

控制与决策

Control and Decision

考虑动态配送时间需求的多策略协同车辆路径优化算法

侯莹, 乔聃, 韩红桂

引用本文:

侯莹, 乔聃, 韩红桂. 考虑动态配送时间需求的多策略协同车辆路径优化算法[J]. *控制与决策*, 2026, 41(4): 1143-1153.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0908>

您可能感兴趣的其他文章

Articles you may be interested in

需求波动下考虑乘运供应能力的网约车平台动态定价

Dynamic pricing for ride-hailing platform with demand fluctuation and supply capacity
控制与决策. 2021, 36(6): 1499-1508 <https://doi.org/10.13195/j.kzyjc.2019.0881>

基于粒子群算法的满载需求可拆分车辆路径规划

Split vehicle route planning with full load demand based on particle swarm optimization
控制与决策. 2021, 36(6): 1397-1406 <https://doi.org/10.13195/j.kzyjc.2019.1323>

基于Frenet坐标系的自动驾驶轨迹规划与优化算法

Trajectory planning and optimization algorithm for automated driving based on Frenet coordinate system
控制与决策. 2021, 36(4): 815-824 <https://doi.org/10.13195/j.kzyjc.2019.0748>

基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM
控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

现货市场补充作用下基于总量折扣的运输服务采购问题研究

Transportation service procurement based on total discount under complementary effect of spot market
控制与决策. 2021, 36(11): 2794-2802 <https://doi.org/10.13195/j.kzyjc.2020.0274>

考虑动态配送时间需求的多策略协同车辆路径优化算法

侯莹^{1,2†}, 乔聃^{1,2}, 韩红桂^{1,2}

(1. 北京工业大学信息科学技术学院, 北京 100124; 2. 数字社区教育部工程研究中心, 北京 100124)

摘要: 在城市物流配送行业中, 配送时间需求的变化直接干扰配送方案的制定, 影响配送效率, 给高效寻找车辆路径方案带来了挑战. 鉴于此, 提出考虑动态配送时间需求的多策略协同车辆路径优化算法. 首先, 构建一个动态车辆路径优化模型, 根据配送时间需求变化带来的影响设计约束条件, 将最短行驶距离、最小等待时间和最少车辆使用数作为优化目标; 其次, 定性分析配送时间需求的变化类型, 定量描述配送时间需求变化强度, 设计需求变化连锁影响因子, 研究动态配送时间需求综合评价指标; 最后, 构建差分进化算法进化策略库, 根据配送时间需求的变化类型和时间需求综合评价指标, 筛选重点优化客户, 设计多策略协同车辆路径优化算法. 实验结果表明, 所提出方法能够定性分析和定量表征客户配送时间需求的变化, 显著降低配送时间需求变化对配送方案的影响, 提升车辆路径优化效率.

关键词: 配送时间需求; 车辆路径问题; 连锁影响因子; 动态优化; 多策略协同; 差分进化算法

中图分类号: TP181; U491 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0908

引用格式: 侯莹, 乔聃, 韩红桂. 考虑动态配送时间需求的多策略协同车辆路径优化算法 [J]. 控制与决策, 2026, 41(4): 1143-1153.

Multi-strategy collaborative vehicle routing optimization algorithm considering dynamic delivery time requirements

HOU Ying^{1,2†}, QIAO Dan^{1,2}, HAN Hong-gui^{1,2}

(1. School of Information Science and Technology, Beijing University of Technology, Beijing 100124, China; 2. Engineering Research Center of Digital Community of Ministry of Education, Beijing 100124, China)

Abstract: In the urban logistics distribution industry, fluctuations in delivery time requirements directly disrupt the formulation of distribution plans, adversely affecting delivery efficiency and posing significant challenges to the effective determination of vehicle routing solutions. To address these challenges, a multi-strategy collaborative vehicle routing optimization algorithm considering dynamic delivery time requirements is proposed. Firstly, a dynamic vehicle routing optimization model is constructed, in which constraints are designed based on the impact of changes in customer time windows. The shortest travel distance, minimum waiting time, and least number of vehicles used are set as optimization objectives. Secondly, the types of changes in delivery time requirements are qualitatively analysed, and the intensity of such changes is quantitatively described. The chain impact factors of changing requirements are designed, and a comprehensive evaluation index for dynamic delivery time requirements is investigated. Finally, a strategy library for differential evolution algorithms is established. The priority of key optimization customers is identified based on the types of changes in delivery time requirements and comprehensive evaluation indicators of time requirements. And a multi-strategy collaborative vehicle routing optimization algorithm is developed. Experimental results demonstrate that the proposed method enables both qualitative analysis and quantitative characterization of changes in customer delivery time requirements, reduces the impact of delivery time requirement fluctuations on distribution plans significantly, and enhances the efficiency of vehicle routing optimization.

Keywords: delivery time requirements; vehicle routing problem; chain influence factor; dynamic optimization; multi-strategy collaborative; differential evolution algorithm

收稿日期: 2025-08-31; 录用日期: 2025-10-21.

基金项目: 国家自然科学基金项目 (62373011); 国家重点研发计划项目 (2023YFB3308004); 北京市青年学者基金项目 (037).

责任编辑: 王凌.

†通信作者. E-mail: houying17@sina.com.

0 引言

近年来,随着城市化进程的加快和电子商务的发展,居民对高效智能化物流服务的需求日益强烈.各国政府高度重视物流行业发展,相继出台政策推动物流效率的提升.2019年,我国出台了《关于推动物流高质量发展促进形成强大国内市场的意见》,明确提出要提高物流运输效率、降低物流成本^[1];此外,欧盟各成员国也积极推行新政,支持数字技术在物流领域的应用.在市场需求和政策的推动下,物流行业加速智能化转型,广泛应用智能调度、大数据和物联网等新兴技术^[2].然而,由于路面交通、客户配送需求和配送条件存在时变特征,目前的车辆路径优化方法难以满足现代物流高效灵活的配送要求.因此,研究适用于动态配送环境的车辆路径优化方法,是提升物流业配送效率的关键^[3-4].

