

# 控制与决策

*Control and Decision*

两阶段混合优化算法求解模糊需求下多时间窗车辆路径问题

李楠, 胡蓉, 钱斌, 金怀平, 于乃康

引用本文:

李楠,胡蓉,钱斌,金怀平,乃康. 两阶段混合优化算法求解模糊需求下多时间窗车辆路径问题[J]. [控制与决策](#), 2022, 37(6): 1573–1582.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0022>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

[基于时空聚类求解带容积约束的选址-路径问题](#)

Time-space cluster based location-routing problem with capacitate constraints

[控制与决策](#). 2021, 36(10): 2504–2510 <https://doi.org/10.13195/j.kzyjc.2020.0073>

[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>

[考虑卸载顺序约束的成品油二次配送车辆路径问题](#)

Vehicle routing problem of refined oil secondary distribution considering unloading sequence constraints

[控制与决策](#). 2020, 35(12): 2999–3005 <https://doi.org/10.13195/j.kzyjc.2018.1756>

[超启发式交叉熵算法求解模糊分布式流水线绿色调度问题](#)

Hyper-heuristic cross-entropy algorithm for green distributed permutation flow-shop scheduling problem with fuzzy processing time

[控制与决策](#). 2021, 36(6): 1387–1396 <https://doi.org/10.13195/j.kzyjc.2019.1681>

[基于平衡鲸鱼优化算法的无人车路径规划](#)

Path planning of unmanned ground vehicle based on balanced whale optimization algorithm

[控制与决策](#). 2021, 36(11): 2647–2655 <https://doi.org/10.13195/j.kzyjc.2020.0416>

# 两阶段混合优化算法求解模糊需求下多时间窗车辆路径问题

李楠<sup>1</sup>, 胡蓉<sup>1†</sup>, 钱斌<sup>1,2</sup>, 金怀平<sup>1</sup>, 于乃康<sup>2</sup>

(1. 昆明理工大学 信息工程与自动化学院, 昆明 650500; 2. 昆明理工大学 机电工程学院, 昆明 650500)

**摘要:** 针对现实中广泛存在的一类模糊需求下多时间窗车辆路径问题(vehicle routing problem with multiple time windows under fuzzy demand, VRPMTW\_FD), 即车辆配送前客户需求模糊但车辆到达客户后其需求变为确定的多时间窗车辆路径问题(vehicle routing problem with multiple time windows, VRPMTW), 以最小化总成本为优化目标, 构建基于模糊可信性理论的模糊机会约束规划模型, 并提出一种两阶段混合优化算法(two-stage hybrid optimization algorithm, TSHOA)进行求解。首先, 在TSHOA的第1阶段设计改进灰狼优化算法(improved grey wolf optimizer, IGWO)求解车辆配送前客户需求模糊的VRPMTW, 以获得VRPMTW\_FD的预优化路径; 然后, 在TSHOA的第2阶段设计最优点重调度策略(optimal point rescheduling strategy, OPRS), 对预优化路径进行动态调整, 从而确定合适的返回点以降低因预优化路径故障产生的额外配送成本。通过不同规模问题上的仿真实验和算法比较, 验证了TSHOA可有效求解VRPMTW\_FD。

**关键词:** 车辆路径问题; 模糊需求; 多时间窗; 灰狼优化算法; 局部搜索; 动态调整

中图分类号: TP18

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0022

开放科学(资源服务)标识码(OSID):

引用格式: 李楠, 胡蓉, 钱斌, 等. 两阶段混合优化算法求解模糊需求下多时间窗车辆路径问题[J]. 控制与决策, 2022, 37(6): 1573-1582.



## Two stage hybrid optimization algorithm for vehicle routing problem with multiple time windows under fuzzy demand

LI Nan<sup>1</sup>, HU Rong<sup>1†</sup>, QIAN Bin<sup>1,2</sup>, JIN Huai-ping<sup>1</sup>, YU Nai-kang<sup>2</sup>

(1. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. School of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** Aiming at a type of vehicle routing problems with multiple time windows under fuzzy demand (VRPMTW\_FD) that exists widely in reality, which is that the customer demand is fuzzy before the vehicle is delivered but the customer demand becomes definite after the vehicle reaches the customer, a fuzzy chance constrained programming model based on the fuzzy credibility theory is constructed to minimize the total cost, and a two-stage hybrid optimization algorithm (TSHOA) is proposed to solve it. Firstly, the first stage of the TSHOA designs an improved gray wolf optimizer (IGWO) to solve the VRPMTW with fuzzy customer demand before vehicle delivery, to obtain the pre-optimized path of the VRPMTW\_FD. Then, in the second stage of the TSHOA, the optimal point rescheduling strategy (OPRS) is designed to dynamically adjust the pre-optimized path, so as to determine the appropriate return point to reduce the additional distribution cost due to the failure of the pre-optimized path. Through simulation experiments and algorithm comparisons on different scale problems, it is verified that the TSHOA can effectively solve the VRPMTW\_FD.

**Keywords:** vehicle routing problem; fuzzy demand; multi time windows; gray wolf optimizer; local search; dynamic adjustment

## 0 引言

车辆路径问题(vehicle routing problem, VRP)于1959年由Dantzig等<sup>[1]</sup>首次提出, 此后便成为运筹学

和组合优化领域的前沿研究热点。随着现代物流配送系统的建立和电子商务的快速发展, 传统的VRP模型已经难以适应现代物流准时、高效的配送需求。

收稿日期: 2021-01-06; 录用日期: 2021-03-29。

基金项目: 国家自然科学基金项目(61963022, 62173169, 51665025)。

责任编辑: 王伟。

<sup>†</sup>通讯作者. E-mail: ronghu@vip.163.com.

另外,实际物流配送往往具有多时间窗的特性,譬如,长途运输<sup>[2]</sup>、团队定向<sup>[3]</sup>、家具和电子零售商的配送业务等。并且客户的信息也存在不确定性,譬如,客户的需求<sup>[4]</sup>和服务时间<sup>[5]</sup>等。在上述背景下,模糊需求下多时间窗车辆路径问题(vehicle routing problem with multiple time windows under fuzzy demand, VRPMTW\_FD)的重要性日益凸显,在计算复杂度上,VRP属于NP-hard问题,而VRP又可归约为VRPMTW\_FD,故VRPMTW\_FD也属于NP-hard问题。因此,研究VRPMTW\_FD的建模及其求解算法具有重要的理论价值和实际意义。

VRPMTW\_FD综合了多时间窗车辆路径问题(vehicle routing problem with multiple time windows, VRPMTW)和模糊需求车辆路径问题(vehicle routing problem with fuzzy demand, VRPFD)中的约束条件,因此,要根据上述两个问题的特点建立恰当的数学模型并寻求适合的求解算法。Favaretto等<sup>[6]</sup>首次提出VRPMTW,并设计一种基于蚁群系统的双蚁群算法进行求解。此后,部分学者对VRPMTW进行了模型和算法上的扩展研究。Belhaiza等<sup>[7]</sup>以最小化总持续时间为优化目标,提出了一种混合变邻域禁忌搜索启发式算法,用于求解VRPMTW,并使用Solomon的VRPTW实例<sup>[8]</sup>生成两种不同类型的VRPMTW实例。Beheshti等<sup>[9]</sup>以旅行成本最小化和顾客满意度最大化为优化目标,提出一种协同进化的多目标量子遗传算法用于求解具有多个优先时间窗的多目标VRP。Hoogeboom等<sup>[10]</sup>提出了一种自适应变邻域搜索算法和一种基于前向和后向开始时间间隔重新计算路径持续时间的精确多项式时间算法,用于求解出发时间不固定的VRPMTW。Bogue等<sup>[11]</sup>提出了一种基于可变邻域搜索的列生成算法和后优化启发式算法,以提供VRPMTW最优解的上界和下界。通过对已有文献的梳理可见,现有文献针对VRPMTW的研究均是基于客户需求是确定条件下的,没有考虑实际配送中客户需求的不确定性。

