

# 基于改进蚁群算法的冷链物流多目标路径优化研究

车冰艳, 何胜学

上海理工大学管理学院, 上海

收稿日期: 2025年6月19日; 录用日期: 2025年7月29日; 发布日期: 2025年8月6日

## 摘要

在冷链物流配送过程中, 如何在多目标约束下实现高效、低成本的路径优化, 以降低运输成本、控制货损并满足时效要求, 是当前企业面临的关键问题。本文针对多车辆冷链配送系统构建了一个多目标、多约束的优化模型, 全面考虑运输成本、时间窗约束、货物损耗、制冷成本等因素, 特别引入多温区需求建模与蓄冷箱配置限制, 使模型更贴近实际业务需求。为克服传统蚁群算法在求解强约束多目标问题中易陷入局部最优、收敛速度慢等问题, 本文提出了一种状态感知蚁群算法(State-Aware Ant Colony Algorithm, SA-ACA)。该算法融合车辆状态建模(位置、时间、载重、货损)、多温区路径动态评估机制、局部搜索(2-opt)及基于精英路径的Top-K信息素增强策略, 从而显著提升了解的质量与算法效率。通过在典型冷链配送网络上的仿真实验, 结果表明SA-ACA在运输成本、时间窗满足率、货损控制与制冷成本等关键指标上均优于标准蚁群算法, 验证了该方法在冷链物流路径优化中的有效性与实际应用潜力。

## 关键词

冷链物流, 路径优化, 状态感知蚁群算法, 多目标优化, 时间窗约束

# Multi-Objective Route Optimization for Cold Chain Logistics Based on an Improved Ant Colony Algorithm

Bingyan Che, Shengxue He

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

Received: Jun. 19<sup>th</sup>, 2025; accepted: Jul. 29<sup>th</sup>, 2025; published: Aug. 6<sup>th</sup>, 2025

## Abstract

In the process of cold chain logistics distribution, achieving efficient and low-cost route optimization under multi-objective constraints—such as reducing transportation costs, minimizing time-related losses, and controlling cargo damage—remains a critical challenge. To address the complexity of multi-vehicle cold chain systems in real-world applications, this paper establishes a comprehensive optimization model that simultaneously considers transportation cost, service time windows constraint, vehicle loading capacity, cargo spoilage, and refrigeration cost. Notably, the model incorporates multi-temperature zone demand constraints and cold box configuration limits to better align with actual business scenarios. To overcome the limitations of the traditional Ant Colony Algorithm (ACA) in handling strongly constrained multi-objective problems—such as susceptibility to local optima and slow convergence—a State-Aware Ant Colony Algorithm (SA-ACA) is proposed. The algorithm integrates a vehicle state modeling mechanism (including position, time, residual load, and spoilage), multi-temperature path evaluation, local 2-opt search, and a Top-K elite-based pheromone reinforcement strategy, thereby significantly improving both the solution quality and convergence efficiency. Numerical experiments on a representative cold chain distribution network demonstrate that the SA-ACA outperforms the standard ACA in terms of transportation cost, time window satisfaction rate, cargo preservation, and refrigeration expense, confirming its effectiveness and practical value in solving real-world cold chain logistics routing problems.

## Keywords

Cold Chain Logistics, Route Optimization, State-Aware Ant Colony Algorithm, Multi-Objective Optimization, Time Window Constraint

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

随着生鲜电商与现代消费需求的快速增长,冷链物流已成为保障食品新鲜、安全与时效的关键领域,其高效配送直接影响企业成本、客户满意度及产品品质,车辆路径优化(VRP)因此成为该领域的核心研究问题[1]。

现有研究聚焦于构建贴合实际约束的冷链配送模型,针对生鲜农产品、冷鲜肉等易腐货物,学者们普遍将运输成本、时间窗、货损、碳排放等纳入优化目标,通过人工蜂群算法[2]、改进遗传算法、蚁群算法等提升求解效能。

在约束处理方面,相关研究已覆盖多温区共配、动态需求、客户满意度、碳交易机制等[3],逐步实现从单目标成本优化向多目标绿色智能转型。例如,张富慧[4]结合低碳目标优化遗传算法,获得更经济的低碳配送方案;吕勇强[5]通过改进蚁群算法参数,提升了多配送中心路径优化效率。

在算法与模型融合层面,栗治杰[6]提出双层规划路径规划方法,为复杂约束建模提供新思路;王宁等[7]构建多目标模型并改进蚁群算法,提升了求解效果。

另外,学者们进一步强化了算法与业务场景的适配性:曹菁菁等[8]基于实时交通数据构建动态模型,提升了拥堵场景下的决策实时性;陈妮[9]针对时间窗约束细化研究,为同类问题提供了约束处理参考。在多目标优化的实际应用中,张雯惠等[10]结合碳交易机制与客户满意度,通过多目标遗传算法实现了成