动态车辆路径问题 (dynamic vehicle routing problem, DVRP) 是在车辆路径问题基础上发展而来的,其核心在于应对现实物流环境中的动态变化. DVRP 的主要挑战在于以最小总配送成本或最大服务质量为目标,兼顾车辆容量、客户配送时间需求,即客户时间窗、服务时间等多重约束,在有限的计算时间内快速响应动态信息,获得最优的车辆路径优化方案,从而提升物流效率、降低运营成本、增强客户满意度.

在物流配送过程中,存在路况、交通管制、天气等外部环境的不确定性因素,使车辆路径方案难以适应实际需求,需要研究能快速响应外部变化的动态车辆路径优化方法.已有研究提出了多种应对策略,例如, Sze 等^[5]针对交通环境动态变化的挑战,提出了一种自适应邻域搜索算法,该方法采用两阶段策略:第1阶段,在静态环境中生成初始路线作为学习资源,并根据交通状况变化进行动态调整;第2阶段,根据第1阶段获得的经验信息,通过伪随机选择程序,设计动态邻域操作和局部搜索策略,同时嵌入大邻域搜索以增强解的多样性.实验结果表明,自适应邻域搜索算法在交通条件变化时,具有良好的灵活性,能够有效应对实时交通信息对路径规划的影响.为应对服务环境和约束条件的动态变化, Demirbilek^[6]研究了动态车辆路径问题中的可选和强制分配策略,提出了基于接受/拒绝策略的多规划方法和基于强制分配策略的多规划方法,通过考虑已分配客户、新请求客户和模拟未来客户的需求,在动态条件下求取最优路径方案.实验结果表明,与传统算法相比,所提出方法大幅提升了平均接受率,显

著减少了日均旅行时间,有效提升了系统在复杂动态环境下的鲁棒性.针对动态电动汽车路由问题, Wang 等^[7]提出了基于混合充电策略的多目标优化方法,该方法综合考虑充电站可用性、电价波动、充电技术多样性等多种外部环境因素的动态变化,构建了多目标优化模型,采用进化算法处理充电环境的不确定性.实验结果表明,该混合充电策略能够有效应对充电基础设施的动态变化,在保证服务质量的同时,显著降低运营成本和充电等待时间.这些成果为 DVRP 的实际应用奠定了基础,但随着物流需求个性化和精细化发展,只关注外部变化已难以满足现代物流系统需求,研究重点逐步转向内部动态因素.

与外部环境变化不同,物流系统内部的动态变化具有实时性强、变化频繁、影响多个优化环节等特点,给车辆路径优化带来更高的挑战.为应对协作车队内部任务分配和负载均衡的动态变化, Sánchez 等^[8]提出了车辆间信息共享机制和动态任务重分配算法,该方法根据各车辆的实时负载情况和服务能力变化,动态调整任务分配策略,确保系统整体效率的同时兼顾各车辆间的公平性.实验结果表明,该协作机制在处理内部任务动态变化时,能够显著提升车队整体性能和资源利用率. Botros 等^[9]针对动态环境下任务等待时间的变化,提出了基于成本函数优化的任务等待时间优化方法,该研究针对客户到达和服务位置不确定性导致的任务等待时间波动问题,建立了考虑任务优先级的动态优化模型,设计累积等待时间成本函数,根据任务队列的实时变化,持续优化任务调度顺序和车辆分配方案.在多种动态需求场景下的仿真实验表明,该方法能够有效减少任务平均等待时间. Wang 等^[10]针对大规模客户需求随机变化的内部动态性,提出了一种处理随机请求的大规模动态车辆路径问题求解方法,该方法构建了随机规划模型,设计了高效的启发式算法,重点解决客户需求量动态波动、服务请求随机到达以及客户偏好实时变化等内部因素对路径规划的影响.实验结果表明,该方法能够有效应对现实物流系统中客户需求的内在不确定性. Wang 等^[11]提出了一种基于集成学习的多目标进化算法,该方法构建了多目标优化模型,设计了多种预测与优化策略,以应对客户随机请求、服务时间变化等动态因素.实验结果表明,该方法能够平衡多个优化目标,有效解决带时间窗的动态车辆路径问题.以上研究在处理各类内部动态因素方面取得了显著进展,但内部因素中的客户时间窗变化类型多,具有联动影响属性,其变

化量不仅会直接影响当前客户的服务,还会通过配送网络影响到其他客户的服务顺序和路径安排.现有方法往往采用单一优化策略,难以响应各类型时间窗变化需求,存在适应性不足、响应策略受限、优化效果欠佳的问题.

针对上述不足,本文提出一种考虑动态配送时间需求的多策略协同车辆路径优化方法,主要创新包括:构建动态车辆路径优化模型,将等待时间、路径成本与最少车辆使用数同步优化;提出动态时间窗扰动分类与强度量化机制,描述时间窗变化对路径优化的联动影响;提出多策略协同车辆路径优化算法,显著提升算法在动态配送时间需求场景下的寻优效率和鲁棒性.

1 动态车辆路径优化模型

1.1 问题描述

考虑动态配送时间需求的车辆路径优化问题描述如下:配送公司安排多辆配送车从一个车场出发,同时为多位客户配送货物,车场位置、车辆容量、客户数量、客户位置、客户配送需求量、客户配送时间需求以及客户服务时长已知,每辆车根据规划的最优路径进行配送.在实际配送过程中,客户临时调整收货时间,变更配送时间需求.此时,配送公司必须及时响应客户需求的变化,快速调整配送方案.

为便于分析和研究问题,做出以下假设:

- 1) 配送车辆是同一车型,从配送车场出发,完成任务后返回原车场;
- 2) 客户的需求量均小于车辆容量;
- 3) 每位客户由且仅由一辆车服务;
- 4) 客户的开始服务时间和完成服务时间需在最早服务时间与最晚服务时间之间.

