

基于改进多目标蜣螂优化算法的生鲜多温共配路径优化研究

李昕鹏¹, 刘勤明^{1*}, 倪静然², 叶春明¹, 汪宇杰¹

¹上海理工大学管理学院, 上海

²北部湾大学东密歇根联合工程学院, 广西 钦州

收稿日期: 2024年12月15日; 录用日期: 2025年1月8日; 发布日期: 2025年1月16日

摘要

考虑到生鲜配送场景下消费者需求零散化、个性化和及时性的特点, 本文开展了生鲜多温共配路径问题研究。首先, 基于客户对生鲜配送时间是否及时准确的敏感程度, 引入时间抵制度模型, 构建以运输成本最小、客户时间抵制度最小为目标的生鲜多温共配路径多目标优化模型。其次, 针对蜣螂优化算法的改进, 设计了一种以tent混沌映射与逆向学习策略生成初始种群, 在蜣螂觅食阶段引入自适应步长策略与凸透镜成像策略, 滚球阶段引入曲线自适应黄金正弦策略的多策略改进的多目标蜣螂优化算法用于模型求解。最后, 通过算例分析验证模型和算法的有效性, 与未改进的多目标蜣螂优化算法进行对比, 验证了改进多目标蜣螂优化算法性能的优越性。

关键词

多温共配, 蜣螂优化算法, 多目标优化模型, 路径优化, 生鲜物流

Research on Optimization of Fresh Produce Multi-Temperature Joint Distribution Path Based on Improved Multi-Objective Dung Beetle Optimization Algorithm

Xinpeng Li¹, Qinming Liu^{1*}, Jingran Ni², Chunming Ye¹, Yujie Wang¹

¹Business School, University of Shanghai for Science and Technology, Shanghai

²Eastern Michigan Joint College of Engineering, Beibu Gulf University, Qinzhou Guangxi

Received: Dec. 15th, 2024; accepted: Jan. 8th, 2025; published: Jan. 16th, 2025

*通讯作者。

文章引用: 李昕鹏, 刘勤明, 倪静然, 叶春明, 汪宇杰. 基于改进多目标蜣螂优化算法的生鲜多温共配路径优化研究[J]. 建模与仿真, 2025, 14(1): 509-524. DOI: 10.12677/mos.2025.141048

Abstract

Considering the characteristics of decentralized, personalized, and timely consumer demand in the context of fresh produce delivery, this paper investigates the multi-temperature joint distribution path problem for fresh produce. Firstly, based on customers' sensitivity to the timeliness and accuracy of fresh produce delivery, a time resistance model is introduced. A multi-objective optimization model for the multi-temperature joint distribution path of fresh produce is constructed with the objectives of minimizing transportation costs and customer time resistance. Secondly, for the improvement of the dung beetle optimization algorithm, a multi-strategy improved multi-objective dung beetle optimization algorithm is designed. This algorithm generates an initial population using tent chaotic mapping and inverse learning strategy, introduces an adaptive step size strategy and a convex lens imaging strategy in the dung beetle foraging phase, and incorporates a curve adaptive golden sine strategy in the rolling phase for model solving. Finally, through case analysis, the effectiveness of the model and algorithm is verified. Compared with the unimproved multi-objective dung beetle optimization algorithm, the superiority of the improved multi-objective dung beetle optimization algorithm's performance is validated.

Keywords

Multi-Temperature Joint Distribution, Dung Beetle Optimization Algorithm, Multi-Objective Optimization Model, Path Optimization, Fresh Produce Logistics

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

生鲜冷链物流因其高碳排放的特点而备受关注,研究表明,物流运输产生的碳排放是全球温室气体排放的重要来源,占全球物流运输温室气体排放总量的 14% [1]。因此,重点研究能源消耗更少的蓄冷式多温共配问题具有重要的现实意义。同时,在生鲜配送新业态消费场景下,为满足消费者需求的碎片化、个性化和及时性,可以采用具有隔间的多车厢配送车辆完成配送任务,不仅可以降低配送成本,还增加了运输路径决策的灵活性。

在考虑传统的多隔间车辆路径问题方面,已有国内外学者对其做了大量的研究。Kaabi [2]开发了一种基于遗传算法和迭代局部搜索方法的混合方法来求解 MCVRPWTW 问题。Sun 等[3]针对成品油配送问题,通过优化经济行驶距离来综合解决车辆配置、运输路径和装载决策。在考虑冷链生鲜多温共配物流车辆配送方面,Cho [4]等总结了台湾地区蓄冷式多温共配模式的实践经验,论述了该模式的可行性。王淑云等[5]通过构建蓄冷式多温共配模型,并与传统单品温配送模式进行比较,论证了蓄冷式多温共配的经济性。Hsu [6]等利用层级辐射式网络结构,建立了以总物流配送成本最小的多温共配路径模型,并通过数值实验证明了多温共配模式的适用性。牟进进[7]等从服务创新的角度,论述了蓄冷式多温共配系统的价值创造过程。戴夏静和梁承姬[8]以最小总成本为优化目标,研究了在时间窗约束下的蓄冷式多温共配优化模型。Hsiao 等[9]研究了温度对生鲜产品质量的影响,并建立了多温共配车辆配送路径问题的数学模型。