本与满意度的平衡, 推动了多目标模型的落地。

总体来看, 现有研究虽在冷链物流路径优化领域成果丰硕, 但在多目标与强约束耦合的求解效率、算法全局搜索能力、解的可行性保障等方面仍存不足, 传统算法亦易陷入局部最优与解空间探索不足的困境。为应对多目标、多约束下冷链路径优化的复杂性, 本文提出了一种状态感知蚁群算法(SA-ACA)。该算法通过引入车辆状态建模机制, 动态跟踪车辆当前位置、时间、载重与货损信息, 提升路径选择的可行性与响应性; 同时引入多温区需求与蓄冷箱配置建模, 实现制冷成本的动态控制。算法融合 2-opt 局部优化与 Top-K 信息素增强策略, 兼顾搜索质量与收敛速度。仿真实验证明, SA-ACA 在运输成本、时间窗满足、货损控制及制冷能耗等方面均优于标准蚁群算法, 展现出良好的实际应用价值。

## 2. 问题描述与模型构建

### 2.1. 问题描述

随着冷链物流需求增长, 企业在路径规划中需同时兼顾运输成本、时效性、货损控制与能耗管理, 路径优化问题呈现出典型的多目标、多约束特征。本文研究的配送系统由一个配送中心、多辆冷藏车和多个客户节点组成, 客户存在多温区需求(如冷藏、冷冻), 车辆按需配置蓄冷箱, 运输过程中持续维持温度, 产生与运行时间及箱数相关的制冷成本。

配送过程中货物将随运输与卸货时间发生非线性损耗, 若到达时间不满足客户时间窗, 还将产生服务违约成本。同时, 车辆载重与服务时间有限, 路径构建需动态满足各类实际约束。为此, 本文建立融合多温区需求、货损与制冷成本的多目标优化模型, 并设计状态感知蚁群算法进行求解, 通过车辆状态建模与路径动态调整, 实现冷链路径规划中成本与服务质量的综合优化。

### 2.2. 模型假设

为准确刻画冷链物流配送过程中的实际运营情形, 并便于模型构建与后续算法设计, 本文在研究中作出如下基本假设: 1. 所有客户节点的位置、需求和配送中心的位置与容量均已知且固定。2. 运输车辆的数量和载重量是有限的, 且已知。3. 客户节点设定了严格的配送时间窗。4. 运输和卸货过程中货物损耗呈非线性增长, 分别受运输时间与卸货时间影响。5. 车辆从配送中心出发, 必须最终返回配送中心。6. 车辆为蓄冷式冷藏车, 可按需配置不同类型的蓄冷箱以满足客户多温区需求, 制冷成本随运输时间和箱数线性增长, 每车蓄冷箱总数存在上限。

### 2.3. 符号定义

基于上述问题描述, 本文进一步对该问题进行数学建模, 相关符号定义见表 1。

Table 1. Description of relevant symbols

表 1. 相关符号说明

符号	含义
$N = \{0, 1, \dots, n\}$	所有节点集合, 节点 0 为配送中心, 其余为客户
$V = \{1, 2, \dots, m\}$	可用车辆集合
$d_{ij}$	节点 $i$ 到节点 $j$ 的距离
$t_{ij}$	节点 $i$ 到节点 $j$ 的运输时间
$q_j$	客户 $j$ 的需求量
$Q_k$	车辆 $k$ 的最大载重

续表

$[e_j, l_j]$	客户 $j$ 的服务时间窗(最早到达时间与最晚服务时间)
$\rho_1$	运输阶段单位时间货物损耗率
$\rho_2$	卸货阶段单位时间货物损耗率
$\gamma_1, \gamma_2$	迟到与早到的时间窗惩罚系数
$\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5$	各目标的加权系数
$x_{ijk}$	若车辆 $k$ 从节点 $i$ 行驶至节点 $j$ , 否则 $x_{ijk} = 1$ , 否则为 0
$a_{jk}$	车辆 $k$ 到达客户 $j$ 的服务开始时间
$l_{ik}$	车辆 $k$ 到达节点 $i$ 时的剩余载重
$c$	单位货物价值
$c_r$	第 $r$ 类温层蓄冷箱单位时间制冷成本
$p_k^r$	车辆 $k$ 所搭载的第 $r$ 类温层蓄冷箱数
$s_{ik}$	车辆 $k$ 在客户 $i$ 处的卸货服务时间

## 2.4. 目标函数

本模型目标函数的设计目的是在多个约束条件下实现冷链物流配送系统的高效性与低成本。综合考虑运输成本、配送耗时、服务时间窗违约惩罚、货物损耗与制冷成本五个方面, 构建如下多目标加权目标函数:

$$\min Z = \lambda_1 Z_1 + \lambda_2 Z_2 + \lambda_3 Z_3 + \lambda_4 Z_4 + \lambda_5 Z_5 \quad (1)$$