1.2 集合和变量

客户: $c = \{0, 1, \dots, N\}$, 共 $N+1$ 个客户 (配送中心为客户0);

车辆: $k = \{1, 2, \dots, K\}$, 共 K 辆车;

车辆的容量: Q ;

客户 i 的配送需求量: q_i ;

客户 i 到客户 j 的距离: d_{ij} ;

车辆 k 的行驶速度: v_k ;

客户 i 的服务时间窗: $[t_i^l, t_i^r]$;

车辆 k 到达客户 i 的时间: t_{ik}^a ;

车辆 k 离开客户 i 的时间: t_{ik}^d .

1.3 车辆路径优化数学模型

1.3.1 决策变量

x_{ij}^k : 若车辆 k 从客户 i 到客户 j 服务, 则 $x_{ij}^k = 1$,

否则为 0.

z_k : 表示车辆 k 是否被使用, 若车辆被使用, 则 $z_k = 1$; 否则, $z_k = 0$.

1.3.2 目标函数

$Y_1 = \min \left(\sum_{k \in K} \sum_{i \in C} \sum_{j \in C} d_{ij} \cdot x_{ij}^k \right)$: 最小化车辆行驶总距离.

$Y_2 = \min \left(\sum_{k \in K} \sum_{i \in C} \max(0, t_i^l - t_{ik}^a) \right)$: 最小化等待时间.

$Y_3 = \min \left(\sum_{k \in K} z_k \right)$: 最小化车辆使用数.

1.3.3 约束条件

$\sum_{k \in K} \sum_{j \in C} x_{ij}^k = 1, \forall i \in C$: 每个客户必须被一辆车服务一次.

$\sum_{j \in C} x_{ij}^k - \sum_{j \in C} x_{ji}^k = 0, \forall i \in C, \forall k \in K$: 车辆从客户 i 出发后必须到达另一个客户或回到配送中心.

$t_i^l \leq t_i^a \leq t_i^r, \forall i \in C$: 车辆到达客户 i 的时间必须满足更新后的时间窗.

$t_j > t_i^d + t_{ij}, \forall i, j \in C, \forall k \in K$: 客户 j 的到达时间依赖于客户 i 的离开时间和客户 i 到达客户 j 的行驶时间.

$\sum_{i \in C} q_i \cdot x_{ij}^k \leq Q_k, \forall k \in K$: 每辆车的总装载量不能超过容量上限.

2 多策略协同车辆路径优化方法

车辆路径优化问题因其复杂性,通常使用启发式算法、元启发式算法、多目标优化算法等算法进行求解^[12-14].考虑动态配送时间需求,根据问题与模型的特点,设计了一种多策略协同车辆路径优化算法 (multi strategy collaborative vehicle routing optimization algorithm considering dynamic delivery time requirements, MSC-DDTR),定性分析并定量描述配送时间需求变化,综合考虑不同客户的调整必要性及优先级,确定最佳的进化策略,以提升算法对动态环境的响应性能,提高物流配送效率.考虑动态配送时间需求的多策略协同车辆路径优化方法的总框图如图1所示.

2.1 配送时间需求类型

根据客户配送时间需求变化情况,设计客户配送时间需求变化类型分类规则,具体如下.

- 1) 单边变化时间窗.

假设有客户 e 、客户 i 、客户 n , 其中客户 i 的左时

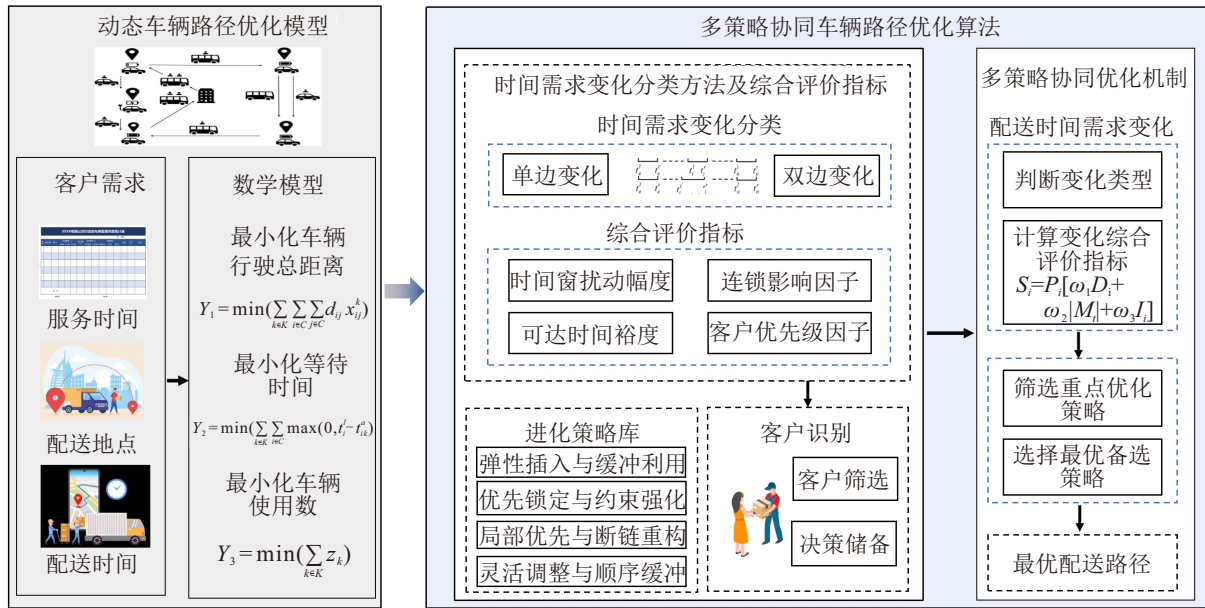


图1 考虑动态配送时间需求的多策略协同车辆路径优化方法

间窗 t_i^l 发生左移, 定义为起始松弛型; 客户 i 的左时间窗 t_i^l 发生右移, 定义为起始紧缩型; 客户 i 的右时间窗 t_i^r 发生右移, 定义为终止松弛型; 客户 i 的右时间窗 t_i^r 发生左移, 定义为终止紧缩型. 假设客户 i 的时间窗发生变化, 则不同单边变化类型分别如图2(a)~(d)所示.




图2 单边变化时间窗类型示例

2) 双边变化时间窗.