在算法求解方面,任腾等[10]将禁忌搜索算子和动态概率选择的知识模型融合,并以此设计了一种基

于知识模型指导的蚁群算法。李春发等[11]通过引入双曲正切函数改进蚁群算法,实现了参数的动态调整,增强了算法的全局搜索能力和收敛速度。Sbai 等[12]提出了一种混合遗传变邻域搜索算法,在遗传算法的变异操作中引入了变邻域搜索方法,以提高遗传算法对高质量解的收敛性。周鲜成[13]等提出了一种基于 NSGA-II 和变邻域搜索的混合算法,旨在优化冷链物流配送的绿色车辆路径问题。

现有的国内外研究成果为生鲜冷链多温共配配送路径问题的深入研究奠定了良好的理论基础。但仍有几个方面有待改进。首先,生鲜冷链车辆路径优化问题研究大多集中在单品类产品配送场景,较少考虑多种生鲜冷链产品对配送计划的影响。其次,从客户角度出发,已有研究大多只是考虑客户的整体满意度,忽略了不同客户对配送时间敏感性的差异化。

基于上述问题,从客户角度出发,为满足不同客户对配送时间的个性化需求,本文引入了时间抵制度模型;从企业角度出发,为了提高企业的市场竞争力,构建多温共配路径优化问题最小运输成本模型。构建了时间抵制度最小以及运输成本最小的双目标多隔间车辆路径问题模型。同时,针对问题模型和蛭螂优化算法的特点,进行算法改进。最后通过多组数值实验进行验证,结果表明,在求解多温共配车辆路径问题中,多策略改进的多目标蛭螂优化算法更加具有优越性。

2. 问题描述

该生鲜多温共配车辆路径问题可定义为一个完整的有向图 $G=(V,E)$ 。其中,车辆行驶速度恒定,节点集合 $V=V_c\cup\{0\}$, 其中 V_c 为顾客集合, 0 表示配送中心, 边集 $E=\{(i,j):i,j\in V,i\neq j\}$, d_{ij} 为弧 $e(i,j)$ 的长度,即客户与客户或者客户与配送中心的距离。 $K=\{k|k=1,2,\dots|K|\}$ 为蓄冷车车辆集合。针对多温共配模型, h_k 表示车辆 k 的车辆隔间集合, Q_k^h 表示车辆 k 车厢 h 的最大载重, $h\in h_k$, p 为生鲜产品种类集合 $P=\{p|p=1,2,3\}$, q_i^p 为顾客 i 对于对商品 p 的需求量, t_k^i 为车辆 k 从 i 点出发时间的的时间, $[E_i,L_i]$ 为客户 i 所能接受的服务时间, $[e_i,l_i]$ 为客户 i 的最佳服务时间。若车辆 k 从顾客 i 行驶到顾客 j 则 x_{ij}^k 值为 1, 否则值为 0。若顾客 i 的 p 类生鲜商品需求由车辆 k 的车厢 h 满足, 则 y_{ip}^{kh} 为 1, 否则为 0。

3. 符号说明与假设

3.1. 符号说明

参数和决策变量及其含义分别如表 1 和表 2 所示。

Table 1. Meanings of parameters
表 1. 参数及其含义

参数	含义
V_c	客户点集合
K	配送车辆集合
F_1	车辆固定成本
F_2	燃油消耗总成本
F_3	制冷成本
F_4	碳排放成本
F_5	货损成本
F_6	时间窗惩罚成本
h	生鲜品类编号, $h=1,2,3$

续表

N	配送车辆最多能够容纳的蓄冷箱个数
c_1	固定成本费用
c_2	单位燃油价格
Q	车辆最大载重量
q_i^k	当时车辆 k 在 i 点的载重量
p_0	车辆在空载状态下行驶单位距离消耗的燃油量
p^*	车辆满载状态下行驶单位距离消耗的燃油量
p^{ij}	表示从 i 点到 j 点的燃油消耗量
f_q	车辆载重为 q 时的单位距离的燃油消耗
$fuel$	所有车辆的总油耗
g_h	第 h 类生鲜产品的蓄冷器成本
η_h	第 h 类生鲜产品的单位变动制冷成本
n_{kh}	第 k 辆车配送第 h 类生鲜品所需要的蓄冷箱个数, n_{kh} 为整数
u	碳税系数
w	碳排放系数
D_0	生鲜产品在出发时刻的质量
ε_h	表示第 h 类生鲜产品的损耗系数
P_h	表示第 h 类生鲜产品的单位价格
D_i^p	客户点 i 点对 h 类生鲜产品的需求量
$[e_i, l_i]$	客户期望被服务的时间窗
$[E_i, L_i]$	客户能接受的被服务的时间窗
t_{ik}	车辆 k 到达客户点 i 的时间点
t_{0k}	车辆 k 从配送中心出发的时间点
Q^{ik}	车辆离开客户点 i 时车上剩余的载货量
t_{si}	车辆在配送点 i 处的服务时间
β_i	客户 i 的抵制系数, 表示不同客户对超出最佳服务时间的时间敏感程度
α	时间抵制指数, 表示对配送时间的抵制程度。
Of_i	客户 i 的时间抵制度值
n	客户数量

Table 2. Meanings of decision variables
表 2. 算法决策变量及其含义

决策变量	含义
x_{ij}^k	若车辆 k 从顾客 i 行驶到顾客 j 则 x_{ij}^k 值为 1, 否则值为 0
y_{ip}^{kh}	若顾客 i 的 p 类冷链商品需求由车辆 k 的车厢 h 满足, 则 y_{ip}^{kh} 为 1, 否则为 0
y_{ik}	当 y_{ik} 时, 表示车辆 k 已为 i 点服务, 反之为 0