其中, 各子目标函数具体表示如下:

1) 运输成本目标  $Z_1$ :

表示所有车辆在执行配送任务过程中所产生的总运输距离成本, 计算如下:

$$Z_1 = \sum_{k \in V} \sum_{i \in N} \sum_{\substack{j \in N \\ j \neq i}} d_{ij} \cdot x_{ijk} \quad (2)$$

2) 配送耗时目标  $Z_2$ :

表示所有车辆配送路径的累计时间, 反映车辆执行效率:

$$Z_2 = \sum_{k \in V} \sum_{i \in N} \sum_{\substack{j \in N \\ j \neq i}} t_{ij} \cdot x_{ijk} \quad (3)$$

3) 时间窗惩罚成本  $Z_3$ :

若车辆到达客户点的时间不满足服务时间窗要求, 将产生早到或迟到的惩罚。惩罚函数如下:

$$Z_3 = \sum_{k \in V} \sum_{j \in N} \left[ \gamma_1 \cdot \max(0, a_{jk} - l_j) + \gamma_2 \cdot \max(0, e_j - a_{jk}) \right] \quad (4)$$

其中,  $l_j$ 、 $e_j$  分别为客户允许的最早与最晚服务时间。

4) 货物非线性损耗成本  $Z_4$ :

在冷链配送中, 货物在运输及卸货过程中会因时间推移及温度变化而发生损耗, 采用非线性衰减函数进行建模, 分为运输阶段与卸货阶段两部分:

$$Z_4 = c \cdot \sum_{k \in V} \sum_{i \in N} \sum_{\substack{j \in N \\ j \neq i}} Q_{ij} \cdot x_{ijk} \cdot (1 - e^{-\rho_1 t_{ij}}) + c \cdot \sum_{k \in V} \sum_{i \in N} y_{ik} \cdot q_i \cdot (1 - e^{-\rho_2 \cdot s_{ik}}) \quad (5)$$

其中,  $Q_{ij}$  表示车辆在行驶路径段  $i \rightarrow j$  上所运输的剩余货物量。

5) 制冷成本  $Z_5$ :

冷藏车辆在配送过程中需持续运行蓄冷装置维持设定温度, 制冷成本与车辆蓄冷配置及运输时长有关, 建模如下:

$$Z_5 = \sum_{k \in V} \sum_{r \in R} \sum_{i \in N} \sum_{\substack{j \in N \\ j \neq i}} c_r \cdot p_k^r \cdot t_{ij} \cdot x_{ijk} \quad (6)$$

## 2.5. 约束条件

为保证模型解的可行性, 需满足以下约束:

(1) 客户唯一服务约束:

即每个客户只能被一辆车服务一次:

$$\sum_{k \in V} \sum_{\substack{i \in N \\ i \neq j}} x_{ijk} = 1, \forall j \in N, j \neq 0 \quad (7)$$

(2) 车辆容量限制:

车辆在任意配送路径中负载不得超过其最大载重:

$$\sum_{j \in N} q_j \cdot x_{ijk} \leq Q_k, \forall k \in V, i \in N \quad (8)$$

(3) 车辆始末点限制:

每辆车必须从配送中心出发并返回:

$$\sum_{j \in N} x_{0jk} = 1, \sum_{i \in N} x_{i0k} = 1, \forall k \in V \quad (9)$$

(4) 路径连续性约束:

车辆每进入一个节点也必须离开该节点:

$$\sum_{i \in N} x_{ihk} = \sum_{j \in N} x_{hjk}, \forall h \in N, k \in V \quad (10)$$

(5) 服务时间逻辑约束:

车辆  $k$  若从节点  $i$  到达节点  $j$ , 其到达时间必须考虑运输时间:

$$a_{jk} \geq a_{ik} + t_{ij} - M \cdot (1 - x_{ijk}), \forall i, j \in N, k \in V \quad (11)$$

其中,  $M$  为足够大的常数。

(6) 装载动态更新约束:

若车辆  $k$  从  $i$  到  $j$ , 其装载应扣除已配送货量:

$$l_{jk} \leq l_{ik} - q_j + M \cdot (1 - x_{ijk}), \forall i, j \in N, j \neq 0, k \in V \quad (12)$$

(7) 初始装载约束:

车辆离开配送中心时其装载应满足车辆容量:

$$l_{0k} \leq Q_k, \forall k \in V \quad (13)$$

(8) 载重非负约束:

$$0 \leq l_{ik} \leq Q_k, \forall i \in N, k \in V \quad (14)$$

(9) 货损约束(考虑装载与时间):