假设有客户 e 、客户 i 、客户 n , 其中客户 i 的左时间窗 t_i^l 发生左移, 且客户 i 的右时间窗 t_i^r 发生左移, 定义为双边左移型; 客户 i 的左时间窗 t_i^l 发生左移, 且客户 i 的右时间窗 t_i^r 发生右移, 定义为双边松弛型; 客户 i 的左时间窗 t_i^l 发生右移, 且客户 i 的右时间窗 t_i^r 发生左移, 定义为双边紧缩型; 客户 i 的左时间窗 t_i^l 发生右移, 且客户 i 的右时间窗 t_i^r 发生右移, 定义为双边右移型. 假设客户 i 的时间窗发生变化, 则不同双边变化类型分别如图3(a)~(d)所示.




图3 双边变化时间窗类型示例

2.2 动态配送时间需求综合评价指标

考虑时间窗扰动幅度、可达时间裕度、连锁影响因子以及客户优先级因子4个维度, 构建客户动态配送时间需求综合评价指标.

2.2.1 变量与符号定义

变量与符号定义如下:

- t_i^s : 客户 i 的服务时间;
- $\Delta t_i^l = t_i^{l'} - t_i^l$: 客户 i 的左时间窗变化量;
- $\Delta t_i^r = t_i^{r'} - t_i^r$: 客户 i 的右时间窗变化量;
- γ_i^l : 客户 i 左时间窗扰动类型因子;
- γ_i^r : 客户 i 右时间窗扰动类型因子;
- M_i : 客户 i 的可达时间裕度;
- $\alpha_{i,j}$: 客户 i 与客户 j 的依赖系数;
- I_i : 客户 i 的需求变化连锁影响因子;
- D_i : 客户 i 的时间窗扰动幅度;
- P_i : 客户 i 的需求变化处理优先级因子;
- S_i : 动态配送时间需求综合评价指标;

$\omega_1, \omega_2, \omega_3$: 综合评价指标各分量权重.

2.2.2 动态配送时间需求综合评价指标

1) 时间窗扰动幅度.

根据扰动类型, 计算反映客户 i 的时间窗变化扰动幅度如下:

$$D_i = |\gamma_i^l \cdot \Delta t_i^l| + |\gamma_i^r \cdot \Delta t_i^r|, \quad (1)$$

其中 γ_i^l 与 γ_i^r 的取值规则如表 1 所示. 表 1 中左右时间窗扰动类型因子的数值, 根据客户配送时间窗左右端点的变化方向进行设计, 旨在将不同类型的时间窗扰动转化为模型可识别的参数, 表征各类变化对车辆路径优化过程带来的影响.

表1 γ_i^l 与 γ_i^r 的取值规则

配送时间需求变化类型	γ_i^l	γ_i^r
起始松弛型	-1	0
起始紧缩型	1	0
终止松弛型	0	-1
终止紧缩型	0	1
双边松弛型	-1	-1
双边紧缩型	1	1
双边左移型	-1	1
双边右移型	1	-1

2) 可达时间裕度.

车辆到达客户 i 的可达时间裕度计算如下:

$$M_i = \min\{t_{ik}^a - t_i^{l'}, t_i^{r'} - t_i^s - t_{ik}^a\}. \quad (2)$$

可达时间裕度用于量化车辆到达客户 i 时, 与该客户时间窗边界的时间剩余量. 式 (2) 通过计算车辆实际到达时间与客户时间窗起止点的差值, 选取最小值作为裕度指标, 从而反映在当前路径安排下, 客户时间窗的动态变化对车辆调度灵活性的影响.

当客户的配送时间需求发生变化 (如时间窗变化为收紧或松弛), 其时间窗参数 t_i^l, t_i^r 会相应调整, 导致可达时间裕度 M_i 发生变化. 时间窗的松弛 (扩大) 会增加裕度, 提升调度灵活性; 时间窗的紧缩 (缩小) 则减少裕度, 增加调度难度.

3) 连锁影响因子.

客户 i 的时间窗扰动对后续客户的连锁影响因子计算如下:

$$I_i = \sum_{j=i+1}^N (\gamma_i^l |\Delta t_i^l| + \gamma_i^r |\Delta t_i^r|) \alpha_{i,j}. \quad (3)$$

其中: $\alpha_{i,j} = \frac{t_j^l - t_i^l}{T}$, $T = t_n^d - t_i^a$ 为后续总路径时长.

连锁影响因子用于定量评估客户 i 的时间窗扰动对后续路径上其他客户的累计影响. 式 (3) 通过引

入时间窗扰动类型因子 γ_i^l, γ_i^r 及变化幅度 $|\Delta t_i^l|, |\Delta t_i^r|$, 结合客户间影响权重 $\alpha_{i,j}$, 将客户时间窗变化类型和强度转化为对路径连锁影响的量化指标.

当客户时间窗大幅收紧, 连锁影响因子值会显著增大, 表示该客户的扰动对整体路径影响较大; 反之, 若时间窗变化幅度较小或为松弛, 则影响因子较低.

4) 客户优先级因子.

反映不同客户需求变化的优先处理权重, 客户优先级因子 P_i 取值如表 2 所示. 表 2 中, 客户优先级因子的数值根据不同客户时间窗变化类型对整体路径调整的影响程度不同进行设计, 旨在引导算法优先处理对路径影响较大的客户, 表中数值并非绝对量化值, 仅需保证高优先级客户对应较大权重即可.

表2 客户优先级因子取值

配送时间需求变化类型	P_i
左时间窗提前; 右时间窗延迟; 双边松弛型	0.5
右时间窗提前及双边左移型且 $t_i^a + t_i^s \leq t_i^{r'}$	1
左时间窗延迟及双边右移型且 $t_i^s > t_i^{l'}$	1
右时间窗提前及双边左移型且 $t_i^a + t_i^s > t_i^{r'}$	1.5
左时间窗延迟及双边右移型且 $t_i^s \leq t_i^{l'}$	1.5
双边紧缩型	1.5

基于上述分量, 客户 i 的动态配送时间需求综合评价指标定义如下:

$$S_i = P_i [\omega_1 D_i + \omega_2 |M_i| + \omega_3 I_i], \quad (4)$$

其中 S_i 各分量权重取值分别为 $\omega_1 = 0.2, \omega_2 = 0.2, \omega_3 = 0.6$. 式 (4) 中 3 个分量权重值根据研究关注点确定, 可以灵活调整. 本文主要考虑客户时间窗变化对后续客户的影响, 因此更关注连锁影响因子, 设置 $\omega_3 = 0.6$.