VRPFD是模糊车辆路径问题(fuzzy vehicle routing problem, FVRP)的一种。与求解需求确定型的VRP相比,VRPFD受客户需求模糊的影响,客户的需求直到在车辆到达客户后才可以确定。因此,VRPFD的求解过程具有两阶段的特点,即在车辆配送前客户需求不确定情况下设计配送方案的预优化阶段和在车辆到达客户点获取客户的需求后为防止继续服务造成服务失败而对当前车辆是否返回配送中心补货进行判断的重优化阶段。现

有文献多采用模糊集可能性、模糊可信性等理论界定模糊需求变量和相关约束来处理预优化阶段。Teodorovi等<sup>[12]</sup>基于模糊算法和模糊逻辑规则设计扫描算法求解VRPFD。曹二保等<sup>[13]</sup>基于模糊可信性理论提出了一种随机模拟的混合差分进化算法求解VRPFD。Peng等<sup>[14]</sup>基于模糊可信性理论提出了一种改进的粒子群算法用于求解VRPFD。王连峰等<sup>[15]</sup>基于模糊可信性理论对VRPFD中服务失败事件进行可能性分析,构建了VRPFD的模糊期望值模型,并设计了一种带双层禁忌搜索的并行粒子群算法进行求解。在重优化阶段,VRPFD与随机需求车辆路径问题(vehicle routing problem with stochastic demand, VRPSD)相同,文献[12]针对VRPFD提出失败点返回策略,当车辆到达客户点发现剩余装载量不足以满足客户的实际需求便返回配送中心补货,然后返回到发生故障的客户点继续进行服务。Yang等<sup>[16]</sup>针对VRPSD提出了一种预防性补货(preventive replenishment, PR)策略用于降低失败点造成的成本。Lei等<sup>[17]</sup>针对具有随机需求和时间窗的车辆路径问题提出了失败点返回策略(detour to depot, DTD)用于解决失败点造成的路由故障。李阳等<sup>[18]</sup>针对VRPFD提出一种点重调度策略,当所有车辆确认失败点后,重新对所有失败点和未服务的客户进行调度。根据以上文献调研可知,一方面,VRPFD的研究仍十分有限,并且现有文献在重优化阶段基本均采用DTD和PR对失败点进行动态调整,PR虽然能够降低预优化路径出现故障的概率,但可能导致不恰当的返回。DTD虽然不会像PR做出错误的判断,但车辆被动地返回会造成大量的往返成本;另一方面,目前尚无对VRPMTW\_FD建模和智能算法求解方面的相关研究。

灰狼优化算法(grey wolf optimizer, GWO)是一种基于群体智能的连续随机优化算法,最早由Mirjalili等<sup>[19]</sup>通过模拟狼群的社会等级及狩猎机制提出。该算法因具有控制参数少、全局寻优能力强、收敛快、易于实现等优点,在现实生活中有着广泛的应用。目前,对GWO的应用多集中于连续优化领域<sup>[20-21]</sup>,GWO在离散优化领域的应用相对较少。姜天华<sup>[22]</sup>将其应用于柔性作业车间调度问题中。Korayem等<sup>[23]</sup>将其用于求解带容量约束的VRP。VRPMTW\_FD本质上属于离散优化问题,标准GWO不能直接用于求解该问题,因此本文设计了一种改进灰狼优化算法,实现原算法从连续空间搜索到离散空间搜索的相互转化,以克服标准GWO不能应用于离

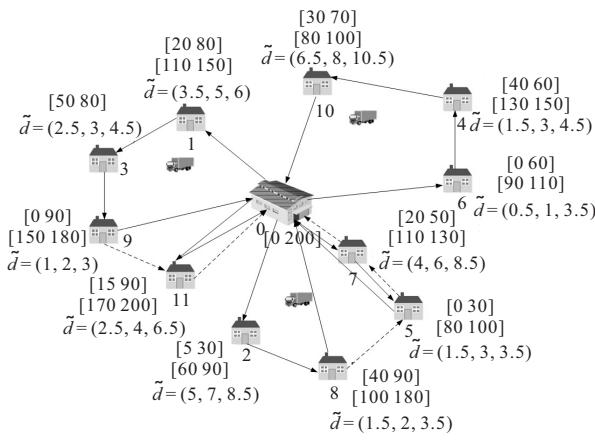
散优化问题的缺点。

本文基于模糊可信性理论,构建以最小化总成本为优化目标的VRPMTW\_FD的模糊机会约束规划模型,并提出一种两阶段混合优化算法(two-stage hybrid optimization algorithm, TSHOA)分阶段对其进行求解。在TSHOA的第一阶段,设计了具有多种排序操作的改进灰狼优化算法(improved grey wolf optimizer, IGWO)。首先,在保留标准GWO个体更新机理的前提下,采用基于随机键编码的LOV(Largest-order-value)规则实现在离散问题解空间中执行标准GWO的全局搜索;然后,设计等待时间最小、最近邻和随机3种启发式规则用于生成具有高质量和分散性的初始种群,进而引导算法的全局搜索快速发现并探索解空间中的优质解区域;最后,针对车辆内和车辆间的搜索,分别设计了4种不同形式的插入和交换邻域操作对其进行3层递进式的局部搜索,进一步增强了算法的局部搜索能力。TSHOA的第二阶段,提出了最优点重调度策略(optimal point rescheduling strategy, OPRS),通过对下一未服务客户按照设定的机制进行预判,找出可能发生故障的客户点,分别在当前客户点和下一客户点对剩余客户重新调度,以成本最低的重调度方案确定最优返回点。通过对不同测试问题的仿真实验和算法比较验证了TSHOA的有效性和鲁棒性。

## 1 问题描述及模型建立

### 1.1 问题描述

VRPMTW\_FD可描述为:拥有若干车辆的配送中心为若干客户配送货物,每个客户有多个不重叠的时间窗口,且每个客户的需求量在配送前是不确定的,用三角模糊数表征。客户的实际需求量在车辆到达后才可以得知。如图1所示,要求在满足客户模糊需求和服务时间的约束下,预优化出一个配送方案,



预优化路径:  $\pi = (0, 1, 3, 9, 11, 0, 2, 8, 5, 7, 0, 6, 4, 10, 0)$   
重优化路径:  $\pi' = (0, 1, 3, 9, 0, 11, 0, 2, 8, 0, 7, 5, 0, 6, 4, 10, 0)$

图1 VRPMTW\_FD示意图

车辆从配送中心满载出发,按照预优化的配送方案对客户进行服务。在车辆配送过程中,由于车辆的装载量逐渐减少,后续客户的需求又是模糊不确定的,如果车辆单纯地按照预优化方案进行配送,则可能会造成大量的往返成本。因此需要针对预优化方案进行实时调整,以减少车辆的往返成本。优化目标是在满足约束的条件下,使配送成本最小化。

### 1.2 符号定义

本节涉及的数学符号及定义如下所示。

- $V_0$ :客户集  $V_0 = \{1, 2, \dots, n\}$ ;
- $V$ :节点集  $V = \{0\} \cup V_0$ , 0表示配送中心;
- $K$ :车辆集  $K = \{1, 2, \dots, m\}$ ;
- $W_i$ :客户  $i$  的时间窗口集  $W_i = \{1, 2, \dots, T_i\}$ ;
- $n$ :总客户数;
- $m$ :总车辆数;
- $T_i$ :客户  $i$  的最大时间窗口数;
- $r^k$ :配送方案需要的车辆总数;
- $Q$ :车辆的最大载重;
- $[e_i^p, l_i^p]$ :客户  $i$  的第  $p$  个时间窗;
- $[e_0, l_0]$ :配送中心时间窗;
- $\tilde{d}_i = (d_{1i}, d_{2i}, d_{3i})$ :客户的模糊需求量;
- $c$ :单辆车发车固定成本;
- $c_1$ :车辆每千米的行驶成本;
- $c_2$ :车辆每小时的等待成本;
- $d_{ij}$ :客户  $i$  到客户  $j$  的距离;
- $t_{ij}$ :车辆从客户  $i$  到客户  $j$  的行驶时间;
- $w_i^k$ :车辆  $k$  在客户  $i$  处的等待时间;
- $a_i^k$ :车辆  $k$  到达客户  $i$  的时间;
- $b_i^k$ :车辆  $k$  离开客户  $i$  的时间;
- $s_i$ :客户  $i$  处的服务时间;
- $x_{ijk}$ :决策变量, 车辆  $k$  从客户  $i$  到客户  $j$  时为1, 否则为0;
- $y_{ik}$ :决策变量, 客户  $i$  由车辆  $k$  服务为1, 否则为0;
- $z_{ik}^p$ :决策变量, 车辆  $k$  在客户  $i$  的第  $p$  个时间窗内为其服务时为1, 否则为0。