总运输过程中的损耗不能超过给定阈值:

$$\sum_{k \in V} \sum_{i \in N, j \in N, j \neq i} \rho \cdot t_{ij} \cdot l_{ik} \cdot x_{ijk} \leq \text{MaxLoss} \quad (15)$$

(10) 车辆蓄冷箱配置数量不得超过上限:

$$\sum_{r \in R} p_k^r \leq P_{\max}, \forall k \in V \quad (16)$$

(11) 变量定义域:

$$x_{ijk} \in \{0,1\}, a_{jk} \geq 0, l_{ik} \geq 0 \quad (17)$$

### 3. 状态感知蚁群算法(SA-ACA)

蚁群算法(ACA)是一种基于群体智能的信息素协同机制的启发式优化方法,能够有效求解路径优化问题,但在多约束和多目标情境下易陷入局部最优且搜索效率有限。为求解具有多目标与多约束的冷链物流车辆路径优化模型,本文提出一种状态感知蚁群算法(SA-ACA)。该算法融合了车辆状态建模机制、局部路径优化策略及精英信息素更新机制,在提升解的可行性与全局质量的同时,显著增强了收敛效率。其整体流程如图1所示。

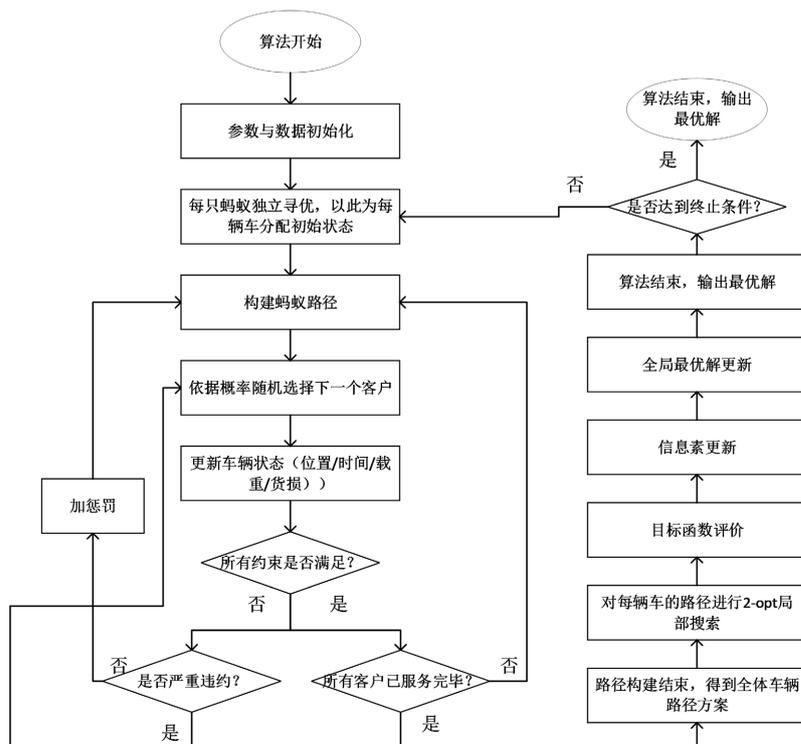


Figure 1. Flowchart of the SA-ACA algorithm

图1. SA-ACA 算法流程图

### 3.1. 路径构建

在路径构建过程中, SA-ACA 引入了车辆状态元组用于动态维护路径选择过程中的核心信息, 包括当前位置、累计运行时间、当前载重和累计货损等。设车辆当前状态为四元组  $(n, t, q, d)$ , 分别表示当前节点位置  $n$ 、累计时间  $t$ 、载重  $q$  及已产生货物损耗  $d$ 。在构建路径时, 蚁群依据当前状态, 动态评估所有未访问节点的状态转移成本, 并据此决定下一跳节点。

路径选择基于状态转移概率函数, 其计算表达式如下:

$$P_{ij} = \frac{\tau_{ij}^\alpha \cdot \eta_{ij}^\beta}{1 + \text{Penalty}_{ij}}$$

其中,  $\tau_{ij}$  表示边  $(i, j)$  的信息素浓度,  $\eta_{ij} = 1/d_{ij}$  为距离启发函数,  $\alpha$  与  $\beta$  分别控制两者的权重,  $\text{Penalty}_{ij}$  表示从节点  $i$  到节点  $j$  所引发的综合状态惩罚项。该惩罚函数主要考虑以下三类因素:

1. 时间窗违约惩罚: 若车辆到达时间超过节点最晚服务时间或早于最早服务时间, 将分别产生迟到或等待惩罚;
2. 货物损耗惩罚: 根据当前载重、行驶时间与损耗率估算路径段的货损量, 若累计货损超过设定阈值(如 20 单位), 将产生高额惩罚或直接判为不可行;
3. 容量限制与温区装载匹配: 节点需求包括冷藏与冷冻两类, 车辆需具备相应温区蓄冷箱, 且总装载量不得超过车辆最大载重。