3.2. 模型假设

构建多温共配生鲜配送路径问题模型，需要综合考虑现实因素的影响，因此，本文设置了一些假设条件。

(1) 有且仅有一家配送中心，且该配送中心使用的车辆类型统一，每一辆蓄冷车从配送中心出发，完成配送任务后必须返回配送中心。

(2) 客户点的位置、时间窗要求和需求量等信息已知，蓄冷箱规格一致。

(3) 每个客户点只能由一辆蓄冷车服务，但每辆蓄冷车可以为多个客户点提供服务，每辆车服务客户点的生鲜需求量总和不得超过其最大载重量。

4. 数学模型

4.1. 配送成本模型

(1) 车辆固定成本

假设配送中心的车辆数量足够且满足配送需求，且不考虑闲置车辆的成本。则车辆固定成本 F_1 为：

$$F_1 = c_1 \sum_{k \in K} \sum_{j \in V_c} x_{ojk} \quad (1)$$

(2) 燃油消耗成本

对于生鲜配送而言，运输过程中产生的燃油消耗是主要成本之一。燃油消耗的计算过程如下：

$$f_q = P_0 + \frac{P^* - P_0}{Q} q_i^k \quad (2)$$

$$p_{ij}^k = \left(P_0 + \frac{P^* - P_0}{Q} q_i^k \right) d_{ij} \quad (3)$$

$$fuel = \sum_{k \in K} \sum_{i \in V_c} \sum_{j \in V_c} x_{ij}^k p_{ij}^k \quad (4)$$

$$F_2 = C_2 fuel \quad (5)$$

(3) 制冷成本

多温共配路径优化问题的制冷成本主要包括蓄冷箱的固定成本、蓄冷器成本以及单位变动制冷成本。

制冷成本 F_3 如式(6)所示：

$$F_3 = \sum_{h \in H} \sum_{k \in K} (c_3 + g_h + \eta_h) n_{hk} \quad (6)$$

(4) 碳排放成本

物流运输中产生的碳排放主要来源于车辆在配送过程中产生的燃油消耗。 E 表示生鲜配送过程中产生的碳排放量， F_4 表示生鲜配送过程中产生的碳排放成本。公式如下：

$$E = w fuel \quad (7)$$

$$F_4 = u w fuel \quad (8)$$

(5) 货损成本

多温共配模式下车门的开启不会影响其他蓄冷箱的温度。因此，本文只考虑运输过程中因行驶时间增加所带来的货损成本。

引入质量腐败函数 $D(t)$ 表示产品质量随时间变化的趋势。如式(9)所示：

$$D(t) = D_0 e^{-\varepsilon t} \quad (9)$$

式(9)中: D_0 代表生鲜产品在出发时刻的质量, t 代表生鲜产品的在途时间, ε 表示货损系数。

$$F_5 = \sum_{k \in K} \sum_{i \in V_c} y_{ik} P_h D_i^p \left(1 - e^{-\varepsilon_h (t_{ik} - t_{0k})}\right) \quad (10)$$

(6) 时间窗惩罚成本

如果配送车辆未能在客户期望的时间窗内送达, 将产生相应的惩罚成本。这种惩罚成本与车辆到达时间与客户期望时间窗之间的差异程度密切相关。计算过程如下:

$$F_6 = \sum_{i=1}^n \left(\alpha_1 \max\{e_i - t_{ik}, 0\} + \alpha_2 \max\{t_{ik} - l_i, 0\} \right) \quad (11)$$

4.2. 时间抵制度模型

从客户角度出发, 引入时间抵制度模型, 所谓时间抵制度是指客户在主观上对配送时间偏离其期望时间的抵制程度, 当接近客户的最佳服务时间窗时, 客户对服务时间的抵制程度较小, 即配送车辆到达时间越接近客户要求的最佳服务时间, 时间抵制度越小; 反之, 当随着时间提前或延迟, 客户对生鲜配送到达时间的抵制程度逐渐增加。时间抵制度模型如下:

$$Of_i = \begin{cases} 1, & 0 \leq t_i^k < E_i \\ \beta_i \left(\frac{t_i^k - E_i}{e_i - E_i} \right)^\alpha, & E_i \leq t_i^k < e_i \\ 0, & e_i \leq t_i^k \leq l_i \\ \beta_i \left(\frac{l_i - t_i^k}{l_i - l_i} \right)^\alpha, & l_i < t_i^k \leq L_i \\ 1, & t_i^k > L_i \end{cases} \quad (12)$$

式(12)中, Of_i 为客户 i 的时间抵制度值, t_{ik} 为车辆 k 从配送中心到达客户 i 的时间, α 为时间抵制指数即表示对配送时间出现偏差的抵制程度, β_i 为客户 i 的抵制系数。综上, 客户的时间抵制度最小的目标函数为:

$$\min Z = \frac{1}{n} \sum_{i=1}^n Of_i \quad (13)$$

4.3. 多温共配路径优化模型

考虑到蓄冷车辆容量、时间窗等约束条件, 以车辆运输总成本最小和时间抵制度最小为优化目标, 构建蓄冷式多温共配生鲜路径多目标优化模型如下:

$$\begin{aligned} \min C &= F_1 + F_2 + F_3 + F_4 + F_5 + F_6 \\ &= c_1 \sum_{k \in K} \sum_{j \in V_c} x_{ojk} + C_2 \text{fuel} + \sum_{h \in H} \sum_{k \in K} (c_3 + g_h + \eta_h) n_{hk} + uw \text{fuel} \\ &\quad + \sum_{k \in K} \sum_{i \in V_c} y_{ik} P_h D_i^p \left(1 - e^{-\varepsilon_h (t_{ik} - t_{0k})}\right) \end{aligned} \quad (14)$$