### 1.3 模糊机会约束规划模型构建

在需求确定的VRP中,容量约束为整条路径的总需求量不超过车辆最大装载量。然而,在VRPMTW\_FD中,对于不确定的需求,容量约束比确定需求下的容量约束更为复杂。本文基于模糊可信性理论构建模糊机会约束规划模型对客户的模糊需求进行处理。假设某车辆  $k$  已经确定了待服务的客户序列  $\{s, t, u\}$ , 车辆从配送中心满载出发,按顺序依次服务完客户  $s, t, u$  后的剩余装载量为

$$\begin{aligned}\tilde{Q}_u &= Q - \tilde{d}_s - \tilde{d}_t - \tilde{d}_u = \\ \left( Q - \sum_{i=s,t,u} d_{3i}, Q - \sum_{i=s,t,u} d_{2i}, Q - \sum_{i=s,t,u} d_{1i} \right) &= \\ (q_{1u}, q_{2u}, q_{3u}),\end{aligned}$$

其中  $q_{1u} \leq q_{2u} \leq q_{3u}$ . 当车辆想要继续为下一个客户  $j$  服务时, 基于可信性理论, 其需求小于剩余装载量的可信度为

$$\begin{aligned}\text{Cr}\{\tilde{d}_j \leq \tilde{Q}_u\} &= \\ \text{Cr}\{(d_{1j} - q_{3u}, d_{2j} - q_{2u}, d_{3j} - q_{1u}) \leq 0\} &= \\ \begin{cases} 0, & d_{1j} \geq q_{3u}; \\ \frac{q_{3u} - d_{1j}}{2(q_{3u} - d_{1j} + d_{2j} - q_{2u})}, & d_{1j} < q_{3u}, d_{2j} \geq q_{2u}; \\ \frac{d_{3j} - q_{1u} - 2(d_{2j} - q_{2u})}{2(q_{2u} - d_{2j} + d_{3j} - q_{1u})}, & d_{2j} < q_{2u}, d_{3j} > q_{1u}; \\ 1, & d_{3j} \geq q_{1u}. \end{cases} \quad (1)\end{aligned}$$

式(1)中,  $\text{Cr}\{\tilde{d}_j \leq \tilde{Q}_u\}$  表达的是三角模糊数  $\tilde{d}_j \leq \tilde{Q}_u$  的一种可信度测度,  $\text{Cr} \in [0, 1]$ ,  $\text{Cr}$  越大, 表示车辆的剩余装载量能够满足客户模糊需求量的可信度越大. 为设计模糊需求下的容量约束, 引入偏好值  $\alpha$ ,  $\alpha \in [0, 1]$ , 若  $\text{Cr} \geq \alpha$ , 则车辆继续对下一客户  $j$  进行服务, 若  $\text{Cr} < \alpha$ , 则车辆返回配送中心, 重新增派车辆对剩余客户服务. 偏好值  $\alpha$  表征的是决策者的风险态度,  $\alpha$  越小表明决策者越倾向于冒着失败的风险去充分利用车辆的剩余装载量. 相反,  $\alpha$  越大表明决策者宁愿多派一辆车继续服务剩下的客户, 也不愿去冒失败的风险.

对于给定的  $\alpha$  值, 相应的基于模糊可信性理论的 VRPMTW\_FD 模糊机会约束规划模型如下所示:

$$\min \sum_{k \in K} cr^k + \sum_{i \in V} \sum_{j \in V} \sum_{k \in K} c_1 d_{ij} x_{ijk} + \sum_{k \in K} \sum_{i \in V_0} c_2 w_i^k. \quad (2)$$

$$\text{s.t. } \sum_{i \in V} x_{ihk} = \sum_{j \in V} x_{hjk}, \forall h \in V_0, \forall k \in K; \quad (3)$$

$$x_{ijk} = 0, \forall i = j, \forall i, j \in V, \forall k \in K; \quad (4)$$

$$\sum_{j \in V_0} x_{0jk} = \sum_{j \in V_0} x_{j0k} \leq 1, \forall k \in K; \quad (5)$$

$$\sum_{i \in V} x_{ijk} = y_{jk}, \forall j \in V_0, \forall k \in K; \quad (6)$$

$$\sum_{j \in V} x_{ijk} = y_{ik}, \forall i \in V_0, \forall k \in K; \quad (7)$$

$$\text{Cr}\left\{\sum_{i \in V} \sum_{j \in V_0} x_{ijk} \cdot \tilde{d}_j \leq Q\right\} \geq \alpha, \forall k \in K; \quad (8)$$

$$b_{0k} = e_0, \forall k \in K; \quad (9)$$

$$a_{0k} \leq l_0, \forall k \in K; \quad (10)$$

$$a_j^k = a_i^k + w_i^k + s_i + t_{ij}, \forall i \in V, \forall k \in K; \quad (11)$$

$$a_i^k + w_i^k \geq \sum_{p \in W_i} e_i^p z_{ik}^p, \forall i \in V, \forall k \in K; \quad (12)$$

$$a_i^k + w_i^k \leq \sum_{p \in W_i} l_i^p z_{ik}^p, \forall i \in V, \forall k \in K; \quad (13)$$

$$\sum_{p \in W_i} z_{ik}^p = 1, \forall i \in V, \forall k \in K; \quad (14)$$

$$x_{ijk} \in \{0, 1\}, \forall i, j \in V, \forall k \in K; \quad (15)$$

$$y_{jk} \in \{0, 1\}, \forall j \in V_0, \forall k \in K; \quad (16)$$

$$z_{ik}^p \in \{0, 1\}, \forall i \in V, \forall k \in K. \quad (17)$$

式(2)为优化目标函数, 表示最小化总成本, 包括所有车辆的发车成本、行驶成本和提前到达的等待成本. 式(3)表示客户点车辆流平衡约束, 即车辆到达客户  $h$  后必须离开. 式(4)表示相同节点之间没有路径连通. 式(5)表示每辆车仅有一条服务路径, 且服务完客户后必须返回配送中心. 式(6)和(7)保证客户点被车辆服务时一定有路径与其连接. 式(8)表示模糊容量机会约束, 保证车辆在选择客户点进行服务时其需求量不大于  $Q$  的可信度高于预先设定的置信水平. 式(9)和(10)表示车辆出发时间为配送中心的最早开放时间, 返回时间要早于配送中心的关闭时间. 式(11)表示到达客户  $j$  的时间等于到达客户  $i$  的时间, 加上在客户  $i$  处的等待时间、服务时间和从客户  $i$  到客户  $j$  的总行驶时间. 式(12)和(13)表示客户在时间窗内被服务. 式(14)表示仅有一个时间窗口可被选中. 式(15)~(17)表示决策变量属性.

## 2 TSHOA求解VRPMTW\_FD

### 2.1 IGWO

本文针对标准 GWO 存在的编解码不适用于离散优化问题、随机初始化产生的解较差和局部搜索能力较弱的缺点, 对其进行相关改进. 下面分别对 IGWO 的编码与解码、种群初始化、灰狼种群的位置更新、局部搜索及流程进行介绍.

#### 2.1.1 编码与解码

标准 GWO 主要用来求解连续变量优化问题, 而 VRPMTW\_FD 是离散优化问题, 因此不能将标准 GWO 直接用于求解 VRPMTW\_FD. 本文采用 LOV 规则, 实现连续灰狼位置向量到离散客户序列的转化. 当客户序列发生变化时, 可通过 RLOV (reverse largest-order-value) 规则对个体的位置信息进行更新. 令种群大小为  $\text{popsize}$ ,  $\pi_i^{\text{gen}} = [\pi_i^{\text{gen}}[1], \pi_i^{\text{gen}}[2], \dots, \pi_i^{\text{gen}}[S]] (2+n \leq S \leq 2n+1)$  为第  $\text{gen}$  代种群中个体  $i$  对应的配送方案,  $S$  为  $\pi_i^{\text{gen}}$  的长度.  $C_i^{\text{gen}} = [C_i^{\text{gen}}[1], C_i^{\text{gen}}[2], \dots, C_i^{\text{gen}}[n]]$  为对应  $\pi_i^{\text{gen}}$  基于客户

序号的排列.  $X_i^{\text{gen}} = [X_i^{\text{gen}}[1], X_i^{\text{gen}}[2], \dots, X_i^{\text{gen}}[n]]$  为  $C_i^{\text{gen}}$  对应的客户个体实数位置信息.