若某候选节点导致路径不可行, 则其选择概率为 0。其余可行节点按照上述概率函数通过轮盘法选择, 逐步构建完整路径, 最终回到配送中心。

### 3.2. 局部搜索策略

为进一步提升解的质量并跳出局部最优, 本文引入基于路径交换的 2-opt 局部搜索策略。其基本步骤如下:

- (1) 对车辆路径中任意两节点  $(i, j)$ , 交换其访问顺序;
- (2) 若新的路径满足所有约束条件, 且整体目标函数值下降, 则接受该路径调整;
- (3) 每轮选取最优局部改进路径作为当前解。

### 3.3. 信息素更新机制

在信息素更新机制方面, 本文采用了蒸发与增强相结合的策略, 以避免信息素过度集中带来的早熟收敛问题。具体而言, 信息素的更新分为两个过程: 首先, 通过信息素蒸发机制, 按一定比例削减原有信息素浓度, 使其更新为  $\tau_{ij} \leftarrow (1 - \rho) \cdot \tau_{ij}$ , 其中,  $\rho$  为信息素挥发因子, 本文设定为 0.05。随后, 在每轮迭代中选取目标函数值最优的前  $K = 5$  条路径构成 Top-K 精英路径集合, 对于精英路径集合 Top-K 中的每一条路径  $p$ , 其对应的路径段  $(i, j)$  上的信息素按照以下方式增强:  $\tau_{ij} \leftarrow \tau_{ij} + \sum_{p \in \text{TopK}} \Delta \tau_{ij}^{(p)}, \Delta \tau_{ij}^{(p)} = \frac{Q}{Z_p}$ ,

其中  $Z_p$  为路径  $p$  的目标函数值,  $Q$  为信息素常量本文设定为 200。

### 3.4. 参数设置和终止条件

为保证算法在复杂约束下的稳定性与求解质量, 本文各关键参数在综合参考相关文献与实际调参基础上设定如下: 信息素重要度因子  $\alpha$  取 1.2, 启发式信息函数因子  $\beta$  设为 3, 信息素挥发系数  $\rho$  设定为 0.05, 以控制信息素浓度收敛速率; 每轮蚂蚁数量为 30, 最大迭代次数设为 300 轮。

在信息素增强阶段, 精英路径数量 Top-K 设为 5, 信息素增强常数  $Q$  取 200, 用于强化优秀路径段的

遗传保留效果。路径评估中, 车辆每条路径容许的最大累计货损阈值为 20 单位, 超出部分将以惩罚形式计入目标函数。

对于冷链车辆的制冷运行成本, 设定冷藏温区与冷冻温区的单位制冷成本分别为 1.8 元/分钟与 2.4 元/分钟, 车辆在构建路径时需按客户多温区需求配置对应的蓄冷箱并据此计算实际能耗成本。

算法将在满足最大迭代轮数、连续若干轮最优解无更新, 或达到预设满意度阈值时终止, 并输出当前最优路径及其分目标评估指标。

## 4. 数值实验

### 4.1. 实验场景设定

本实验以典型的冷链物流配送网络为背景, 模拟多温区生鲜商品在城市范围内的实际配送任务。配送网络由 1 个配送中心及 20 个客户节点组成, 配送中心的地理位置设定为坐标点(50, 50)。客户节点在二维空间中离散分布, 具备明确的服务时间窗、服务时长以及多温区货物需求, 客户点信息详见表 2。

Table 2. Customer node information table

表 2. 客户点信息表

节点编号	x 坐标	y 坐标	最早送达时间	最晚送达时间	服务时长	冷藏需求	冷冻需求
0	50	50	0	0	9999	0	0
1	37.454	61.185	63	123	14.541	7	4
2	95.071	13.949	144	204	12.283	8	8
3	73.199	29.214	97	157	5.382	7	5
4	59.866	36.636	64	124	8.77	6	11
5	15.602	45.607	121	181	7.049	6	1
6	15.599	78.518	127	187	14.219	4	13
7	5.808	19.967	136	196	8.236	7	5
8	86.618	51.423	111	171	9.08	3	5
9	60.112	59.241	89	149	5.846	10	12
10	70.807	4.645	134	194	12.224	9	3
11	2.058	60.754	129	189	9.712	7	1
12	96.991	17.052	131	191	8.731	1	5
13	83.244	6.505	102	162	12.089	6	4
14	21.234	94.889	73	133	10.455	8	6
15	18.182	96.563	75	135	7.121	2	6
16	18.34	80.84	138	198	12.36	14	3
17	30.424	30.461	109	169	6.194	4	12
18	52.476	9.767	90	150	13.626	3	3
19	43.195	68.423	78	138	13.836	5	9
20	29.123	44.015	64	124	6.342	4	4

