

面向多目标车辆路径规划问题的进化多任务算法

鲁宇明^{1*}, 曹龙昊^{1,5}, 郭鑫², 艾亿豪¹, 陈昊³, 揭丽琳⁴

(1. 南昌航空大学航空制造与机械工程学院, 江西南昌 330063; 2. 北京安期生技术有限公司, 北京 101399;
3. 南昌航空大学信息工程学院, 江西南昌 330063; 4. 南昌航空大学仪器科学与光电工程学院, 江西南昌 330063;
5. 珠海京东方晶芯科技有限公司, 广东珠海 519055)

摘要: 多目标车辆路径规划问题(Multi-Objective Vehicle Routing Problem, MOVRP)是物流配送与运输领域的一个关键优化问题,直接关联物流运营效率、成本控制与客户服务质量,该问题广泛应用于城市配送、电商物流及应急物资运输等实际场景。随着物流系统规模的不断扩大及运行环境的动态化发展,MOVRP所涉及的约束条件和优化目标数量持续增加,问题结构日趋复杂,在求解效率、解集质量以及鲁棒性等方面对优化算法提出了更高要求。现有多目标优化算法在求解MOVRP时普遍采用单任务独立求解范式,即针对每个新的MOVRP问题均从零开始构建求解模型,这种求解方式忽略了不同问题实例或问题子结构之间潜在的相似性,未能有效利用历史搜索过程中积累的有用信息,从而造成重复搜索、收敛速度较慢,且在复杂场景下容易陷入局部最优,从而导致算法求解效果不佳。为应对这一挑战,本文提出一种多目标车辆路径进化多任务算法(Multi-Objective vehicle routing MultiTasking Evolutionary Algorithm, MO-MTEA)。首先,将原问题通过降维的方式拆分成若干个简单且相似的子任务,通过子任务的分层求解简化原问题的复杂度,该策略在保持原问题关键约束关系的前提下,有效降低了单个子任务的搜索空间规模,从而减轻算法的搜索负担,提高求解效率。其次,基于进化多任务(Evolutionary MultiTasking, EMT)技术,通过引入知识迁移机制,将各子任务在搜索过程中获得的有效信息在不同任务之间进行共享与传递,实现子任务之间的协同进化。该多任务协同机制能够充分挖掘不同子任务之间的潜在关联性,有效增强算法的全局搜索能力和收敛性能。最后,在主种群进化的同时,引入独立的存档种群,通过精英保留策略将主种群中的精英个体保存到存档种群中,在保证优秀解不丢失的同时,维持种群多样性和分布均匀性,防止主种群陷入局部最优。为验证该算法的性能,将所提出算法在经典Solomon测试数据集上进行测试,并与蚁群禁忌算法(Ant Colony Optimization-Tabu search, ACO-Tabu)、基于分解的多目标模因算法(Decomposition based Memetic Algorithm for Multi-Objective Evolutionary Algorithm, M-MOEA/D)、混合多目标模因算法(Hybrid MultiObjective Memetic Algorithm, HMOMA)和共同进化的约束优化(Coevolutionary framework for Constrained Multiobjective Optimization, CCMO)四种代表性的多目标进化算法进行比较。实验结果表明,MO-MTEA性能优于其他进化算法,能够更好地求解MOVRP。

关键词: 多目标优化;多任务;车辆路径规划问题;时间窗;进化算法

基金项目: 国家自然科学基金(No.62473188);江西省自然科学基金(No.20242BAB25094);江西省教育厅科技项目(No.GJJ2401009)

中图分类号: TP301;TP399

文献标识码: A

文章编号: 0372-2112(2026)01-0352-16

电子学报 URL: <http://www.ejournal.org.cn>

DOI:10.12263/DZXB.20250777

A Multi-Task Evolutionary Algorithm for Multi-Objective Vehicle Routing Problems

LU Yuming^{1*}, CAO Longhao^{1,5}, GUO Xin², AI Yihao¹, CHEN Hao³, JIE Lilin⁴

(1. School of Aeronautical Manufacturing and Mechanical Engineering, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China;
2. Beijing Anqisheng Technology Co., Ltd., Beijing 101399, China;
3. School of Information Engineering, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China;
4. School of Instrument Science and Optoelectronic Engineering, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China;
5. Zhuhai BOE MLED Technology Co., Ltd., Zhuhai, Guangdong 519055, China)