2.3 差分进化算法进化策略库与优化决策

差分进化算法是一种高效的群体智能优化方法, 具有强大的全局搜索能力, 适用于复杂的动态路径优化问题. 本节针对不同类型客户, 建立路径优化差分进化算法进化策略库^[15], 设计指标驱动的动态优化决策方法用于筛选重点优化对象, 提升路径调整的针对性与效率.

2.3.1 差分进化算法进化策略库

为有效应对动态配送环境下客户时间需求的频繁扰动, 本节依据客户时间窗变化的方向与幅度, 将客户类型进行系统划分. 具体而言, 根据时间窗的松弛或紧缩特征, 将客户分为松弛型、紧缩型和双边变化型; 同时, 结合客户配送时间需求变化对路径全局

的影响程度,进一步识别高连锁影响客户与低优先级客户,为后续差异化的调度与优化策略设计提供理论依据。

1) 弹性插入与缓冲利用策略.

松弛型扰动客户的服务时间窗被放宽,服务可达裕度大,对路径约束弱,因此适合作为路径调整的“缓冲节点”,提升调度灵活性。

进化算法中的具体实现如下:

① 编码阶段:在个体编码(路径序列)时,将松弛型客户标记为“弹性节点”;

② 变异操作:在差分变异算子生成新解时,优先允许松弛型客户参与位置交换、插入等操作,增加其在路径中的流动性;

③ 适应度评估:对松弛型客户的时间窗违约惩罚权重设置较低,鼓励算法优先满足紧张客户的约束;

④ 选择操作:若解中存在路径冲突,则优先调整松弛型客户的服务顺序,辅助算法跳出局部最优。

2) 优先锁定与约束强化策略.

紧缩型扰动客户时间窗收紧,服务裕度小,极易成为路径失效风险点,需优先保障其服务可行性。

进化算法中的具体实现如下。

① 编码阶段:将紧缩型客户标记为“刚性节点”,在初始种群生成时,尽量安排其靠前服务;

② 变异与交叉操作:限制紧缩型客户的位置变动幅度,仅允许微调,且优先保证其在服务时间窗内被访问;

③ 适应度评估:对紧缩型客户的时间窗违约设置高权重惩罚,降低违约解的适应度;

④ 选择操作:若变异或交叉产生的解导致紧缩型客户违约,则直接淘汰或局部重构。

3) 局部优先与断链重构策略.

高连锁影响客户的时间窗扰动会对后续多个客户产生级联影响,可能引发路径整体失效,应优先处理。

进化算法中的具体实现如下:

① 编码阶段:为高连锁影响客户设置高优先级标签;

② 变异操作:在变异生成新解时,优先调整高连锁影响客户及其相邻节点的服务顺序,采用“局部断链重构”策略,单独优化其影响区段;

③ 适应度评估:对连锁影响因子高的客户,服务违约惩罚进一步加重,算法自动规避其违约风险;

④ 选择操作:当检测到连锁影响超阈值时,触发

分段优化,仅对高影响区段做深度调整,减少全局扰动。

4) 灵活调整与顺序缓冲策略.

低优先级客户对路径优化影响有限,可作为调度的“调整余地”,以保障整体效率。

进化算法中的具体实现如下:

① 编码阶段:低优先级客户标记为“缓冲节点”,在初始种群中安排在路径末端或与其他低优先级客户合并;

② 变异与交叉操作:在优化过程中,优先允许低优先级客户的顺序变动;

③ 适应度评估:对低优先级客户的时间窗违约惩罚权重降低,扩大可行解空间;

④ 选择操作:资源紧张或路径冲突时,优先调整低优先级客户的服务顺序,释放调度空间,提高整体鲁棒性。

2.3.2 客户服务优先级及优化决策机制

本节基于客户配送时间需求变化分类和动态配送时间需求综合评价指标,采用归一化排序和分层筛选的方法,确定需重点优化的客户对象并选择最优策略。

1) 需求变化客户识别与分层筛选.

针对所有发生时间需求变化的客户(记为变化客户集),计算其动态配送时间需求综合评价指标 S_i ,并进行归一化处理,有

$$S_i^* = \frac{S_i - \min(S)}{\max(S) - \min(S)}, \quad (5)$$

其中 $\max(S)$, $\min(S)$ 分别为变化客户集中指标的最大值和最小值.该机制能够识别出对整体路径影响最大的关键客户,为后续优化提供有针对性的决策依据。

2) 客户筛选及优化决策机制.

将客户按归一化指标 S_i^* 从高到低排序,选取排名前60%的客户作为重点优化客户.以重点优化客户为中心,优先对其及其直接相关的路径段进行优化调整,其余客户作为一般优化对象,仅在资源充裕或局部冲突时考虑调整。

针对所有时间需求变化的客户,首先通过动态配送时间需求综合评价指标归一化与分层筛选,确定重点优化客户,并依据客户类型选定相应优化策略.动态调整各类客户在差分进化算法中的算子操作权重,通过适应度函数对每代候选解进行综合评价.最终,筛选到最优解,作为车辆路径优化方案.该机制能够区别处理不同层级客户,优先调整关键路段,结合客户类型选择最优优化策略,有效提升计算

效率.

3 实验设计与结果分析

3.1 实验数据

本研究采用 Solomon VRPTW 基准实例集中的 C1 类、C2 类、R1 类、R2 类、RC1 类、RC2 类数据集进行实验, 这些数据集是车辆路径问题研究中广泛使用的标准测试集, 每类数据集的特点如表 3 所示.