在本文模型中, 最早和最晚送达时间的单位为分钟, 且时间窗基准点可根据实际需求设定。通常, 基准点由研究者或系统管理员选择(如凌晨四点), 时间窗的最早送达时间则为基准点后的分钟数。例如, 若基准点为凌晨四点, 客户的最早送达时间为 4:45, 则其实际最早送达时间为 45 分钟。此方式简化了时间管理, 灵活适配不同配送计划。

每个客户可同时提出冷藏(Zone 1)与冷冻(Zone 2)两类温区的配送需求。为精确建模客户异质性需求, 系统分别记录各节点的第一温区与第二温区需求量, 并在路径构建与车辆决策中进行温区匹配、载重控制与制冷成本评估。

系统配置 4 辆冷链配送车辆, 编号为 1 至 4。每辆车均设有最大载重、最大配送时间及蓄冷箱搭载上限(不超过 16 个)。车辆支持同时搭载冷藏与冷冻两类蓄冷装置, 其具体搭载组合由算法根据路径所涉客户需求动态决策。所有车辆均需从配送中心出发并最终返回中心, 完成封闭式配送任务。

配送过程中, 货物在运输与卸货阶段持续发生时间相关损耗, 单位时间货损率设定为 0.005。若某条路径累计货损超过系统设定的最大容许值(20 单位), 则超出部分将以货损惩罚的形式纳入目标函数中评估。制冷运行成本按路段时间与各温区蓄冷箱数量线性累计, 其中冷藏区单位制冷成本为 1.8 元/分钟, 冷冻区为 2.4 元/分钟。

本实验通过数值仿真评估所提出状态感知蚁群算法(SA-ACA)的优化效果, 重点考察其在运输成本、时间窗满足率、货物损耗控制与制冷能耗等关键指标上的表现。

### 4.2. 实验结果分析

图 2 和图 3 分别展示了 SA-ACA 与标准 ACA 在四车调度场景下的路径分配结果。相比之下, SA-ACA 生成的车辆路径在空间上更集中, 客户分配更具连贯性, 路径结构整体较为紧凑。标准 ACA 路径中存在部分跨区域跳跃与交叉, 服务节点分布较为分散。

表 3 与表 4 分别汇总了标准蚁群算法(ACA)与状态感知蚁群算法(SA-ACA)在四车辆调度下的各项成本明细。比较结果显示, SA-ACA 在时间窗约束与货物损耗控制方面整体表现更优。

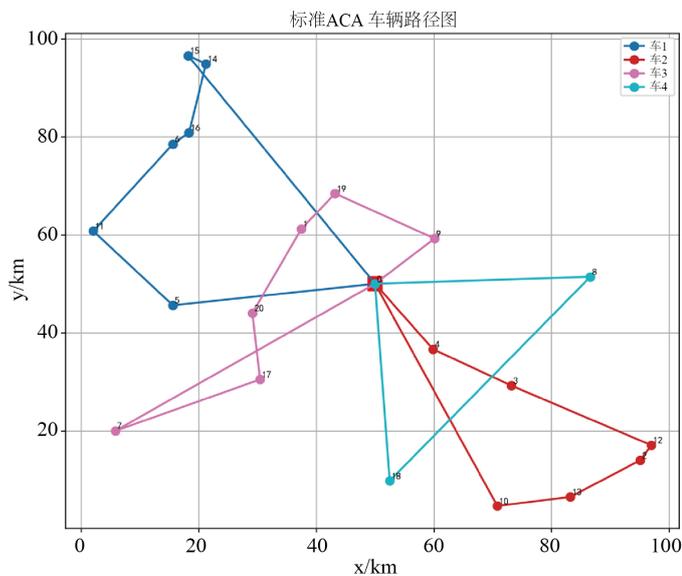
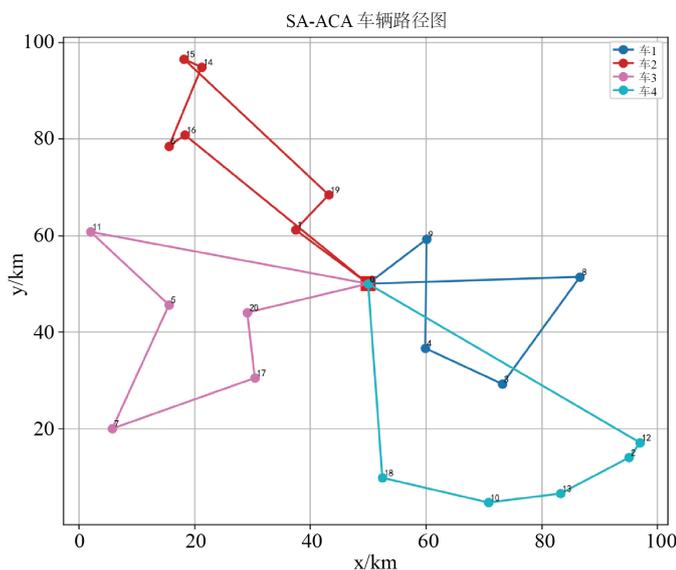


