según el método de comparación con el que se desee contrastar. Igualmente, se identifica en la Figura 4 que a medida en que aumenta el número de posiciones a visitar en una ruta, aumenta de forma exponencial el tiempo de cómputo para el ACO. Incluso, en experimentos adicionales en almacenes de 2 y 3 bloques considerando 40 y 50 posiciones a visitar, se generó un tiempo de computación promedio de 33,7 y 71,4 segundos respectivamente por ruta, lo cual sigue representando tiempos de computación razonables para ambientes operacionales en almacenes y centros de distribución. Sin embargo, en la práctica es poco recurrente rutas que requieran visitar más de 30 posiciones de almacenamiento debido a las restricciones de capacidad que presentan los vehículos de preparación de pedidos, ya sea a nivel de volumen, peso y arrume.

En resumen, los resultados resaltan el buen desempeño del ACO para solucionar el PRP en almacenes 2D de múltiples bloques, ofreciendo ahorros satisfactorios frente a metaheurísticas ampliamente utilizadas en otros estudios, tales como los algoritmos genéticos, y frente a heurísticas utilizadas por su facilidad de entendimiento y ejecución tales como la S-shape y Aisle-by-Aisle. Estos resultados se obtienen en tiempos de computación viables y factibles a nivel de simulación, y compatibles con los requerimientos de los ambientes reales de almacenes y centros de distribución.

Fig. 4: Tiempo de cómputo del ACO y AG según el número de posiciones a visitar.

DISCUSIÓN FINAL

Este artículo propone un algoritmo de optimización por colonia de hormigas (ACO) para minimizar la distancia recorrida en almacenes 2D multibloque, considerando una formulación de distancias mínimas entre cada par de posiciones de almacenamiento para solucionar el problema del ruteo de la preparación de pedidos (PRP) como un Steiner TSP. A través del uso de probabilidades para elegir pasar de un nodo a otro, actualización de feromona en cada arco, y la aplicación del operador de cataclismo, se logra el desarrollo de un algoritmo con enfoque constructivista capaz de brindar soluciones satisfactorias al problema abordado.

Los experimentos de simulación permitieron ajustar los parámetros más relevantes del ACO, de tal forma que arrojaran los menores valores de distancia recorrida en los escenarios propuestos, y permitieron igualmente generar ahorros satisfactorios en distancia recorrida frente a una metaheurística y dos heurísticas de amplio uso para solucionar el PRP. Los resultados demostraron que el ACO presenta mejor desempeño respecto al AG cuando aumenta el número de posiciones a visitar respecto al tamaño del almacén, y ofrece mejor desempeño respecto a la S-shape y Aisle-by-Aisle cuando disminuye el número de posiciones a visitar respecto al tamaño del almacén. Del mismo modo, el ACO brinda mejor desempeño respecto a los métodos de comparación considerados cuando aumenta el número de bloques, argumentando así su pertinencia de utilizarse como método de solución del PRP en almacenes con múltiples bloques.

De esta forma, el ACO propuesto puede mejorar el desempeño de las operaciones de preparación de pedidos en almacenes y centros de distribución, brindando soluciones satisfactorias para la distancia recorrida, y en tiempo de cómputo viables para entornos operativos. Futuros trabajos pueden enfocarse en reducir el tiempo de cómputo del ACO, lo cual involucra el análisis de las compensaciones entre la calidad de la solución y eficiencia computacional al disminuir el número de iteraciones y hormigas. Del mismo modo, este estudio puede extenderse al integrar métodos de búsqueda local para refinar la solución global del ACO, e integrar el ACO a algoritmos que solucionen problemas de conformación de lotes, secuenciación y asignación de lotes a operarios de preparación de pedidos.

CONCLUSIONES

De acuerdo con el trabajo presentado y a los resultados obtenidos, se pueden plantear las siguientes conclusiones principales: 1.- El algoritmo ACO propuesto para solucionar el PRP genera soluciones de alta calidad en tiempos de computación razonables, demostrando su eficiencia para ambientes de almacenes 2D de múltiples bloques frente a heurísticas y metaheurísticas ampliamente utilizadas; 2.- El ajuste de parámetros utilizado para el ACO permite ofrecer una metaheurística de alto desempeño, que adapta el valor de parámetros a las condiciones específicas del PRP de almacenes 2D de múltiples bloques, y sirve como referencia para futuros trabajos que requieran la adaptación de metaheurísticas a problemas combinatoriales; y 3.- Este estudio permite mejorar el desempeño de las operaciones de preparación de pedidos en almacenes y centros de distribución, y sirve como base para integraciones de otros problemas como la conformación de lotes, secuenciación y asignación de lotes a operarios.