如图2所示,假设某个体的实数位置信息  $X_i^{\text{gen}} = [0.33, 0.92, 0.75, 0.21, 0.56, 0.81, 0.08, 0.12, 0.46, 0.88]$ , 根据LOV规则可得对应的客户排列  $C_i^{\text{gen}} = [2, 10, 6, 3, 5, 9, 1, 4, 8, 7]$ , 然后按照车辆的载重和客户的时间窗约束,依次将  $C_i^{\text{gen}}$  中的客户从左至右分配给各车辆, 可得到所有车辆的配送路径  $\pi_i^{\text{gen}} = [0, 2, 10, 6, 0, 3, 5, 9, 1, 4, 0, 8, 7, 0]$ , 该配送方案共有3辆车, 以车辆1为例, 车辆1从配送中心0出发, 依次服务客户2、10、6后返回配送中心0, 车辆2和车辆3的服务路径与车辆1类似. 当灰狼种群实数位置信息对应的解  $\pi_i$  发生变化时, 假设变化后  $\pi_i^{\text{gen}} = [0, 10, 2, 5, 0, 1, 4, 3, 6, 9, 0, 8, 7, 0]$ , 对应的客户排列为  $C_i^{\text{gen}} = [10, 2, 5, 1, 4, 3, 6, 9, 8, 7]$ , 通过RLOV规则可得对应的个体的实数位置为  $X_i^{\text{gen}} = [0.53, 0.76, 0.35, 0.46, 0.68, 0.25, 0.05, 0.12, 0.23, 0.95]$ .

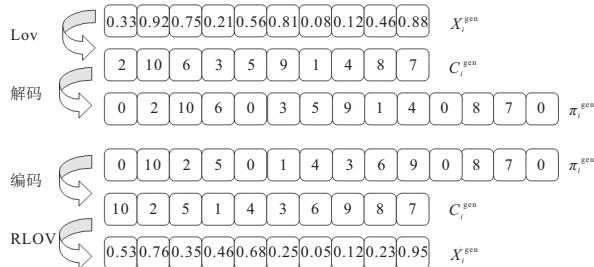


图2 编码与解码

### 2.1.2 初始化策略

为提高初始种群的质量并保证初始种群的多样性和分散性, 本文设计了等待时间最小规则、最近邻规则和随机规则3种启发式规则用来产生第1代种群, 使用等待时间最小、最近邻规则生成两个个体, 其余个体由随机规则产生. 3种初始化规则具体如下:

1) 等待时间最小规则: 车辆从配送中心满载出发, 将满足车辆模糊容量机会约束并且能够在规定时间窗口内服务的客户记录下来, 在上述客户中选择等待时间最小的客户作为下一个被服务的客户, 当车辆的剩余装载量不足以继续为下一客户服务时, 车辆将返回配送中心, 重新装载货物后, 继续按照上述方法对客户进行服务, 直至所有的客户被服务.

2) 最近邻规则: 车辆从配送中心满载出发, 将满足车辆模糊容量机会约束并且能够在规定时间窗口内服务的客户记录下来, 在上述客户中选择距离车辆当前位置最近的客户作为下一个被服务的客户, 当车辆的剩余装载量不足以继续为下一客户服务时, 车辆将返回配送中心, 重新装载货物后, 继续按照上述方法对客户进行服务, 直至所有的客户被服务.

3) 随机规则: 车辆从配送中心满载出发, 将满足车辆模糊容量机会约束并且能够在规定时间窗口内服务的客户记录下来, 在上述客户中随机挑选一个客户作为下一个被服务的客户, 当车辆的剩余装载量不足以继续为下一客户服务时, 车辆将返回配送中心, 重新装载货物后, 继续按照上述方法对客户进行服务, 直至所有的客户被服务.

根据以上初始化规则产生第1代初始种群  $\{\pi_1^1, \pi_2^1, \dots, \pi_{\text{popsize}}^1\}$ , 将每个个体  $\pi_i^1$  去除配送中心后得到该个体对应的客户序列  $C_i^1$ , 然后根据RLOV得到客户序列  $C_i^1$  对应的个体实数位置  $X_i^1$ .

### 2.1.3 位置更新

首先, 按照狼群中所有个体的适应度确定  $\alpha$ 、 $\beta$ 、 $\delta$  和  $\omega$  后, 将  $\omega$  中的每个个体按照式(18)~(24)分别向  $\alpha$ 、 $\beta$ 、 $\delta$  靠近以更新  $\omega$  群体位置; 然后, 根据LOV规则将灰狼实数位置对应为客户序列; 最后, 根据先路由后分组策略得到对应的解并计算每个解的适应度. 经过以上操作便对整个灰狼种群进行了更新, 更新后的灰狼种群按照灰狼个体实数位置对应的解的适应度进行排列, 将新的最优位置作为  $\alpha$ 、 $\beta$ 、 $\delta$  狼的位置. GWO的具体原理和步骤详见文献[19]. 有

$$D_\alpha = |c_1 \cdot X_\alpha(\text{gen}) - X(\text{gen})|, \quad (18)$$

$$D_\beta = |c_2 \cdot X_\beta(\text{gen}) - X(\text{gen})|, \quad (19)$$

$$D_\delta = |c_3 \cdot X_\delta(\text{gen}) - X(\text{gen})|, \quad (20)$$

$$X_1 = X_\alpha(\text{gen}) - A_1 \cdot D_\alpha, \quad (21)$$

$$X_2 = X_\beta(\text{gen}) - A_2 \cdot D_\beta, \quad (22)$$

$$X_3 = X_\delta(\text{gen}) - A_3 \cdot D_\delta, \quad (23)$$

$$X(\text{gen} + 1) = (X_1 + X_2 + X_3)/3. \quad (24)$$

### 2.1.4 局部搜索

为引导算法在更为紧凑的解空间中增加搜索深度, 设计车辆内和车辆间两类共8种局部搜索操作, 每种操作在选择时采用随机选取规则. 在局部搜索部分设计了具有3层递进搜索关系的搜索策略. 具体而言, 对每一代的  $\alpha$ 、 $\beta$ 、 $\delta$  狼先进行车辆内局部搜索, 达到搜索次数后, 再对搜索到的局部较优解进行车辆间局部搜索, 最后对搜索到的局部较优解再一次进行车辆内局部搜索. 局部搜索策略是对个体对应的解  $\pi_i^{\text{gen}}$  进行操作, 当搜索到比原始解更好的解  $\pi'$  后, 用  $\pi'$  代替  $\pi_i^{\text{gen}}$ . 对于车辆内局部搜索, 对每辆客户数大于1的车辆均进行局部搜索, 搜索次数为该车辆服务的客户数乘以系数  $\theta$ ; 对于车辆间局部搜索, 任意选出两个车辆的次数为配送方案中车辆的总数乘以系数  $\rho$ , 对选出的两个车辆进行搜索的次数为两车辆中服务最多的客户数乘以系数  $\sigma$ .

1) 车辆内4种局部操作: 第1种为车辆内相邻客户交换操作, 随机挑选一条路径, 并在该路径内随机挑选两个相邻的客户进行交换; 第2种为车辆内不相邻客户交换操作, 随机挑选一条路径, 并在该路径内随机挑选两个不相邻的客户进行交换; 第3种为车辆内插入操作, 随机挑选一条路径, 并在该路径内随机挑选两个客户*i*和*j*, 将客户*j*插入到客户*i*前面; 第4种为车辆内逆序操作, 随机挑选一条路径, 并在该路径内随机挑选两个客户*i*与*j*, 将客户*i*与*j*之间(包括*i*, *j*两个客户)的客户进行逆序.