Figure 2. Optimal route assignment results of ant colony algorithm (ACA)

图 2. 蚁群算法(ACA)最优路径分配结果



**Figure 3.** Optimal route assignment results of state-aware ant colony algorithm (SA-ACA)

**图 3.** 状态感知蚁群算法(SA-ACA)最优路径分配结果

**Table 3.** Detailed target value breakdown for the ant colony algorithm (ACA)

**表 3.** 蚁群算法(ACA)各车辆详细目标值分解

车辆 ID	路径	Z	运输成本	时间窗惩罚	货损成本	制冷成本	配送耗时
1	[0, 15, 14, 16, 6, 11, 5, 0]	731.411	155.145	48.127	14.968	193.442	155.145
2	[0, 4, 3, 12, 2, 13, 10, 0]	658.276	138.690	40.880	22.845	172.001	138.690
3	[0, 9, 19, 1, 20, 17, 7, 0]	910.236	155.076	100.504	50.384	242.021	155.076
4	[0, 18, 8, 0]	538.471	130.814	24.846	0.000	120.422	130.814

**Table 4.** Detailed target value breakdown for the state-aware ant colony algorithm (SA-ACA)

**表 4.** 状态感知蚁群算法(SA-ACA)各车辆详细目标值分解

车辆 ID	路径	Z	运输成本	时间窗惩罚	货损成本	制冷成本	配送耗时
1	[0, 9, 4, 3, 8, 0]	577.484	114.158	37.651	5.779	192.411	114.158
2	[0, 1, 19, 15, 14, 6, 16, 0]	614.271	132.279	25.977	17.814	184.582	132.279
3	[0, 20, 17, 7, 5, 11, 0]	707.431	158.992	36.953	11.187	181.701	158.992
4	[0, 18, 10, 13, 2, 12, 0]	630.770	146.932	37.329	0.000	144.144	146.932

具体来看, 车辆 3 在 ACA 下的时间窗惩罚与货损成本分别为 100.504 元和 50.384 元, 而在 SA-ACA 下下降至 36.953 元和 11.187 元, 反映出状态建模机制有效改善了配送时效与货损积累。车辆 1 在两种算法下的时间窗惩罚分别为 48.127 元与 37.651 元, 亦有明显改善。

运输与制冷成本方面, 两种算法差距相对较小。例如, 车辆 4 在 ACA 与 SA-ACA 下的运输成本分别为 130.814 元与 146.932 元, 制冷成本分别为 120.422 元与 144.144 元, 波动幅度受路径覆盖范围和服务节点差异影响。

在目标函数 Z 值上, SA-ACA 优化后的车辆目标值更接近, 数值集中度较高, 任务分配趋于均衡。

相比之下, ACA 中车辆 3 的总目标值高达 910.236 元, 明显偏离其他车辆, 反映任务负载不均的问题更为突出。

整体结果说明, SA-ACA 在多约束路径构建中具备更好的协调能力, 能够在满足服务需求的同时有效控制关键运营成本, 提高调度方案的稳定性与可执行性。

图 4 展示了状态感知蚁群算法(SA-ACA)与标准蚁群算法(ACA)在冷链物流路径优化问题中的收敛曲线对比。由图可见, 两种算法在迭代过程中均表现出良好的收敛趋势, 目标函数值随迭代次数逐步下降并趋于稳定。