$$+ \sum_{i=1}^n \left(\alpha_1 \max\{e_i - t_{ik}, 0\} + \alpha_2 \max\{t_{ik} - l_i, 0\} \right)$$

$$\min Z = \frac{1}{n} \sum_{i=1}^n Of_i \quad (15)$$

约束条件:

$$\text{s.t. } \sum_{i \in V} x_{ijk} = \sum_{i \in V} x_{jik} = 1, \forall j \in V_c, \forall k \in K \quad (16)$$

$$\sum_{i \in V} \sum_{k \in K} x_{ij}^k = \sum_{i \in V} \sum_{k \in K} x_{ji}^k \quad j \in V_c \quad (17)$$

$$\sum_{i \in V_c} \sum_{h \in H} \sum_{k \in K} q_{ih} y_{ik} \leq Q \quad (18)$$

$$\sum_{i \in V_c} \sum_{k \in K} x_{i0k} = \sum_{j \in V_c} \sum_{k \in K} x_{0jk} \quad (19)$$

$$\sum_{i \in V_c} \sum_{k \in K} y_{ik} = n \quad (20)$$

$$\sum_{h \in H} n_{kh} \leq N \quad (21)$$

$$E_i \leq t_{ik} \leq L_i \quad \forall i \in V \quad (22)$$

$$\sum_{i \in V_c} y_{ip}^{kh} q_i^p \leq Q_k^h \quad k \in K, h \in h_k, p \in P \quad (23)$$

$$\sum_{i \in V} x_{ij}^k \leq \sum_{p \in P} y_{jp}^{kh} \quad j \in V, k \in K, h \in h_k \quad (24)$$

$$x_{ij}^k (1 - x_{ij}^k) = 0 \quad i \in V, j \in V, k \in K \quad (25)$$

$$y_{ip}^{kh} (1 - y_{ip}^{kh}) = 0 \quad i \in V, p \in P, h \in h_k, k \in K \quad (26)$$

其中, 式(14)表示最小运输成本, 式(15)表示最低时间抵制度; 式(16)表示每个节点有且仅有一辆车服务, 车辆到达节点后必须离开; 式(17)表示表示访问顾客的车辆流量平衡; 式(18)表示表示每辆车运输的货物不超过车辆载重量; 式(19)表示车辆从配送中心出发, 完成配送任务后全部返回配送中心; 式(20)表示所有客户点都有车辆服务, 没有遗漏的客户点; 式(21)表示第 k 辆车装载的蓄冷式保温箱数不能超过车辆最多能装载的保温箱数; 式(22)表示为时间窗约束, 限制车辆配送时间; 式(23)表示每位顾客任意商品的配送需求不大于相对应配送车辆车厢容量; 式(24)表示表示一次服务应当尽可能完成多种冷链产品的配送; 式(25)为决策变量, 表示若车辆 k 从顾客 i 行驶到顾客 j 则为 1, 否则为 0; 式(26)为决策变量, 表示若车辆 k 的车厢 h 满足顾客 i 的 p 类商品需求则为 1, 否则为 0。

5. 改进蜣螂优化算法

蜣螂优化算法(DBO)算法首次由 Xue 等[14]提出, 之前的研究表明它具有良好的性能。然而, 它也存在一些局限性。因此, 本文提出了一系列改进措施。改进后的多目标蜣螂优化算法如下:

5.1. 种群初始化融合 tent 混沌与逆向学习策略

种群初始化在 DBO 中通常是随机生成的, 这种方式可能导致种群初始化分布不均匀。因此, 通过结合 tent 混沌初始化方法和逆向学习策略, 来提高种群初始化的质量。

改进后的 Tent 混沌映射表达式如下:

$$x_{m+1} = \begin{cases} 2x_m + \text{rand}(0,1) \times \frac{1}{N}, & 0 \leq x \leq \frac{1}{2} \\ 2(1-x_m) + \text{rand}(0,1) \times \frac{1}{N}, & \frac{1}{2} < x \leq 1 \end{cases} \quad (27)$$

使用 tent 混沌映射生成初始解的同时, 引入逆向学习策略, 对每个初始解生成其对应的反向解, 可以有效补充搜索空间, 提高种群的多样性和覆盖率。逆向学习策略的表达式如下:

$$OP_i = J(P_{\min} + P_{\max}) - P_i \quad (28)$$

式(28)中, OP_i 是对应于每个初始解 P_i 的逆解。 $P_{\max}$ 和 $P_{\min}$ 分别表示初始解中的最大值和最小值。 J 是 (0,1) 范围内的随机值。

5.2. 滚球阶段(无障碍向前)

蛭螂个体在滚球阶段会推滚一个粪球, 并在推滚过程中不断调整方向以找到最优解。位置变化计算公式为:

$$x_m^{(t+1)} = x_m^t + acx_i^{(t-1)} + b|x_m^t - x_{\text{worst}}^t| \quad (29)$$

式(29)中, x_m^t 表示第 m 个蛭螂在第 t 次迭代时的位置; a 表示蛭螂是否偏离其原始方向, 其中, $a=1$ 表示无偏差, $a=-1$ 表示发生了方向偏离。 $c \in (0, 0.2]$; $b \in (0, 1]$ 中的随机数; x_{worst}^t 表示全局最差位置, $|x_m^t - x_{\text{worst}}^t|$ 用于模拟太阳照明。

但由于 DBO 算法的随机搜索策略缺乏自适应性, 容易陷入局部最优。为提高算法性能, 可以引入动态选择策略, 在一定概率下交替使用自适应步长策略和凸透镜成像反转策略更新目标位置。