2) 车辆间4种局部操作, 第1种为路径间单个客户交换, 随机挑选两条不同路径, 在两条路径中分别随机挑选一个客户进行交换; 第2种为路径间多个客户交换操作, 随机挑选两条不同路径, 在两条路径中分别挑选一个长度为*l*的连续客户序列进行交换, 该连续客户序列的长度*l* ∈ [2, 4]; 第3种为路径间单个客户插入操作, 随机挑选两条不同路径, 在两条路径中分别随机挑选一个客户, 得到客户*i*和*j*, 将*j*客户插入到*i*客户前面; 第4种为路径间多个客户插入操作, 随机挑选两条不同路径, 任选一条作为被插入路径, 另一条作为插入路径, 在被插入路径中随机挑选一个长度为2的连续客户序列, 在插入路径中随机挑选一个客户作为插入位置, 将被插入路径中选中的客户序列插入到插入路径中选中客户的前面.

### 2.1.5 IGWO流程

令  $P(\text{gen})$  为算法第  $\text{gen}$  代种群, 种群大小为  $\text{popsize}$ , 算法的最大运行代数为  $\text{gen\_max}$ , 根据第 2.1.1 节~2.1.4 节的描述, IGWO 的具体步骤如下.

step 1(初始化种群): 令  $\text{gen} = 1$ , 根据第 2.1.2 节, 先由前两种规则生成两个个体, 其余  $\text{popsize} - 2$  个个体由随机规则产生, 计算每个个体的适应度确定  $\alpha$ 、 $\beta$ 、 $\delta$ .

step 2(位置更新): 根据第 2.1.3 节, 将  $\omega$  中的个体分别向  $\alpha$ 、 $\beta$ 、 $\delta$  狼靠近以更新  $\omega$  群体位置, 将种群位置更新后的解按照适应度由小到大的顺序对种群中的个体进行排序, 重新确定  $\alpha$ 、 $\beta$ 、 $\delta$ .

step 3(局部搜索): 根据第 2.1.4 节, 对  $\alpha$ 、 $\beta$ 、 $\delta$  按照先车辆内、后车辆间、再车辆内的顺序进行3层递进关系的局部搜索.

step 4:  $\text{gen} = \text{gen} + 1$ , 如果  $\text{gen} \leq \text{gen\_max}$ , 则转至 step 2, 否则输出最优值.

## 2.2 重优化策略

在 VRPMTW\_FD 中, 客户的需求用三角模糊数表征, 因此只有当车辆到达客户点进行服务时, 客户

点的模糊需求量才得以明确. 为模拟车辆的实际运行情况, 测试所提出 OPRS 的性能, 首先采用随机模拟算法(SSA)模拟客户点的实际需求量, 然后运用 OPRS 对预优化方案进行动态调整.

### 2.2.1 随机模拟算法(SSA)

对于任一客户  $i$ , 其模糊需求量为  $(d_{1i}, d_{2i}, d_{3i})$ , SSA 的具体步骤如下.

step 1: 在客户的模糊区间  $[d_{1i}, d_{3i}]$  中生成一个随机数  $r$ , 并计算该随机数的隶属度  $u(r)$ .

step 2: 在区间  $[0, 1]$  中生成一个随机数  $\varepsilon$  并比较  $\varepsilon$  与  $u(r)$  的大小, 若  $\varepsilon \leq u(r)$ , 则取  $r$  为客户  $i$  的实际需求量, 否则重复以上步骤重新生成  $r$  和  $\varepsilon$ , 直至满足  $\varepsilon \leq u(r)$  为止.

step 3: 重复以上步骤  $n$  次, 直至生成所有客户的实际需求量.

### 2.2.2 最优点重调度策略(OPRS)

本文针对 VRPMTW\_FD 的特性, 提出一种新的重优化策略 OPRS. OPRS 分别在当前客户点和下一客户点将未服务的客户序列作为一条可行的重调度路线, 然后采用第 2.1.4 节中的 4 种车辆内局部搜索算子对该可行路线进行搜索, 将搜索到的最优路线成本作为该点返回的重调度成本, 通过比较两成本的大小确定合适的返回点以及合适的重调度方案. 在客户  $i$  处直接返回配送中心和继续为下一客户  $i + 1$  服务的成本如下所示:

$$C_{k(i,i+1)} = F_1 + F_2, \quad (25)$$

$$C'_{k(i,i+1)} = F'_1 + F'_2, \quad (26)$$

$$F_1 = c_1 d_{i,0} + \sum_{j=1}^{l-1} c_1 d_{\pi_j, \pi_{j+1}}, \quad (27)$$

$$F'_1 = c_1 (d_{i,i+1} + d_{i+1,0}) + \sum_{j=1}^{l-1} c_1 d_{\pi'_j, \pi'_{j+1}}, \quad (28)$$

$$F_2 = \sum_{j \in \pi} (c_2 \max\{a_j^k - e_j^a, 0\} + c_3 \max\{l_j^a - a_j^k, 0\}), \quad (29)$$

$$F'_2 = \sum_{j \in \pi'} (c_2 \max\{a_j^k - e_j^a, 0\} + c_3 \max\{l_j^a - a_j^k, 0\}). \quad (30)$$

式(25)中  $C_{k(i,i+1)}$  表示车辆  $k$  对客户  $i$  服务后直接返回配送中心, 然后对剩余客户进行重新调度所产生的费用; 式(26)中  $C'_{k(i,i+1)}$  表示车辆  $k$  对客户  $i$  服务后继续对客户  $i + 1$  服务, 在  $i + 1$  处失败后返回配送中心并对剩余客户进行重新调度所产生的费用. 式(25)和(26)中  $C_{k(i,i+1)}$  和  $C'_{k(i,i+1)}$  均由两部分组成,  $F_1$  和  $F'_1$  表示车辆的路由费用,  $F_2$  和  $F'_2$  表示确认返回点

后对剩余客户重调度产生的超时费用.  $F_1$ 、 $F'_1$ 、 $F_2$  和  $F'_2$  的计算如式(27)~(30)所示,  $\pi$  和  $\pi'$  为车辆返回配送中心后对剩余客户重新调度得到的新的配送路线,  $l$  为未服务的客户数,  $c_3$  为超出客户时间窗的惩罚系数. OPRS 执行过程具体如下.

step 1: 输入当前车辆路径  $\pi_k$ , 服务完当前客户  $i$  后的剩余载重量  $Q_i^k$  及下一待服务客户  $i+1$  的模糊需求  $\tilde{d}_{i+1}$ .

step 2: 判断下一客户的模糊需求小于车辆剩余容量的可信度  $\text{Cr}\{\tilde{d}_{i+1} \leq Q_i^k\}$ .

step 2.1: 若  $\text{Cr}\{\tilde{d}_{i+1} \leq Q_i^k\} = 1$ , 则车辆  $k$  服务完客户  $i$  后继续对客户  $i+1$  服务.

step 2.2: 若  $\text{Cr}\{\tilde{d}_{i+1} \leq Q_i^k\} < 1$ , 则按照式(25)和(26)分别计算在当前客户直接返回配送中心并重新调度的成本  $C_{k(i,i+1)}$  和在下一客户返回配送中心并重新调度的成本  $C'_{k(i,i+1)}$ , 保存两种情况下的重调度

路径  $\pi_{k1}, \pi'_{k1}$ .

step 2.3: 若  $C_{k(i,i+1)} < C'_{k(i,i+1)}$ , 则车辆  $k$  对当前客户  $i$  服务后直接返回配送中心, 并修改车辆  $k$  的剩余服务路径. 否则, 车辆  $k$  服务完当前客户  $i$  后继续为下一客户  $i+1$  服务, 若到达  $i+1$  后不能对其服务, 则先返回配送中心, 再按照路径  $\pi_{k1}$  继续进行服务; 若可以为客户  $i+1$  服务, 则服务完后在下一客户点转至 step 2 继续进行判断.

step 3: 若该路径上的客户均被服务完毕, 则算法结束, 否则转至 step 2.

### 2.3 TSHOA 流程

TSHOA 求解 VRPMTW\_FD 的流程如图 3 所示. 图中左侧虚线框内为 TSHOA 的第 1 阶段 IGWO 求解 VRPMTW\_FD 的预优化阶段, 右边虚线框内为 TSHOA 的第 2 阶段 OPRS 求解 VRPMTW\_FD 的重优化阶段.