REFERENCIAS

- Cano, J. A., Correa-Espinal, A. A., y Gómez-Montoya, R. A., An evaluation of picking routing policies to improve warehouse efficiency, *Int. J. Ind. Eng. Manag.*, 8(4), 229–238 (2017).
- Cano, J. A., Correa-Espinal, A. A., Gómez-Montoya, R. A., y Cortés, P., Genetic algorithms for the picker routing problem in multi-block warehouses; in *Lecture Notes in Business Information Processing*, Springer by W. Abramowicz y R. Corchuelo, Vol. 353, pp. 313–322, Cham, Switzerland (2019).
- Cano, J. A., Correa-Espinal, A., y Gómez-Montoya, R. A., Solución del problema de conformación de lotes en almacenes utilizando algoritmos genéticos, <https://doi.org/10.4067/S0718-07642018000600235>, *Inf. Tecnol.*, 29(6), 235–244 (2018).
- Castrillón, O. D., Sarache, W., y Ruiz, S., Desempeño de técnicas tradicionales de programación de la producción frente a un algoritmo evolutivo, <https://doi.org/10.4067/S0718-07642018000200141>, *Inf. Tecnol.*, 29(2), 141–154 (2018).
- Chen, F., Wang, H., Qi, C., y Xie, Y., An ant colony optimization routing algorithm for two order pickers with congestion consideration, <https://doi.org/10.1016/j.cie.2013.06.013>, *Comput. Ind. Eng.*, 66(1), 77–85 (2013).
- Chen, F., Wang, H., Xie, Y., y Qi, C., An ACO-based online routing method for multiple order pickers with congestion consideration in warehouse, <https://doi.org/10.1007/s10845-014-0871-1>, *J. Intell. Manuf.*, 27(2), 389–408 (2016).
- Chen, F., Xu, G., y Wei, Y., An integrated metaheuristic routing method for multiple-block warehouses with ultranarrow aisles and access restriction, <https://doi.org/10.1155/2019/1280285>, *Complexity*, 2019, 1–14 (2019).
- Chen, T. L., Cheng, C. Y., Chen, Y. Y., y Chan, L. K., An efficient hybrid algorithm for integrated order batching, sequencing and routing problem, <https://doi.org/10.1016/j.jipe.2014.09.029>, *Int. J. Prod. Econ.*, 159, 158–167 (2015).
- Colomi, A., Dorigo, M., y Maniezzo, V., Distributed optimization by ant colonies; in *Proceedings of the 1991 European conference on artificial life (ECAL '91)*, pp. 134–142, (1991).
- Damayanti, D. D., Setyawan, E. B., Andrawina, L., y Santosa, B., Warehouse picking model for single picker routing problem in multi dimensional warehouse layout using genetic algorithm approach to minimize delay, https://doi.org/10.1007/978-3-319-72550-5_13, *Adv. Intell. Syst. Comput.*, 700(1), 124–134 (2018).
- De Koster, R., Le-Duc, T., y Roodbergen, K. J., Design and control of warehouse order picking: A literature review, <https://doi.org/10.1016/j.ejor.2006.07.009>, *Eur. J. Oper. Res.*, 182(2), 481–501 (2007).
- De Santis, R., Montanari, R., Vignali, G., y Bottani, E., An adapted ant colony optimization algorithm for the minimization of the travel distance of pickers in manual warehouses, <https://doi.org/10.1016/j.ejor.2017.11.017>, *Eur. J. Oper. Res.*, 267(1), 120–137 (2018).
- Dorigo, M., Birattari, M., y Stützle, T., Ant colony optimization: Artificial ants as a computational intelligence technique, *IEEE Comput. Intell. Mag.*, 1, 28–39 (2006).
- Dorigo, M., Maniezzo, V., y Colomi, A., Ant system: Optimization by a colony of cooperating agents, <https://doi.org/10.1109/3477.484436>, *IEEE Trans. Syst. Man, Cybern. - Part B Cybern.*, 26(1), 29–41 (1996).
- Fu, C., Wang, Y. y otros tres autores, Routing optimization of high-level orderpickers in a rectangular warehouse; in *2011 International Conference on Consumer Electronics, Communications and Networks, CECNet 2011 – Proceedings*, pp. 4388–4391, XianNing, <https://doi.org/10.1109/CECNET.2011.5768920>, (2011).
- Gómez, R. A., Giraldo, O. G., y Campo, E. A., Conformación de lotes mínimo tiempo en la operación de acomodo considerando k equipos homogéneos usando metaheurísticos, <https://doi.org/10.4067/S0718-07642016000600006>, *Inf. Tecnol.*, 27(6), 53–62 (2016).
- Grosse, E. H., Glock, C. H., y Ballester-Ripoll, R., A simulated annealing approach for the joint order batching and order picker routing problem with weight restrictions, *Int. J. Oper. Quant. Manag.*, 20(2), 65–83 (2014).
- Grosse, E. H., Glock, C. H., y Neumann, W. P., Human factors in order picking: a content analysis of the literature, <https://doi.org/10.1080/00207543.2016.1186296>, *Int. J. Prod. Res.*, 55(5), 1260–1276 (2017).
- Henríquez-Fuentes, G. R., Cardona, D. A., Rada-Llanos, J. A., y Robles, N. R., Medición de tiempos en un sistema de distribución bajo un estudio de métodos y tiempos, <https://doi.org/10.4067/S0718-07642018000600277>, *Inf. Tecnol.*, 29(6), 277–286 (2018).
- Jiménez-Carrión, M., Algoritmo genético simple para resolver el problema de programación de la tienda de trabajo (job shop scheduling), <https://doi.org/10.4067/S0718-07642018000500299>, *Inf. Tecnol.*, 29(5), 299–314 (2018).
- Jin, H., Wang, W., Cai, M., Wang, G., y Yun, C., Ant colony optimization model with characterization-based speed and multi-driver for the refilling system in hospital, <https://doi.org/10.1177/1687814017713700>, *Adv. Mech. Eng.*, 9(8), 1–18 (2017).
- Li, J., Huang, R., y Dai, J. B., Joint optimisation of order batching and picker routing in the online retailer's warehouse in China, <https://doi.org/10.1080/00207543.2016.1187313>, *Int. J. Prod. Res.*, 55(2), 447–461 (2017).
- Liu, L., Li, K., y Liu, Z., A capacitated vehicle routing problem with order available time in e-commerce industry, <https://doi.org/10.1080/0305215X.2016.1188092>, *Eng. Optim.*, 49(3), 449–465 (2017).