自适应步长主要由线性递减的自适应步进控制因子 α_t 决定, 其中, α_0 是初始步长, 为 $\cos \pi/3$, t 为当前迭代次数, β 为控制步长衰减速度的参数。 Z 是目标函数的数量, $f_{\text{best}}^z(0)$ 代表第 z 个目标函数的初始最优解, $f_{\text{best}}^z(t)$ 是第 z 个目标函数在第 t 次迭代中的最优解。具体计算过程如下:

$$\alpha_t = \alpha_0 \cdot \frac{1}{1 + \beta t \left(\frac{1}{Z} \sum_{z=1}^Z \frac{f_{\text{best}}^z(t)}{f_{\text{best}}^z(0)} \right)} \quad (30)$$

同时, 引入一种凸透镜成像学习策略来扰动蛭螂种群, 该策略利用凸透镜的折射特性, 使得位置更新具有非线性特征, 有助于跳出局部最优。表示如式(32):

$$P_j^* = \frac{a_j + b_j}{2} + \frac{a_j + b_j}{2I_n} - \frac{p_j}{I_n} \quad (31)$$

式(31)中, p_j^* 表示更新后的个体位置, a_j 和 b_j 分别表示当前个体的位置向量, I_n 表示当前个体的索引, p_j 表示当前个体的位置向量。

目标位置更新采用哪种策略的选择由选择概率 P_s 决定

$$P_s = -\exp\left(1 - \frac{t}{T}\right)^{10} \quad (32)$$

当随机值 $P_s < 0.5$ 时, 采用自适应步长策略对蛭螂进行位置更新; 否则, 使用凸透镜反向学习策略进行位置更新, 如下所示:

$$\begin{cases} p_m^{t+1} = \alpha_t \times P_{\text{gbest}}^t + B_1 \times (P_m^t - L_{b'}^t) + B_2 \times (P_m^t - U_{b'}^t), & P_s < 0.5 \\ p_m^{t+1} = \frac{(L_{b'}^t + U_{b'}^t)}{2} + \frac{(L_{b'}^t + U_{b'}^t)}{2I_n} - \frac{p_{\text{gbest}}^t}{I_n}, & P_s \geq 0.5 \end{cases} \quad (33)$$

式(33)中, $L_{b'}$ 和 $U_{b'}$ 代表觅食区域的上限和下限。

5.3. 跳舞阶段(遇到障碍)

当蜣螂在行进中被障碍物阻挡时, 它会通过舞蹈行为重新调整前进路线。这个舞蹈行为可以用切线函数来模拟, 位置更新公式为:

$$x_m^{t+1} = x_m^t + \tan \theta |x_m^t - x_m^{t-1}| \quad (34)$$

式(34)中, $\theta \in [0, \pi]$ 为偏转角, 当 θ 为 0 或 $\pi/2$ 时, 代表蜣螂的位置不发生改变; $|x_m^t - x_m^{t-1}|$ 表示第 m 只蜣螂在第 t 次迭代时与第 $t-1$ 次迭代时位置之间的偏移量。

5.4. 繁殖阶段

每次蜣螂产卵时, 它的位置都会更新。蜣螂产卵的位置更新公式为:

$$x_m^{t+1} = x_{gbest}^t + b_1 (x_m^t - L_{b^*}) + b_2 |x_m^t - U_{b^*}| \quad (35)$$

式(35)中, x_{gbest}^t 为全局最佳位置, b_1 和 b_2 为两个大小为 $1 \times d$ 的独立且随机向量, d 为优化问题的维数, L_{b^*} 和 U_{b^*} 是繁殖区域的上限和下限。

5.5. 觅食阶段

当蜣螂觅食时, 位置变化式为:

$$x_m^{t+1} = x_m^t + R_1 (x_m^t - L_{b'}) + R_2 |x_m^t - U_{b'}| \quad (36)$$

式(36)中, $L_{b'}$ 和 $U_{b'}$ 代表觅食区域的上限和下限, R_1 为服从正态分布的随机数, R_2 为大小为 $1 \times d$ 的随机向量。

由于 DBO 算法在觅食搜索过程中缺乏足够的跳出局部最优的能力, 容易陷入局部最优解。为了解决上述问题, 引入曲线自适应惯性权重, 公式如下:

$$w = w_{initial} + (1 - w_{initial}) \cdot \cos\left(\pi \cdot \frac{t}{T}\right) \\ w_{initial} = (w_{max} + w_{min}) / 2 \quad (37)$$

其中, w 为惯性权重, $w_{initial}$ 是惯性权重的初始值。 w_{max} 和 w_{min} 分别是惯性权重的最大和最小值。

黄金正弦算法首次由 E. Tanyildizi 等[15]提出, 并因其快速收敛性、鲁棒性、易于实现以及较少的参数和操作调整而在后续科学研究中广泛应用。该算法的具体公式如下:

$$x_m^{t+1} = x_m^t \cdot |\sin(W_1)| + W_2 \cdot \sin(W_1) \cdot |Q_1 \cdot X_{gbest}^t - Q_2 \cdot X_m^t| \quad (38)$$

式(37)中 x_{gbest}^t 是在第 t 次迭代时的全局最佳位置, Q_1 和 Q_2 分别是随机变量用来更新个体位置。

结合曲线自适应策略与黄金正弦算法得到曲线自适应黄金正弦策略, 位置更新公式如下:

$$X_n^{(t+1)} = (1 - w) X_n^{(t)} \cdot |\sin(W_1)| + W_2 \cdot \sin(W_1) \cdot |Q_1 \cdot X_n^{(t)} - Q_2 \cdot X_n^{(t+1)}| \quad (39)$$