表3 Solomon 基准实例集特点

数据集	客户分布	时间窗	车辆容量	车辆数量
C1	聚类型	严格	200	25
C2	聚类型	较宽松	700	25
R1	随机型	严格	200	25
R2	随机型	较宽松	1000	25
RC1	混合型	严格	200	25
RC2	混合型	较宽松	1000	25

根据各类数据集的特点, 在本实验中, C1 类数据集用于测试算法在处理紧密时间约束和地理聚集客户时的性能; C2 类用于测试算法在处理长距离路径规划和宽松时间约束情况下的优化性能; R1 类用于测试算法在处理分散客户和严格时间约束下的路径优化性能; R2 类用于测试算法的长距离规划的性能; RC1 类用于测试算法在混合分布客户和严格时间约束下的适应性; RC2 用于测试算法在处理复杂客户分布模式和宽松时间约束下的优化能力以及长距离路径规划的效率.

3.2 实验环境与设置

3.2.1 实验环境

实验使用 64 位的 Windows 操作系统, Intel Core i5-13600KF @3.50 GHz, 16 GB 内存, 开发语言为 Python3.11, 开发工具为 PyCharm2023.1.

3.2.2 实验设置

为了模拟现实场景中客户配送时间窗的动态变化, 设计配送时间需求变动规则如下:

1) 变动比例: 随机选择 10%、30% 和 50% 的客户进行时间窗调整.

2) 变动类型: 包含单边变化时间窗和双边变化时间窗, 在实验中随机选取.

3) 变动强度: 配送时间需求变动 10 ~ 20 个时间单位为一般扰动, 变动 20 ~ 30 个时间单位为强扰动, 在实验中随机选取.

4) 实验参数: 种群规模设置为 100, 迭代次数设置为 200, 各类算法采用相同的初始解和随机扰动方案.

3.2.3 评价指标

1) 超体积.

超体积 (hypervolume, HV) 指标能够同时考虑解集的收敛性和多样性, 是评价多目标优化算法性能的综合指标. 本文通过多次运行所提出算法和对比算法构建参考集, 基于参考集确定统一参考点, 以全面评估算法性能.

2) 车辆使用数.

车辆使用数指标用于衡量在完成所有配送任务时实际派出的车辆数量, 该指标能够直接反映调度方案在资源利用方面的紧凑性和经济性. 本文统计各算法在每次实验运行中所需车辆的数量, 以评估其在降低运营成本和提升车辆利用率方面的优化能力.

3) 总行驶距离.

总行驶距离指标表示所有车辆在完成全部配送任务过程中所行驶路程的总和, 该指标能够有效反映路径规划方案的运输效率和运营成本. 本文记录各算法在每次实验中的总行驶距离, 以评价其在降低能耗、减少运输成本以及提升配送效率等方面的表现.

4) 总等待时间.

等待时间指标是指所有客户或任务从请求服务到实际被服务之间的累计等待时间, 该指标反映解决方案在保障服务及时性和提升客户满意度方面的能力. 本文统计各算法在每次实验中产生的总等待时间, 以综合评估其在优化服务质量和响应速度方面的效果.

3.3 实验结果与讨论

所有实验均在相同的 Solomon 标准数据集及设定的扰动比例下进行. 本文所提出方法为 MSC-DDTR, 对比算法为一种针对带时间窗多车场动态车辆路径问题的自适应大邻域搜索算法 (ALNS)^[10] 和一种针对动态时间窗车辆路径问题的基于集成学习的多目标进化算法 (EL-DMOEA)^[11], 实验结果如表 4 所示.

3.3.1 实验结果分析

表 4 展示了 MSC-DDTR 算法在不同配送时间需求变动比例下的寻优性能. 根据表 4 的数据, MSC-DDTR 在所有实例和不同变动比例下, 平均 HV 值达到 0.509 8, 显著高于 ALNS 的 0.386 8 和 EL-DMOEA 的 0.456 5, 表明其在多目标权衡和收敛性方面具有显著优势. 从胜出次数统计来看, MSC-DDTR 和 EL-DMOEA 在 HV 指标上各获得 9 次最优表现, 而 ALNS 在所有测试案例中均未取得最佳

表4 多策略协同路径优化算法性能

实例	时间需求 变动比例	HV			车辆数			总行驶距离			总等待时间		
		MSC-DDTR	ALNS	EL-DMOEA	MSC-DDTR	ALNS	EL-DMOEA	MSC-DDTR	ALNS	EL-DMOEA	MSC-DDTR	ALNS	EL-DMOEA
C101	10%	0.3662	0.3629	0.4201	21	23	25	1870.6	3352.1	2470.1	7673.7	5403.6	8835.9
	30%	0.5134	0.3199	0.3250	20	23	25	1730.1	3310.3	2625.3	7024.6	5088.6	8108.8
	50%	0.4547	0.3851	0.4203	20	22	25	1759.7	4143.6	2706.3	6871.8	4154.9	7230.9
C201	10%	0.3698	0.2720	0.5157	13	13	25	1807.9	4695.7	2150.7	22331	4197.6	29581
	30%	0.4460	0.3243	0.4486	13	13	25	1880.4	4813.6	2281.5	26398	3809.6	31006
	50%	0.5268	0.2463	0.4602	15	13	25	1921.4	5144.4	2411.6	26526	4176.5	35872
R101	10%	0.5329	0.3553	0.5981	16	18	25	2672.2	3361.2	2452.9	2346.4	4415.5	1379.6
	30%	0.4948	0.2921	0.5256	15	18	25	2720.2	3406.5	2543.3	2643.8	3460.4	1444.8
	50%	0.4664	0.3583	0.5296	17	18	25	2644.2	3483	2344.6	2384.1	3363.6	1557.1
R201	10%	0.8285	0.3673	0.3568	15	18	25	1998.3	3317.6	2071.9	5523.5	6350.7	9285.7
	30%	0.6091	0.3573	0.4074	16	18	25	2053.8	3419.2	2241.7	5994.8	6426.6	9410.4
	50%	0.6304	0.2037	0.3909	15	18	25	2011.5	2851.5	2611.4	5493.4	6397.4	9498.1
RC101	10%	0.5537	0.2737	0.3544	17	13	25	2800.7	3181.9	3044.3	1386.0	1500.5	1189.7
	30%	0.3333	0.2709	0.4832	18	13	25	2789.7	3709.5	3246.6	1427.5	1397.6	1006.4
	50%	0.4918	0.3065	0.4084	18	12	25	2691.1	3282.5	3514.7	1350.3	1521.8	1240.3
RC201	10%	0.2449	0.4173	0.4448	15	12	25	2468.2	2135.8	3051.6	5279.4	6788.9	9619.9
	30%	0.3665	0.2843	0.4266	14	12	25	2518.7	4612.4	2997.6	4674.5	6386.3	8787.0
	50%	0.5372	0.4333	0.3986	15	12	25	2642.0	3137	2591.8	4745.8	6355.3	9538.6
均值	0.5098	0.3868	0.4565	16	16	25	2410.1	3603.2	2630.9	7643.1	4705.3	9255.5	
胜出次数	9/18	0/18	9/18	11/18	7/18	0/18	13/18	1/18	4/18	6/18	6/18	6/18	