Abstract: Multi-objective vehicle routing problem is a key optimization problem in the field of logistics distribution and transportation. It is directly impact to logistics operational efficiency, cost control and customer service quality. This problem has widely exist in practical scenarios such as e-commerce warehousing and distribution, urban cold chain transportation and emergency material scheduling, As logistics systems expand in scale and operating environments become increas-

ingly dynamic, the number of constraints and optimisation objectives involved in MOVRP continues to grow, rendering the problem structure progressively more complex. This places heightened demands on optimisation algorithms regarding computational efficiency, solution quality, and robustness. Existing optimization algorithms employ a single-task independent solution approach, where each new problem is processed from scratch, where a solution model is built and the search process is initialized from scratch for each new MOVRP problem. This method fails to effectively utilise useful information accumulated during historical searches. Consequently, it leads to redundant searches, slower convergence speeds, and a tendency to become trapped in local optima in complex scenarios. This results in suboptimal algorithmic performance. To overcome the above-mentioned deficiencies, a multi-objective vehicle routing multi-task evolutionary algorithm is proposed in this paper. Firstly, the original problem is divided into several simple and similar sub-tasks by dimensional reduction, which is used to simplify the complexity of the original problem through hierarchical solution of sub-tasks. While preserving the key constraints of the original problem, this strategy effectively reduces the search space scale of individual sub-tasks, thereby alleviating the algorithm's search burden and enhancing solution efficiency. Then, based on Evolutionary MultiTasking technology, the method of knowledge transfer is adopted to transfer the searched information between sub-tasks to achieve collaborative gain of sub-tasks and assist in the solution of the original task. This multi-task coordination mechanism fully exploits latent correlations between sub-tasks, significantly enhancing the algorithm's global search capability and convergence performance. Finally, while the main population evolves, an independent archive population is introduced. The elite individuals in the main population are saved into the archive population. This ensures that high-quality solutions are not lost while maintaining population diversity and uniform distribution, effectively preventing the main population from becoming trapped in local optima. To evaluate the performance of the proposed algorithm, it is tested on the classic Solomon test dataset and compared with four mainstream evolutionary algorithms in the field, namely ACO-Tabu, M-MOEA/D, HMOMA and CCMO. Experimental results show that MO-MTEA outperforms other evolutionary algorithms and achieves superior solutions for MOVRP.

Keywords: multi-objective optimization; multitasking; vehicle routing problems; time window; evolutionary algorithm

Foundation Item(s): National Natural Science Foundation of China (No.62473188); Natural Science Foundation of Jiangxi Province (No.20242BAB25094); Science and Technology Project of the Education Department of Jiangxi Province (No.GJJ2401009)

0 引言

车辆路径规划问题 (Vehicle Routing Problem, VRP) 是运输、物流和供应链管理的基石^[1], 其广泛存在于城市轨道交通、无人驾驶车辆路径规划、外卖配送等多个场景^[2-5]。研究 VRP 问题不仅能够降低物流成本, 而且能够显著提高配送效率, 达到降本增效的目的。如何科学规划物流配送路线, 是实现运输成本最小化、推动物流行业高效发展的关键所在。近年来, 在智慧城市和智慧交通不断发展的过程中, 物流行业较之过去也得到了大量的发展。随着客户对于物流行业的要求越来越严格, 需要处理的目标不断增加。因此, 多目标车辆路径规划问题逐渐成为路径规划问题的研究热点。如何有效地求解 MOVRP (Multi-Objective Vehicle Routing Problem) 也成为了学者的主要研究方向。

求解 MOVRP 不仅需要平衡多个目标, 而且还要考虑时间窗带来的影响。在经典 VRP 的基础上引入时间窗后, 使得车辆不仅需要满足空间路径规划要求, 还需在给定的服务时段内到达客户点, 严格的时间窗约束缩减了可行的路径选择, 使问题更为复杂。

早期求解 MOVRP 的方法主要依赖于精确算法, 如分支定价算法和动态规划算法^[6-7]等。虽然这类算法在处理小规模算例上具有一定的优势, 但随着客户数量和问题规模的增加, 其计算复杂度显著提高, 导致在大规模问题上难以高效求解。为解决这一问题, 研究人员将进化算法引入 MOVRP 领域, 并取得了较好的效果。文献[8]提出了一种显式进化多任务优化 (Evolutionary MultiTasking Optimization, EMTO) 框架, 结合任务的特点, 深入挖掘任务间隐含的关联性, 并提出了一种基于车辆位置映射和相关性评估的 EMTO 算法。文献[9]提出了一种混合多目标灰狼算法, 该算法通过区间变换实现编码转换, 利用多策略选择个体以平衡收敛性和多样性, 结合粒子群算法增强全局收敛, 并通过二层局部搜索提高局部搜索能力, 从而有效求解多目标 MOVRP 问题。文献[10]提出一种基于动态分解和角度惩罚距离的高维多目标进化算法。该算法基于动态分解将种群分成多个类别, 此过程无需预先设定参考向量, 可根据种群自身分布信息进行分解。之后, 基于改进的角度惩罚距离从每类中选择个体, 从而平衡收敛性与多样性。