5.6. 偷窃阶段

在自然界中, 一些蜣螂会选择从其他蜣螂那里偷粪球。为了模拟这种行为, 将最佳全局位置作为有争议的粪球位置。位置更新通过以下公式进行计算:

$$x_m^{(t+1)} = x_{lbest}^t + Sg(|x_m^t - x_{gbest}^t| + |x_m^t - x_{lbest}^t|) \quad (40)$$

式(41)中 x_{lbest}^t 为最佳食物来源, S 代表常数值, g 为服从正态分布的大小为的随机向量。

5.7. 算法求解流程

多策略改进的多目标蜚螂优化算法求解流程如下, 算法流程图如图 1 所示:




Figure 1. Algorithm flowchart

图 1. 算法流程图

Step 1: 初始化参数。设定种群规模, 最大迭代次数, 偏移控制参数 a 和 b 等。

Step 2: 种群初始化。使用 tent 混沌映射和逆向学习策略生成初始解。基于公式(28)和(29)确定搜索空间的边界合并初始解 p_i 和反向解 OP_i , 形成初始种群。

Step 3: 适应度计算。计算每个个体的适应度值, 进行非支配排序和拥挤距离计算。

Step 4: 位置更新。更新滚球行为、繁殖行为、觅食行为和偷窃行为的蜚螂个体位置, 加入曲线自适应黄金正弦策略、自适应步长控制和凸透镜成像策略更新蜚螂个体位置。计算新位置的适应度值, 若前者更优则, 保持原个体位置不变, 若当前更优更新为当前个体。

Step 4.1: 基于公式(30)~(34), 在蜚螂滚球阶段进行个体位置更新, 当 $P_s < 0.5$ 时, 使用自适应步长策略; 否则, 使用凸透镜成像策略进行位置更新。

Step 4.2: 基于公式(35), 当蜚螂遇到障碍时, 使用切线函数模拟蜚螂位置更新。

Step 4.3: 基于公式(36), 对蜚螂产卵进行位置更新。

Step 4.4: 基于公式(37)~(40), 使用曲线自适应黄金正弦策略, 在蜚螂觅食阶段进行位置更新。

Step 4.5: 基于公式(41), 模拟蜚螂的偷窃行为, 进行位置更新。

Step 5: 结束。输出当前的 Pareto 非劣解集。

6. 算例分析

本文将对 Solomon VRPTW 基准数据集进行改造来验证多温共配配送路径问题模型和基于多策略改

进的多目标蜚螭优化算法的适用性。设置参数如下：配送中心共有 5 辆冷链配送车辆，物流中心的服务时间窗为[7:00, 22:00]，等待成本 10 元/h，延误成本为 15 元/h，服务时间为 0.2 h，车辆载重量为 7 吨，车辆派遣成本为 200 元/辆，蓄冷箱成本为 25 元/个，运输成本为 4 元/km，单位距离油耗 0.165 L/km，满载油耗 0.377 L/km，碳排放系数为 2.63 kg/L，碳税系数为 0.18。时间抵制度指数 α 取 0.2。

6.1. 结果分析

为了验证基于多策略改进的多目标蜚螭优化算法对多车厢车辆路径的求解性能，通过对 Solomon VRPTW 基准数据集的重新设计，选取 50 顾客规模的部分 SolomonVRPTW r101 算例集进行数值实验，以优化运输总成本为目标一，优化时间抵制度为目标二。

以 r101 为例，经过计算得到 28 个非劣解集，通过最优解选择方法，得到最优的 Pareto 非劣解，该解对应的成本为 2714 元，时间抵制度为 0.295，此时，采用五辆车完成配送任务。各车具体路径如图 2 所示。




Figure 2. Vehicle trajectory diagram

图 2. 车辆轨迹图

6.2. 算法性能分析

6.2.1. MSNSDBO 算法改进策略性能验证

为了验证 MSNSDBO 算法中改进的 tent 混沌映射与逆向学习策略相结合的初始化策略(改进策略 1)、自适应步长策略和凸透镜成像策略(改进策略 2)、曲线自适应黄金正弦策略(改进策略 3)三个改进策略的性能，选取部分算例集进行数值实验验证。验证改进策略 1 时，只保留对种群初始化的策略改进，同时去除改进策略 2 与改进策略 3 的内容，设为算法 1，并与未改进的多目标蜚螭优化算法进行对比。以此类推，分别验证独立加入改进策略 2 与改进策略 3 的算法 2 和算法 3 的性能，其中， C'_{best} 和 O'_{best} 分别为

三种子算法求解 10 次的平均成本和平均时间抵制度。验证结果如表 3 所示。




Figure 3. Pareto non-dominated solution distribution comparison
图 3. Pareto 非劣解分布对比图

由表 3 可知，分别独立加入改进策略的算法 1，算法 2 和算法 3，在 C_{best} 和 O_{best} 两项指标对比中均优于 NSDBO 算法。其中，只独立加入 tent 混沌映射与逆向学习策略的算法 1，在处理三个算例集时， C_{best} 和 O_{best} 平均分别减少了 2.74%和 3.34%，证明了其对初始解扰动的有效性。同时，算法 2 的 C_{best} 和 O_{best} 平均分别减少了 2.53%和 3.54%，证明了自适应步长策略与凸透镜策略的有效扰动性。最后，算法 3 的 C_{best} 和 O_{best} 平均分别减少了 2.76%和 2.69%，验证了算法 3 策略在蛱螂觅食阶段扰动种群位置的合理性。