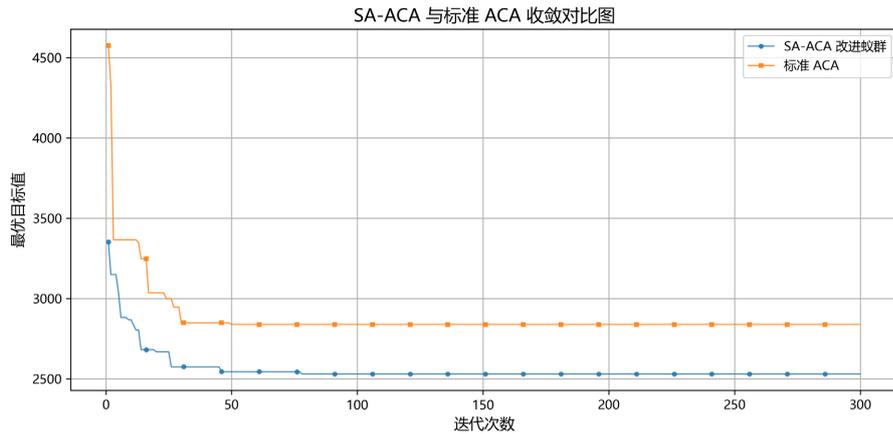


Figure 4. Convergence curve comparison between SA-ACA and standard ACA

图 4. SA-ACA 与标准 ACA 收敛曲线对比图

与标准 ACA 相比, SA-ACA 在收敛过程中表现出显著优势。其初始目标值较低, 生成的初始解质量更高, 能够更快进入优质解域。在前 50 次迭代中, SA-ACA 目标值快速下降并趋于稳定, 展现了较强的全局搜索能力和收敛效率。虽然标准 ACA 的收敛过程较为平稳, 但在前期搜索效率和最终解质量上均逊色于 SA-ACA。后期迭代的差距表明, SA-ACA 更有效地结合了路径构建、状态建模和惩罚机制, 在强约束环境下获得更优解。综上, SA-ACA 在初始解质量、收敛速度和最终优化效果上优于标准 ACA, 验证了其在多目标、多约束冷链物流路径优化中的应用潜力。

表 5 为状态感知蚁群算法(SA-ACA)与标准蚁群算法(ACA)在同一实验环境下的数值对比。

Table 5. Comparison of experimental results between ACA and SA-ACA

表 5. ACA 与 SA-ACA 的实验结果对比

	运输成本	时间窗惩罚	货损惩罚	制冷成本	配送耗时	加权总目标
标准蚁群算法 (ACA)	579.725	214.357	88.198	727.885	579.725	2838.394
改进蚁群算法 (SA-ACA)	552.362	137.910	34.710	702.838	552.362	2529.955
变化率	-4.72%	-35.66%	-60.57%	-3.44%	-4.72%	-10.87%

实验结果表明, SA-ACA 在运输成本、时间窗惩罚、货损成本和制冷成本方面均低于标准 ACA 算法, 综合目标值降低了 10.87%。其中, 时间窗和货损惩罚降幅较大, 分别为 35.66%和 60.57%, 显示出优化算法在时效与质量控制方面的优势。

## 5. 结束语

冷链物流的有效路径优化对企业降本增效、提高服务质量至关重要。本文基于多车辆、多目标、多约束的冷链配送问题,提出了一种状态感知蚁群算法(SA-ACA),充分考虑了运输成本、时间窗、货损及制冷等因素,动态建模了车辆状态,从而使路径优化模型更加贴近实际应用需求。针对传统蚁群算法在强约束多目标问题中的局限性,SA-ACA 通过结合局部搜索与精英信息素更新,显著提升了求解效率与解的全局性。

仿真结果表明,SA-ACA 在运输成本、货物损耗控制、时间窗遵守率及制冷能耗方面均优于传统蚁群算法,展现出较强的工程应用潜力。然而,本文研究的局限在于仅考虑了单一配送中心的情境,且未涉及客户需求的动态变化。未来的研究可扩展至多配送中心与动态需求的复杂场景,以进一步提升模型的适用性和鲁棒性。

## 参考文献

- [1] 宾厚,徐晶晶,王素杰. 基于动态需求的生鲜农产品冷链物流配送路径优化[J]. 枣庄学院学报, 2024, 41(5): 13-24.
- [2] 许志豪,刘慧勇,方德英. 基于改进人工蜂群算法的冷链物流配送路径优化[J]. 物流科技, 2025, 48(1): 155-160.
- [3] 王胜源,王珍. 基于改进遗传算法的冷鲜肉配送路径优化研究[J]. 物流科技, 2025, 48(7): 15-19.
- [4] 张富慧. 基于改进遗传算法的生鲜农产品冷链物流低碳配送路径优化研究[D]: [硕士学位论文]. 太原: 山西财经大学, 2024.
- [5] 吕勇强. 基于改进蚁群算法的低碳冷链物流路径优化[D]: [硕士学位论文]. 淮南: 安徽理工大学, 2024.
- [6] 栗治杰,贾东水. 基于双层规划的冷链物流配送路径规划及其算法研究[J]. 中国储运, 2025(5): 183-184.
- [7] 王宁,杨正华. 基于蚁群算法的多目标农产品物流配送路径优化[J]. 计算机应用, 2024(9): 108-116.
- [8] 曹菁菁,魏杰,雷阿会,韩鹏,冯子立,王梦简. 考虑交通拥堵的冷链配送路径动态优化[J]. 计算机应用研究, 2025, 42(8): 1-12.
- [9] 陈妮. 时间窗约束下农产品物流配送路径优化研究[J]. 自动化技术与应用, 2024, 43(2): 17-22.
- [10] 张雯惠,徐玲玲. 碳交易机制下考虑客户满意度的冷链物流配送路径优化[J]. 公用事业管理, 2025(4): 48-61.