HV 值.

在车辆使用数指标上, MSC-DDTR 表现最佳, 18 个测试案例中获得 11 次最优结果, ALNS 获得 7 次最优, 而 EL-DMOEA 未获得任何最优结果. 例如, 在 C101 实例变动比例为 10% 时, MSC-DDTR 仅需 21 辆车, 相比 ALNS 的 23 辆车减少 8.7%, 相比 EL-DMOEA 的 25 辆车减少 16%. 统计结果表明, MSC-DDTR 在车辆资源配置方面明显优于其他两种算法.

在总行驶距离指标上, MSC-DDTR 表现最为突出, 18 个测试案例中获得 13 次最优结果, EL-DMOEA 获得 4 次最优, ALNS 仅获得 1 次最优. 例如在 C101 实例变动比例为 10% 时, MSC-DDTR 的总行驶距离为 1870.6, 相比 ALNS 的 3352.1 减少 44.2%, 相比 EL-DMOEA 的 2470.1 减少 24.3%. 可见, MSC-DDTR 在运输成本控制方面显著优于对比算法.

在总等待时间指标上, 3 种算法表现相近, 各自在 6 个测试案例中取得最优表现. ALNS 在某些实例中表现较好, 如 C101 实例变动比例为 10% 时, 其总等待时间为 5403.6, 比 MSC-DDTR 的 7673.7 降低 29.6%, 比 EL-DMOEA 的 8835.9 降低 38.8%.


EL-DMOEA 在 R101 系列实例中通常获得最短等待时间, 而 MSC-DDTR 在其他实例中表现出竞争优势.

综述所述, MSC-DDTR 在 4 个关键指标中的 3 个 (HV、车辆数、总行驶距离) 上表现最佳. 具体而言, 在 HV 指标上与 EL-DMOEA 表现相当 (各获得 9 次最优), 明显优于 ALNS; 在车辆数指标上获得 61.1% 的最优率 (11/18), 显著领先于 ALNS 的 38.9% (7/18) 和 EL-DMOEA 的 0%; 在总行驶距离指标上获得 72.2% 的最优率 (13/18), 远超 EL-DMOEA 的 22.2% (4/18) 和 ALNS 的 5.6% (1/18). EL-DMOEA 在 HV 指标上表现良好, 在等待时间控制方面有一定优势, 但在车辆利用效率和行驶距离优化方面明显落后; ALNS 在等待时间方面具有竞争力, 但在 HV 指标、车辆数优化和行驶距离控制方面均表现较差. 实验结果表明, MSC-DDTR 在考虑动态配送时间需求的车辆路径优化问题求解中具有明显优势, 在降低运营成本和提高资源利用效率方面表现卓越.


3.3.2 帕累托前沿对比图

在 6 个典型数据集 (C101、C201、R101、R201、RC101、RC201) 上, 3 种算法在不同扰动比例下的帕累托前沿分布如图 4 ~ 图 9 所示. 整体来看, MSC-DDTR 在所有数据集和动态水平下均展现出更优的

实例:C101 时间需求变动比例:10.0%



实例:C101 时间需求变动比例:30.0%



实例:C101 时间需求变动比例:50.0%






图4 帕累托最优前沿_C101

实例:C201 时间需求变动比例:10.0%



实例:C201 时间需求变动比例:30.0%



实例:C201 时间需求变动比例:50.0%






图5 帕累托最优前沿_C201

实例:R101 时间需求变动比例:10.0%



实例:R101 时间需求变动比例:30.0%



实例:R101 时间需求变动比例:50.0%






图6 帕累托最优前沿_R101

实例:R201 时间需求变动比例:10.0%



实例:R201 时间需求变动比例:30.0%



实例:R201 时间需求变动比例:50.0%






图7 帕累托最优前沿_R201

实例:RC101 时间需求变动比例:10.0%



实例:RC101 时间需求变动比例:30.0%



实例:RC101 时间需求变动比例:50.0%




图8 帕累托最优前沿_RC101




图9 帕累托最优前沿_RC201

多目标平衡能力,其帕累托解集分布紧凑且均匀,能够在总行驶距离、总等待时间和车辆数目三者之间实现较好的权衡.这种表现不仅体现在C类和R类的标准实例上,在更具复杂性的RC类混合实例中同样明显,表明MSC-DDTR具有较强的泛化性和鲁棒性.

进一步对比可以发现,ALNS在大多数情况下能够获得最低的等待时间,但往往以更高的总行驶距离为代价,且车辆数目分布较为集中,缺乏多样性.EL-DMOEA则在解集多样性上略有优势,但整体帕累托前沿普遍落后于其他两种算法,

综合6个数据集的对比结果可见,随着动态水平的提升,所有算法的解集分布均出现一定程度的退化,但MSC-DDTR依然能够保持较好的解集质量和分布均衡性.由此可见,MSC-DDTR在多目标动态车辆路径问题中,具备较强的适应能力和优化效果,能够为实际调度提供更具实用性和参考价值的调度方案.