Table 3. Test results of improvement strategies for MSNSDBO algorithm
表 3. MSNSDBO 算法改进策略测试结果

算例	NSDBO		算法 1		算法 2		算法 3	
	C_{best}	O_{best}	C'_{best}	O'_{best}	C'_{best}	O'_{best}	C'_{best}	O'_{best}
C101	2831.24	0.324	2714.86	0.312	2697.74	0.311	2739.47	0.315
R101	2718.38	0.296	2674.67	0.283	2689.34	0.285	2678.29	0.287
RC101	2814.07	0.313	2743.57	0.307	2763.39	0.304	2713.84	0.306

6.2.2. Pareto 非劣解对比

为进一步验证模型和算法的适用性，在参数设置完全相同的情况下，将 MSNSDBO 算法与 NSDBO 算法各运行十次后，两种算法的 Pareto 非劣解分布图如图 3 所示，MSNSDBO 算法在多次运行中表现出更优的性能，首先，MSNSDBO 算法在生成非劣解数量上占据优势，这表明该算法在平衡时间抵制度和运输成本这两个优化目标时，具有更高的稳定性和效率。其次，MSNSDBO 算法的 Pareto 前沿分布更为

均匀, 显示出更好的解空间探索能力。

6.3. 成本分析

6.3.1. 配送成本分析

为了验证 MSNSDBO 算法的性能, 将 MSNSDBO 算法与多目标粒子群算法(MOPSO)、多目标灰狼算法(MOGWO)、NSDBO 算法进行对比分析。仿真结果如图 4 所示, 在运输成本方面, MSNSDBO 算法计算结果为 2562.68 元, 相较于 MOPSO、MOGWO、NSDBO 算法, 分别降低了 8.76%、8.39%、1.31%, 其收敛能力具有一定的优势。具体而言, MSNSDBO 算法在早期迭代中能迅速找到较优解。随着迭代次数的增加, MSNSDBO 算法可以稳定收敛至较低的成本值。




Figure 4. Convergence comparison of transportation costs

图 4. 运输成本的收敛对比图

6.3.2. 时间抵制度分析

为了进一步探究 MSNSDBO 算法的求解性能, 在时间抵制度方面, 仿真结果如图 5 所示。MSNSDBO 算法计算结果为 0.2838, 相较于 MOPSO、MOGWO 算法, 分别降低了 4.44%、5.65%。MSNSDBO 算法计算结果相较于 NSDBO 算法, 增加了约 0.532%。同时, MSNSDBO 算法在每次迭代中均能找出更优的时间抵制度, 其在时间抵制度目标函数方面具有更好的求解能力。

6.4. 结果对比

为了进一步验证 MSNSDBO 算法求解不同算例的适用性, 选取选用 12 个 50 客户规模的 Solomon 基准数据集进行改造, 并与 NSDBO、MOPSO、MOGWO 算法进行比较, 结果如表 4 所示。其中, C_{best} 、 O_{best} 和 p_n 分别表示算法求解中得到平均最小运输成本和最小时间抵制度和 Pareto 非劣解个数。




Figure 5. Convergence comparison of time resilience
图 5. 时间抵制度的收敛对比图

Table 4. Comparison results of reconstruction case experiments based on benchmark datasets
表 4. 基于基准数据集的改造算例实验对比结果

算例	MSNSDBO				NSDBO				MOPSO				MOGWO			
	t/s	C_{best}	O_{best}	p_n	t/s	C_{best}	O_{best}	p_n	t/s	C_{best}	O_{best}	p_n	t/s	C_{best}	O_{best}	p_n
C101	27.28	2649	0.284	26	29.83	2731	0.304	20	30.13	2657	0.287	22	28.54	2873	0.290	25
C102	30.21	2588	0.297	23	31.24	2638	0.311	23	30.77	2708	0.281	25	30.73	2654	0.303	27
C103	29.56	2661	0.315	28	31.85	2847	0.298	24	32.61	2503	0.304	24	30.54	2868	0.281	25
C104	27.14	2489	0.274	27	28.61	2652	0.307	21	31.30	2555	0.285	23	29.04	2772	0.297	27
R101	28.22	2714	0.295	28	30.78	2618	0.286	18	29.14	2569	0.293	26	29.94	2641	0.294	23
R102	29.19	2697	0.292	27	31.54	2734	0.309	26	29.85	2690	0.314	22	30.22	2688	0.299	21
R103	28.98	2591	0.283	21	31.29	2864	0.313	27	30.27	2739	0.310	24	29.92	2721	0.301	26
R104	29.45	2483	0.274	29	30.98	2529	0.321	25	31.02	2985	0.296	22	31.40	2513	0.309	23
RC101	29.91	2833	0.301	25	30.28	2714	0.293	21	31.60	2810	0.294	21	30.53	2853	0.284	24
RC102	30.17	2752	0.316	22	29.17	2839	0.284	27	31.86	2869	0.309	24	30.97	2781	0.297	22
RC103	29.46	2639	0.293	27	28.67	2869	0.295	24	28.62	2862	0.311	23	29.42	2822	0.285	27
RC104	29.47	2573	0.284	25	30.35	2761	0.297	20	29.15	2691	0.309	24	29.37	2860	0.291	22