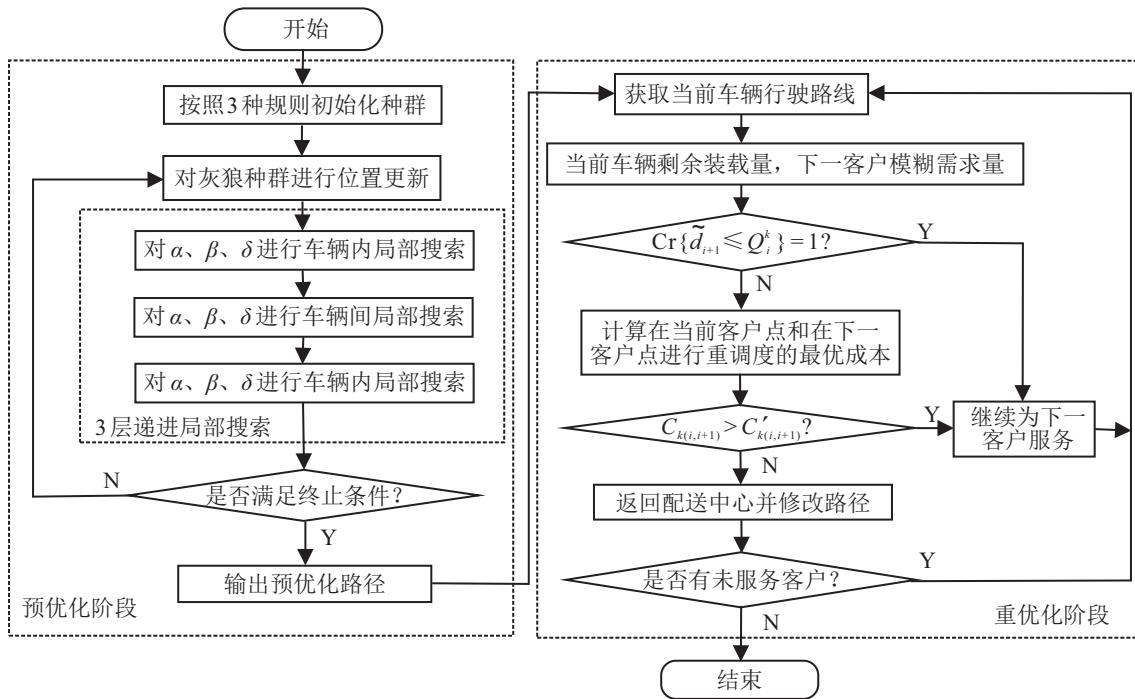


图 3 TSHOA 流程

### 3 算法验证及结果分析

目前关于 VRPMTW\_FD 没有标准算例, 为验证所提出算法的性能, 使用文献[7]的 VRPMTW 算例对 TSHOA 中的 IGWO 和 OPRS 分别进行验证. 本文所有算法和测试程序均由 Python3.7 编程实现, 操作系统为 Win10, CPU 主频为 3.30 GHz, 内存为 8 GB. 每种算法独立运行 30 次, 算法的每次运行时间为 60 s. 算法终止条件为  $T > 60$  s, 用 BST 表示算法独立运行 30 次的最优值, WST 表示算法独立运行 30 次的最差值, AVG 表示算法独立运行 30 次的平均值, 每种算法

对应的最优结果用粗体表示.

#### 3.1 算法参数设置

根据对物流公司实际运输费用的调研和文献[24-25], 将优化目标函数(2)中的系数分别设置为: 发车成本转换系数  $c = 300$  元/辆、行驶成本转换系数  $c_1 = 1.5$  元/千米、等待成本系数  $c_2 = 15$  元/小时. IGWO 涉及到的 4 个关键参数为种群规模  $popsize$ 、车辆内局部搜索系数  $\theta$ 、车辆间局部调整系数  $\rho$ 、车辆间局部搜索系数  $\sigma$ . 本文采用实验设计方法 DOE 进行实验分析, 进而确定 IGWO 的最佳关键参数组合

为:  $\text{popsize} = 25, \theta = 2, \rho = 3, \sigma = 2$ .

### 3.2 IGWO在确定型VRPMTW算例上的性能验证

为验证IGWO的有效性,将IGWO与近期求解确定型VRPMTW的HAVNTS<sup>[7]</sup>和AVNS<sup>[10]</sup>两种算法进行比较。各算法对不同问题的求解结果如表1所示。由表1可知,IGWO在绝大部分问题上的测试结果均明显优于另外两种对比算法。在算例数据具有

的特征上,CM1、CM2在客户的分布上具有群集性,且CM1的时间窗较窄,CM2的时间窗较宽,结合表1中CM1和CM2的结果可知,IGWO在处理具有群集性的数据时没有像在其他算例表现出比AVNS明显的优势,但仍有50%的较优解,且与AVNS得到的较优解相比,两算法的差距并不大。综上可知,所提出的IGWO能够有效求解VRPMTW.

表1 确定需求下3种算法求解结果

算例	HAVNTS			AVNS			IGWO		
	BST	WST	Avg	BST	WST	Avg	BST	WST	Avg
rm101	3 470.809	4 063.364	3 675.711	3 184.230	3 979.212	3 506.183	<b>2 922.454</b>	<b>3 333.950</b>	<b>3 178.827</b>
rm103	3 576.677	4 361.201	3 943.069	3 555.057	4 276.272	3 888.616	<b>3 232.885</b>	<b>3 380.601</b>	<b>3 312.738</b>
rm105	3 813.061	4 416.558	4 157.189	3 552.254	4 419.379	3 984.295	<b>3 349.616</b>	<b>3 797.646</b>	<b>3 625.392</b>
rm107	4 210.167	5 142.931	4 429.757	3 847.479	4 777.713	4 417.538	<b>3 727.218</b>	<b>4 057.218</b>	<b>3 938.382</b>
rm108	4 019.279	4 644.638	4 286.769	3 969.901	4 778.611	4 310.772	<b>3 742.629</b>	<b>4 138.293</b>	<b>4 009.792</b>
rm201	5 587.550	5 786.103	5 667.479	4 455.714	5 564.397	5 441.324	<b>3 351.139</b>	<b>3 489.632</b>	<b>3 413.492</b>
rm203	5 827.103	6 919.697	5 972.628	5 686.474	6 838.703	5 931.453	<b>4 758.547</b>	<b>4 915.229</b>	<b>4 859.089</b>
rm205	6 064.651	8 318.567	7 178.456	6 088.169	8 192.629	6 991.224	<b>5 048.402</b>	<b>6 202.636</b>	<b>5 895.948</b>
rm207	5 761.562	7 861.310	6 523.979	5 539.262	7 766.324	6 620.861	<b>4 610.676</b>	<b>5 811.503</b>	<b>5 320.753</b>
rm208	6 894.828	8 096.173	7 465.921	6 856.658	8 961.516	7 265.900	<b>4 939.610</b>	<b>6 048.266</b>	<b>5 774.019</b>
cm101	4 203.981	4 638.376	4 450.150	<b>4 188.751</b>	4 707.552	<b>4 375.781</b>	4 330.389	<b>4 509.904</b>	4 423.701
cm103	4 505.104	4 931.158	4 679.449	4 525.427	4 820.563	4 651.717	<b>4 395.607</b>	<b>4 757.339</b>	<b>4 594.656</b>
cm105	4 903.664	5 323.275	5 087.922	<b>4 790.594</b>	<b>5 102.915</b>	<b>4 973.884</b>	4 866.252	5 237.983	5 042.097
cm107	4 967.510	5 340.210	5 104.551	4 875.371	<b>5 241.156</b>	5 097.440	<b>4 842.350</b>	5 289.498	<b>4 999.281</b>
cm108	4 640.849	4 955.813	4 789.328	<b>4 546.020</b>	4 939.517	4 727.607	4 555.431	<b>4 874.278</b>	<b>4 699.842</b>
cm201	4 931.721	5 219.791	5 059.240	<b>4 735.816</b>	5 172.339	4 904.842	4 762.992	<b>4 999.752</b>	<b>4 882.142</b>
cm203	5 106.777	5 316.811	5 234.987	<b>4 797.014</b>	5 292.912	<b>5 019.005</b>	4 871.362	<b>5 225.259</b>	5 073.820
cm205	5 114.696	5 478.458	5 270.636	4 991.428	5 347.363	5 181.335	<b>4 915.687</b>	<b>5 262.212</b>	<b>5 072.359</b>
cm207	5 619.736	5 969.057	5 838.937	5 541.598	5 934.603	5 770.863	<b>5 372.461</b>	<b>5 759.743</b>	<b>5 527.618</b>
cm208	5 077.289	5 643.946	5 410.774	5 168.529	5 506.742	5 333.181	<b>4 944.418</b>	<b>5 301.538</b>	<b>5 140.588</b>
rcm101	3 825.087	4 579.910	4 196.675	3 743.927	4 575.923	4 164.509	<b>3 684.211</b>	<b>4 032.639</b>	<b>3 768.627</b>
rcm103	3 822.300	4 900.917	4 367.701	3 983.104	4 936.894	4 336.410	<b>3 717.264</b>	<b>4 101.834</b>	<b>3 904.936</b>
rcm105	4 095.228	4 932.222	4 466.720	4 086.355	4 686.600	4 435.083	<b>3 805.379</b>	<b>4 340.918</b>	<b>4 091.502</b>
rcm107	4 169.304	5 032.498	4 574.331	4 735.449	5 377.082	4 942.571	<b>4 114.593</b>	<b>4 654.686</b>	<b>4 336.202</b>
rcm108	4 055.843	4 965.217	4 470.578	4 045.503	4 728.031	4 407.811	<b>3 846.392</b>	<b>4 372.161</b>	<b>4 160.014</b>
rcm201	5 715.357	6 968.392	6 771.485	5 424.548	6 737.823	6 392.542	<b>4 450.976</b>	<b>4 767.453</b>	<b>4 624.189</b>
rcm203	5 988.358	7 353.942	7 049.778	6 002.441	7 198.141	6 891.771	<b>4 765.841</b>	<b>5 097.031</b>	<b>4 926.358</b>
rcm205	5 761.386	7 179.070	6 765.505	5 809.084	6 978.327	6 780.423	<b>4 700.562</b>	<b>4 954.867</b>	<b>4 776.199</b>
rcm207	6 305.439	8 430.378	7 405.504	7 064.405	8 321.279	7 414.292	<b>5 914.509</b>	<b>6 399.191</b>	<b>6 154.470</b>
rcm208	7 003.533	9 382.256	8 192.084	7 077.152	9 173.891	8 063.841	<b>6 155.265</b>	<b>7 247.546</b>	<b>7 002.072</b>