4 结论

在城市物流配送行业中,配送时间需求的变化极大地影响了配送方案的制定,给高效车辆路径规划带来挑战.针对这一问题,本文提出考虑动态配送时间需求的多策略协同车辆路径优化方法,构建动态车辆路径优化模型,实现了考虑动态配送时间需求的精准建模;设计客户时间需求变化类型分类方法和需求变化综合评价指标,提出指标驱动的客户筛选机制,定量评估需求变化对路径优化的联动影响;构建进化策略库与客户优先级决策机制,实现了多策略协同优化,显著提升了算法的寻优性能.

实验结果表明,所提出方法能够定性分析并定量表征客户配送时间需求变化,降低需求变化对配送方案的影响,有效求解动态路径方案,提升物流配送效率.未来将考虑实时交通信息和碳排放因素,不断完善模型与算法,以适应更加复杂的实际物流场景^[16-18].

参考文献 (References)

- [1] 国务院办公厅.关于推动物流高质量发展促进形成强大国内场的意见(国办发[2019]38号)[Z].2019-12-24.
- [2] Moldabekova A, Philipp R, Reimers H E, et al. Digital technologies for improving logistics performance of countries[J]. *Transport and Telecommunication Journal*, 2021, 22(2): 207-216.
- [3] 邢玉伟,王展华,杨华龙.需求可离散拆分电动汽车充电策略和路径优化问题[J].*控制与决策*, 2025, 40(3): 987-995.
(Xing Y W, Wang Z H, Yang H L. Electric vehicle charging strategies and routing optimization under discrete split demands[J]. *Control and Decision*, 2025, 40(3): 987-995.)
- [4] Hou Y, Shen Y J, Han H G, et al. Multi-task differential evolution algorithm with dynamic resource allocation: A study on e-waste recycling vehicle routing problem[J]. *Swarm and Evolutionary Computation*, 2025, 92: 101806.
- [5] Sze J F, Salhi S, Wassan N. An adaptive variable neighbourhood search approach for the dynamic vehicle routing problem[J]. *Computers & Operations Research*, 2024, 164: 106531.
- [6] Demirbilek M. Optional and mandatory assignment strategies for dynamic vehicle routing with time windows[J]. *Ain Shams Engineering Journal*, 2025, 16(9): 103462.
- [7] Wang Z Z, Ye K, Jiang M, et al. Solving hybrid charging strategy electric vehicle based dynamic routing problem via evolutionary multi-objective optimization[J]. *Swarm and Evolutionary Computation*, 2022, 68: 100975.
- [8] Sánchez A L, Lujak M, Semet F, et al. Dynamic, fair, and efficient routing for cooperative autonomous vehicle fleets[J]. *Expert Systems with Applications*, 2024, 251: 123964.
- [9] Botros A, Gilhuly B, Wilde N, et al. Optimizing task waiting times in dynamic vehicle routing[J]. *IEEE Robotics and Automation Letters*, 2023, 8(9): 5520-5527.
- [10] Wang S H, Sun W, Huang M. An adaptive large neighborhood search for the multi-depot dynamic vehicle routing problem with time windows[J]. *Computers & Industrial Engineering*, 2024, 191: 110122.

- [11] Wang F, Liao F S, Li Y X, et al. An ensemble learning based multi-objective evolutionary algorithm for the dynamic vehicle routing problem with time windows[J]. *Computers & Industrial Engineering*, 2021, 154: 107131.
- [12] 韩红桂, 徐子昂, 王晶晶. 基于 Q 学习的多任务多目标粒子群优化算法[J]. *控制与决策*, 2023, 38(11): 3039-3047.
(Han H G, Xu Z A, Wang J J. A Q -learning-based multi-task multi-objective particle swarm optimization algorithm[J]. *Control and Decision*, 2023, 38(11): 3039-3047.)
- [13] 王凌, 王晶晶. 带峰值能耗约束流水线调度的协同群智能优化[J]. *控制与决策*, 2021, 36(10): 2350-2358.
(Wang L, Wang J J. Cooperative memetic optimization for flowshop scheduling with peak power consumption constraint[J]. *Control and Decision*, 2021, 36(10): 2350-2358.)
- [14] Hou Y, Guo X, Han H, et al. Adaptive ant colony optimization algorithm based on real-time logistics features for instant delivery[J]. *IEEE Transactions on Cybernetics*, 2024, 54(11): 6358-6370.
- [15] 侯莹, 吴毅琳, 白星, 等. 数据驱动选择策略的多目标差分进化算法[J]. *控制与决策*, 2023, 38(7): 1816-1824.
(Hou Y, Wu Y L, Bai X, et al. Multi-objective differential evolution algorithm with data-driven selection strategy[J]. *Control and Decision*, 2023, 38(7): 1816-1824.)
- [16] 李坚强, 蔡俊创, 孙涛. 面向复杂物流配送场景的车辆路径规划多任务辅助进化算法[J]. *自动化学报*, 2023, 50(3): 544-559.
(Li J Q, Cai J C, Sun T, Multitask-based assisted evolutionary algorithm for vehicle routing problems in complex logistics distribution scenarios[J]. *Acta Automatica Sinica*, 2023, 50(3): 544-559.)
- [17] Teng Y, Chen J B, Zhang S Y, et al. Solving dynamic vehicle routing problem with time windows by ant colony system with bipartite graph matching[J]. *Egyptian Informatics Journal*, 2024, 25: 100421.
- [18] 王俊皓, 李晓玲, 段浩浩, 等. 模因算法求解同时取送货车辆-无人机协同路径优化问题[J]. *控制与决策*, 2025, 40(11): 3287-3299.
(Wang J H, Li X L, Duan H H, et al. Memetic algorithm for vehicle-drone collaborative routing problem with simultaneous pickup and delivery[J]. *Control and Decision*, 2025, 40(11): 3287-3299.)

作者简介

侯莹 (1982-), 女, 副教授, 博士, 博士生导师, 主要研究方向为复杂系统智能优化决策, E-mail: houying17@sina.com;

乔聘 (2001-), 男, 硕士生, 主要研究方向为动态车辆路径优化问题, E-mail: jospas@emails.bjut.edu.cn;

韩红桂 (1983-), 男, 教授, 博士, 博士生导师, 主要研究方向为多智能体协同优化控制, E-mail: rechardhan@sina.com.