- López-Lezama, J. M., Villada, F., y Muñoz, N., Metaheurísticas aplicadas a la ubicación y dimensionamiento óptimo de generación distribuida en sistemas de distribución de energía eléctrica, <https://doi.org/10.4067/S0718-07642015000400018>, Inf. Tecnol., 26(4), 145–158 (2015).
- Roodbergen, K. J., y De Koster, R., Routing methods for warehouses with multiple cross aisles, <https://doi.org/10.1080/00207540110028128>, Int. J. Prod. Res., 39(9), 1865–1883 (2001).
- Scholz, A., y Wäscher, G., Order Batching and Picker Routing in manual order picking systems: the benefits of integrated routing, <https://doi.org/10.1007/s10100-017-0467-x>, Cent. Eur. J. Oper. Res., 25(2), 491–520 (2017).
- Valle, C. A., Beasley, J. E., y da Cunha, A. S., Test instances for order picking problems. Retrieved October 22, 2020, from <https://homepages.dcc.ufmg.br> (2020).
- Wang, Y., Fu, C., Ma, M., y Wang, L., Routing optimization of high-level order picking truck based on swarm intelligent algorithm, <https://doi.org/10.4028/www.scientific.net/AMM.101-102.414>, Appl. Mech. Mater., 101–102, 414–417 (2012).
- Xu, W., Shi, C. Y., Song, H. T., y Chen, Y. X., Applied technology on improving the order picking efficiency in the area of EC of china post logistics based on ACO, <https://doi.org/10.4028/www.scientific.net/AMR.859.486>, Adv. Mater. Res., 859, 486–491 (2014).
- Zhang, R., Wang, M., y Pan, X., New model of the storage location assignment problem considering demand correlation pattern, <https://doi.org/10.1016/j.cie.2019.01.027>, Comput. Ind. Eng., 129, 210–219 (2019).