对比结果表明，在算法运行时间上，MSNSDBO 算法运行时间在大多数算例实验中要明显短于其他

三种算法, 其中, MSNSDBO 算法的平均运行时间为 29.09 s, 分别比 NSDBO、MOPSO、MOGWO 算法缩短了 4.25%、4.72%、3.19%。在 Pareto 非劣解的数量上, MSNSDBO 算法的 Pareto 解的平均数量约为 25.33, 其在八个算例测试中均具有更多的帕累托非劣解。在运输成本方面, MSNSDBO 算法的平均运输成本约为 2639.08, 分别比 NSDBO、MOPSO、MOGWO 算法缩短了 4.25%、4.72%、3.19%。在时间抵制度方面, MSNSDBO 算法的平均时间抵制度为 0.292, 分别比 NSDBO、MOPSO、MOGWO 算法减少了约 3.15%、2.47%、0.78%。可以看出, 在求解多温共配车辆路径优化问题中, MSNSDBO 算法具有一定的优势。

7. 结论

本文针对生鲜多温共配车辆路径优化问题, 兼顾客户对生鲜产品配送时间的要求, 建立了生鲜多温共配的多目标优化问题数学模型, 并使用基于多策略改进的多目标蜣螂优化算法进行求解。最后通过多组算例实验验证了算法的可行性和有效性。得到的主要结论如下: 首先, 使用基于多策略改进的多目标蜣螂优化算法在解决生鲜多温共配问题时, 能显著提高求解质量和效率。其次, 多策略改进的多目标蜣螂优化算法可以有效处理不同标准算例的多车仓车辆路径优化问题。

未来将对动态需求, 多配送中心沿途补货等生鲜多温共配问题进行进一步深入研究。

基金项目

国家自然科学基金资助项目(71632008, 71840003); 上海市 2021 度“科技创新行动计划”宝山转型发展科技专项项目(21SQBS01404); 上海理工大学科技发展项目(2020KJFZ038)。

参考文献

- [1] Liu, G., Hu, J., Yang, Y., Xia, S. and Lim, M.K. (2020) Vehicle Routing Problem in Cold Chain Logistics: A Joint Distribution Model with Carbon Trading Mechanisms. *Resources, Conservation and Recycling*, **156**, Article 104715. <https://doi.org/10.1016/j.resconrec.2020.104715>
- [2] Kaabi, H. (2016) Hybrid Metaheuristic to Solve the Selective Multi-Compartment Vehicle Routing Problem with Time Windows. In: *Advances in Intelligent Systems and Computing*, Springer, 185-194. https://doi.org/10.1007/978-3-319-29504-6_19
- [3] Sun, L., Zhang, Y. and Hu, X. (2021) Economical-Traveling-Distance-Based Fleet Composition with Fuel Costs: An Application in Petrol Distribution. *Transportation Research Part E: Logistics and Transportation Review*, **147**, Article 102223. <https://doi.org/10.1016/j.tre.2021.102223>
- [4] Cho, Y.J. and Li, C.C. (2005) Application of Multi-Temperature Refrigerated Container to Improve the Distribution of Cold Logistics. *Journal of the Eastern Asia Society for Transportation Studies*, **6**, 2794-2808.
- [5] 王淑云, 赵敏. 蓄冷式冷链物流多温共配的动力机制研究[J]. 公路交通科技, 2012, 29(2): 144-148.
- [6] Hsu, C. and Liu, K. (2011) A Model for Facilities Planning for Multi-Temperature Joint Distribution System. *Food Control*, **22**, 1873-1882. <https://doi.org/10.1016/j.foodcont.2011.04.029>
- [7] 牟进进, 郑仁教, 王淑云. 基于服务创新的蓄冷式多温共配创新驱动与发展路径研究[J]. 东岳论丛, 2017, 38(10): 86-95.
- [8] 戴夏静, 梁承姬. 带时间窗的蓄冷式多温共配冷链配送问题研究[J]. 重庆师范大学学报: 自然科学版, 2017, 34(5): 18-25.
- [9] Hsiao, Y., Chen, M. and Chin, C. (2017) Distribution Planning for Perishable Foods in Cold Chains with Quality Concerns: Formulation and Solution Procedure. *Trends in Food Science & Technology*, **61**, 80-93. <https://doi.org/10.1016/j.tifs.2016.11.016>
- [10] 任腾, 罗天羽, 李姝萱, 等. 面向冷链物流配送路径优化的知识型蚁群算法[J]. 控制与决策, 2022, 37(3): 545-554.
- [11] 李春发, 米新新, 崔鑫. 基于双曲正切函数改进蚁群算法的冷链物流配送路径优化[J]. 公路交通科技, 2023, 40(12): 236-244+258.
- [12] Sbail, I., Krichen, S. and Limam, O. (2022) Two Meta-Heuristics for Solving the Capacitated Vehicle Routing Problem:

- The Case of the Tunisian Post Office. *Operational Research*, **2022**, 1-43.
- [13] 周鲜成, 蒋涛营, 贺彩虹, 王莉, 吕阳. 冷链物流配送的绿色车辆路径模型及其求解算法[J]. 中国管理科学, 2023, 31(12): 203-214.
- [14] Xue, J. and Shen, B. (2022) Dung Beetle Optimizer: A New Meta-Heuristic Algorithm for Global Optimization. *The Journal of Supercomputing*, **79**, 7305-7336. <https://doi.org/10.1007/s11227-022-04959-6>
- [15] Tanyildizi, E. and Demir, G. (2017) Golden Sine Algorithm: A Novel Math-Inspired Algorithm. *Advances in Electrical and Computer Engineering*, **17**, 71-78. <https://doi.org/10.4316/aece.2017.02010>