### 3.3 TSHOA在VRPMTW\_FD算例上的性能验证

#### 3.3.1 TSHOA在VRPMTW\_FD算例上的预优化性能验证

为验证TSHOA中的IGWO对VRPMTW\_FD也同样有效,本文选取并改进VRPMTW算例中的cm108算例对算法和模型进行测试。改进方法为将算例中客户的需求量以系数 $1 - \gamma$ 和 $1 + \gamma$ 扩充为模糊需求量,即模糊需求量 $\tilde{d} = ((1 - \gamma)d, d, (1 + \gamma)d)$ ,其中 $\gamma = 0.25$ 。求解时,偏好值 $\alpha$ 从0.1开始,按0.1的幅度递增,对每个 $\alpha$ 进行30次预优化,以测试不同偏好值对预优化阶段的影响。30次预优化的结果如表2所示,表中STD表示30次预优化的标准差。

表2 模糊需求下不同 $\alpha$ 的30次预优化结果

$\alpha$	BST	WST	AVG	STD
0.1	3 932.524	4 271.403	4 090.194	77.623
0.2	3 968.080	4 212.892	4 103.278	65.650
0.3	4 213.748	4 556.877	4 378.956	97.376
0.4	4 288.399	4 580.351	4 383.574	78.672
0.5	4 621.541	4 888.383	4 746.303	71.472
0.6	4 619.954	4 999.610	4 766.695	95.832
0.7	4 889.071	5 238.128	5 067.479	97.318
0.8	5 002.609	5 285.134	5 137.559	79.802
0.9	5 294.849	5 480.550	5 399.496	59.208
1.0	5 171.699	5 646.173	5 408.953	108.602

由表2可知,在不同 $\alpha$ 下的30次预优化结果具有较小的标准差,且 $\alpha$ 之间的标准差波动较小,表明IGWO求解VRPMTW\_FD的有效性和鲁棒性。另外,

随着偏好值 $\alpha$ 的增加,车辆的配送成本呈现出逐渐增加的趋势,表明决策者越趋于冒险( $\alpha$ 越小),预优化阶段的配送成本越低,决策者越趋于保守( $\alpha$ 越大),预优化阶段的配送成本越高.

### 3.3.2 TSHOA在VRPMTW\_FD算例上的重优化性能验证

为验证TSHOA中的OPRS对重优化阶段的有效性,通过将第3.3.1节中针对不同 $\alpha$ 得到的预优化方案作为重优化阶段的测试数据,对现有文献中使用较多的DTD和PR两种重优化策略进行对比.重优化

结果如表3所示. $P_c$ 表示预优化阶段的成本, $R_c$ 表示重优化阶段的成本, $A_c$ 表示与预优化阶段相比重优化阶段多出的成本, $N_o$ 表示重优化导致的超出客户规定时间窗的客户个数.由表3可知,所提出的OPRS在会导致路径失败的 $\alpha$ 下,重优化的结果均好于另两种对比算法,且OPRS明显降低了因路径失败导致的超出客户时间窗个数,表明了OPRS对VRPMTW\_FD的有效性.

综上可知,TSHOA是求解VRPMTW\_FD的一种非常有效的算法.

表3  $\alpha$ 递增下各最优预优化方案的不同实时调整结果

$\alpha$	DTD				PR				OPRS			
	$P_c$	$R_c$	$A_c$	$N_o$	$P_c$	$R_c$	$A_c$	$N_o$	$P_c$	$R_c$	$A_c$	$N_o$
0.1	3 932.524	4 647.627	715.103	2	3 932.524	4 446.486	513.963	<b>1</b>	3 932.524	<b>4 293.902</b>	<b>361.379</b>	<b>1</b>
0.2	3 968.080	4 565.212	597.132	3	3 968.080	4 394.411	426.331	3	3 968.080	<b>4 298.496</b>	<b>330.416</b>	<b>1</b>
0.3	4 213.748	4 989.035	775.287	3	4 213.748	4 840.351	626.603	2	4 213.748	<b>4 767.182</b>	<b>553.434</b>	<b>1</b>
0.4	4 288.399	4 875.483	587.083	<b>1</b>	4 288.399	4 695.961	407.562	<b>1</b>	4 288.399	<b>4 685.354</b>	<b>396.955</b>	<b>1</b>
0.5	4 621.541	4 871.593	250.053	<b>0</b>	4 621.541	<b>4 845.413</b>	<b>223.872</b>	<b>0</b>	4 621.541	<b>4 845.413</b>	<b>223.872</b>	<b>0</b>
0.6	4 619.954	4 826.608	206.654	<b>0</b>	4 619.954	4 815.259	195.305	<b>0</b>	4 619.954	<b>4 813.647</b>	<b>193.693</b>	<b>0</b>
0.7	4 889.071	<b>4 889.071</b>	<b>0</b>	<b>0</b>	4 889.071	<b>4 889.071</b>	<b>0</b>	<b>0</b>	4 889.071	<b>4 889.071</b>	<b>0</b>	<b>0</b>
0.8	5 002.609	<b>5 002.609</b>	<b>0</b>	<b>0</b>	5 002.609	<b>5 002.609</b>	<b>0</b>	<b>0</b>	5 002.609	<b>5 002.609</b>	<b>0</b>	<b>0</b>
0.9	5 294.849	<b>5 294.849</b>	<b>0</b>	<b>0</b>	5 294.849	<b>5 294.849</b>	<b>0</b>	<b>0</b>	5 294.849	<b>5 294.849</b>	<b>0</b>	<b>0</b>
1.0	5 171.699	<b>5 171.699</b>	<b>0</b>	<b>0</b>	5 171.699	<b>5 171.699</b>	<b>0</b>	<b>0</b>	5 171.699	<b>5 171.699</b>	<b>0</b>	<b>0</b>

## 4 结 论

本文在多时间窗车辆路径问题(VRPMTW)的基础上,进一步考虑实际配送中普遍存在的客户需求模糊不确定性,基于模糊可信性理论首次建立了以最小化总配送成本为优化目标的模糊需求下多时间窗车辆路径问题(VRPMTW\_FD)的模糊机会约束规划模型,并提出一种两阶段混合优化算法(TSHOA)进行求解.具体结论如下:

1) TSHOA的第1阶段设计改进灰狼优化算法(IGWO)获得VRPMTW\_FD的预优化路径,在IGWO的编码解码部分设计了基于LOV规则的编解码方法用于实现灰狼连续位置向量到离散客户序列的转化,从而在保留GWO个体更新机理的前提下提高了算法的全局搜索效率.在初始化种群部分设计了3种启发式规则提高了初始解的质量并增加了初始解的多样性,进而引导算法的全局搜索快速发现并探索解空间中的优质解区域.在局部搜索部分设计了具有3层递进关系的局部搜索策略对全局搜索得到的优质解区域进行更为细致且深入的搜索.

2) TSHOA的第2阶段根据VRPMTW\_FD多时间窗的特点提出一种最优点重调度策略(OPRS),对预优化阶段得到的预优化路径进行动态调整,即使预优化路径出现因客户模糊需求导致的路由故障,仍能

让车辆以较小的重优化成本为后续客户继续服务.

仿真实验和算法比较验证了TSHOA是求解VRPMTW\_FD的一种非常有效的算法.后续研究将进一步考虑具有多目标的模糊需求下多时间窗车辆路径问题,并设计有效的求解算法.

## 参考文献(References)

- [1] Dantzig G B, Ramser J H. The truck dispatching problem[J]. Management Science, 1959, 6(1): 80-91.
- [2] Rancourt M E, Cordeau J F, Laporte G. Long-haul vehicle routing and scheduling with working hour rules[J]. Transportation Science, 2013, 47(1): 81-107.
- [3] Lin S W, Yu V F. A simulated annealing heuristic for the multiconstraint team orienteering problem with multiple time windows[J]. Applied Soft Computing, 2015, 37: 632-642.
- [4] Salavati-Khosghalb M, Gendreau M, Jabali O, et al. An exact algorithm to solve the vehicle routing problem with stochastic demands under an optimal restocking policy[J]. European Journal of Operational Research, 2019, 273(1): 175-189.
- [5] Goel R, Maini R, Bansal S. Vehicle routing problem with time windows having stochastic customers demands and stochastic service times: Modelling and solution[J]. Journal of Computational Science, 2019, 34: 1-10.
- [6] Favaretto D, Moretti E, Pellegrini P. Ant colony system for a VRP with multiple time windows and multiple visits[J]. Journal of Interdisciplinary Mathematics, 2007, 10(2):

- 263-284.
- [7] Belhaiza S, Hansen P, Laporte G. A hybrid variable neighborhood tabu search heuristic for the vehicle routing problem with multiple time windows[J]. *Computers & Operations Research*, 2014, 52: 269-281.
- [8] Solomon M M. Algorithms for the vehicle routing and scheduling problems with time window constraints[J]. *Operations Research*, 1987, 35(2): 254-265.
- [9] Beheshti A K, Hejazi S R, Alinaghian M. The vehicle routing problem with multiple prioritized time windows: A case study[J]. *Computers & Industrial Engineering*, 2015, 90: 402-413.
- [10] Hoogeboom M, Dullaert W, Lai D, et al. Efficient neighborhood evaluations for the vehicle routing problem with multiple time windows[J]. *Transportation Science*, 2020, 54(2): 400-416.
- [11] Bogue E T, Ferreira H S, Noronha T F, et al. A column generation and a post optimization VNS heuristic for the vehicle routing problem with multiple time windows[J]. *Optimization Letters*, 2020: 1-17.
- [12] Teodorović D, Pavković G. The fuzzy set theory approach to the vehicle routing problem when demand at nodes is uncertain[J]. *Fuzzy Sets and Systems*, 1996, 82(3): 307-317.
- [13] 曹二保, 赖明勇, 李董辉. 基于混合差分进化算法的模糊需求车辆路径问题[J]. 系统工程理论与实践, 2009, 29(2): 106-113.  
(Cao E B, Lai M Y, Li D H. Vehicle routing problem with fuzzy demands based on hybrid differential evolution[J]. *Systems Engineering—Theory & Practice*, 2009, 29(2): 106-113.)
- [14] Peng Y, Chen J. Vehicle routing problem with fuzzy demands and the particle swarm optimization solution[C]. International Conference on Management and Service Science. Wuhan, 2010: 1-4.
- [15] 王连锋, 宋建社, 杨正磊, 等. 基于模糊期望值模型的车辆路径问题[J]. 计算机集成制造系统, 2012, 18(12): 2777-2782.  
(Wang L F, Song J S, Yang Z L, et al. Vehicle routing problem based on fuzzy expected value model[J]. *Computer Integrated Manufacturing Systems*, 2012, 18(12): 2777-2782.)
- [16] Yang W H, Mathur K, Ballou R H. Stochastic vehicle routing problem with restocking[J]. *Transportation Science*, 2000, 34(1): 99-112.
- [17] Lei H T, Laporte G, Guo B. The capacitated vehicle routing problem with stochastic demands and time windows[J]. *Computers & Operations Research*, 2011, 38(12): 1775-1783.
- [18] 李阳, 范厚明, 张晓楠, 等. 求解模糊需求车辆路径问题的两阶段变邻域禁忌搜索算法[J]. 系统工程理论与实践, 2018, 38(2): 522-531.
- (Li Y, Fan H M, Zhang X N, et al. Two-phase variable neighborhood tabu search for the capacitated vehicle routing problem with fuzzy demand[J]. *Systems Engineering—Theory & Practice*, 2018, 38(2): 522-531.)
- [19] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [20] Hemeida A M, Alkhalaif S, Mady A, et al. Implementation of nature-inspired optimization algorithms in some data mining tasks[J]. *Ain Shams Engineering Journal*, 2020, 11(2): 309-318.
- [21] Sam B B, Lenin Fred A. An efficient grey wolf optimization algorithm based extended Kalman filtering technique for various image modalities restoration process[J]. *Multimedia Tools and Applications*, 2018, 77(23): 30205-30232.
- [22] 姜天华. 混合灰狼优化算法求解柔性作业车间调度问题[J]. 控制与决策, 2018, 33(3): 503-508.  
(Jiang T H. Flexible job shop scheduling problem with hybrid grey wolf optimization algorithm[J]. *Control and Decision*, 2018, 33(3): 503-508.)
- [23] Korayem L, Khorsid M, Kassem S S. Using grey wolf algorithm to solve the capacitated vehicle routing problem[J]. *IOP Conference Series: Materials Science and Engineering*, 2015, 83: 012014.
- [24] Jabir E, Panicker V V, Sridharan R. Design and development of a hybrid ant colony-variable neighbourhood search algorithm for a multi-depot green vehicle routing problem[J]. *Transportation Research—Part D: Transport and Environment*, 2017, 57: 422-457.
- [25] Tang Y L, Cai Y G, Yang Q J. Improved ant colony optimization for multi-depot heterogeneous vehicle routing problem with soft time windows[J]. *Journal of Southeast University: English Edition*, 2015, 31(1): 94-99.

## 作者简介

- 李楠(1995-),男,硕士生,从事复杂系统智能优化的研究, E-mail: 2235750519@qq.com;
- 胡蓉(1974-),女,副教授,博士,从事优化方法及决策支持系统等研究, E-mail: ronghu@vip.163.com;
- 钱斌(1976-),男,教授,博士生导师,从事智能优化调度理论与方法等研究, E-mail: bin.qian@vip.163.com;
- 金怀平(1987-),男,副教授,博士,从事复杂过程建模与机器学习等研究, E-mail: jinhuaping@126.com;
- 于乃康(1993-),男,博士生,从事数学规划的研究, E-mail: 240004982@qq.com.

(责任编辑: 郑晓蕾)