尽管进化算法在求解多目标车辆路径问题时表现出较好的性能,但其通常采用单任务独立求解模式,这种模式下,每次均从零开始处理新问题,未能有效挖掘问题间的潜在关联性,无法为后续相似问题的求解提供帮助,导致计算资源重复消耗。为突破这一局限,研究人员提出了一项新的技术——进化多任务(Evolutionary MultiTasking, EMT)^[11]。该技术通过构建跨任务知识迁移机制,可在异构搜索空间中实现多任务的并行协同优化。文献[12]提出了一种进化多任务处理算法,用于同时解决 MOVRP。该算法通过统一的解码方式整合不同任务,并在任务间共享路径信息,从而提升优化效率和质量。文献[13]提出混合进化多任务算法用于解决多目标车辆路径问题。该算法通过同时优化多个相关的 MOVRP 任务,利用不同任务之间的相似性,实现知识的转移和共享,从而提高优化效率和解的质量。文献[14]提出了一种显式进化多任务算法,求解车辆路径等组合优化问题。该算法通过构建稀疏映射、计算权重矩阵和捕获迁移映射的加权范数正则化学习过程来完成跨车辆路径问题的知识转移。文献[15]提出了一种基于历史信息引导的多目标进化算法来解决多目标车辆路径问题。该算法通过构建信息矩阵收集历史进化过程中的有效信息,指导交叉和变异操作,从而产生更优质的后代解。该算法还引入了自适应局部搜索策略,根据种群进化状态动态选择最适合的局部搜索算子,以加速收敛并提升解的质量。在多任务中,知识转移是一个很重要的过程,文献[16]研究了如何采用知识转移策略。文献[17]提出了一种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,用于求解同时取送货的车辆路径问题。该算法将进化多任务方法引入大规模车辆路径问题,并在京东物流公司快递取送货数据集上进行实验验证,结果表明其在路径规划效果上优于当前最新提出的路径规划算法。

针对现有算法求解 MOVRP 的效果不佳、难以找到最优配送路径的问题,受上述思想启发,本文将 EMT 技术应用到多目标车辆问题领域,并提出了一种面向多目标车辆路径问题的进化多任务算法。该算法首先通过混合初始化策略生成分布均匀的初始种群;然后采用进化多任务方法将原任务拆分成多个简单的子任务以简化问题的复杂度,以及利用知识迁移操作实现各任务之间的信息共享;最后引入存档种群,将筛选出的精英个体独立保存至存档种群中以防止种群陷入局部最优。为验证算法性能,将所提出算法与 4 种性能优越的算法在 Solomon 测试数据集上进行对比实验。实验结果表明,本文算法性能显著优于

其他对比算法,能够更好地求解 MOVRP。

1 问题描述及模型

1.1 符号及变量定义

为了方便描述 MOVRP 问题以及建立对应的数学模型,本文所使用的参数和变量符号如表 1 所示。

表 1 变量说明

Table 1 Variable explanation

符号	说明
Q	车辆最大容量
q_i	客户 i 的需求量
N	总客户数, i, j 表示客户编号
C	总的车辆数
d_{ij}	车辆从客户 i 到 j 的距离
t_{ij}	车辆从客户 i 到客户 j 的行驶时间
s_i	客户 i 的服务时间
$[a_i, b_i]$	a_i 和 b_i 分别是客户 i 接受服务的开始时间和结束时间
N_p	种群规模
k	子任务数量
决策变量 y_{ijc}	由客户 i 到客户 j 的车辆 c , 离开客户 i 的载重量
决策变量 x_{ijc}	若车辆 c 从客户 i 到客户 j , 则为 1, 否则为 0

1.2 MOVRP 数学模型

本文研究的 MOVRP 具体描述如下:有一组总数为 N 的客户,每个客户都有特定的需求量 q_i ,同时存在一个配送中心,配送中心内的车辆总数为 C ,每辆车的最大容量为 Q 。所有车辆从配送中心出发,在分别服务不同的客户点后返回配送中心。每辆车必须在满足客户要求的时间窗口 $[a_i, b_i]$ 内对顾客进行服务,如果车辆在客户时间窗开始之前到达,则必须等到时间窗开始。相反,如果车辆超过了客户时间窗内指定的最晚服务时间,服务将被拒绝。每辆车的载重量不能超过车辆容量。在满足所有约束条件的情况下,最小化车辆使用数目和总路径长度。MOV RP 模型的无向图 $G=(V, E)$ 如图 1 所示。其中,顶点集 $V=\{v_0, v_1, v_2, \dots, v_n\}$ 包含一个配送中心 v_0 和 n 个需要接受服务的客户;边集 $E=\{(v_i, v_j) \mid v_i, v_j \in V, i \neq j\}$ 表示每个客户点之间的弧集。

为方便表述,仓库统一标记为 0,客户表示为 $1 \sim n$ 。基于该问题,本文做出如下假设:

(1) 客户点的位置、时间窗、服务时间和需求量均为已知,且每辆车最多只能执行一条路径的服务。

(2) 当车辆在开始时间之前到达客户 i 时,车辆必须等待;车辆不能在结束时间之后到达客户 i 。

(3) 车辆从配送中心出发,完成一系列配送任务

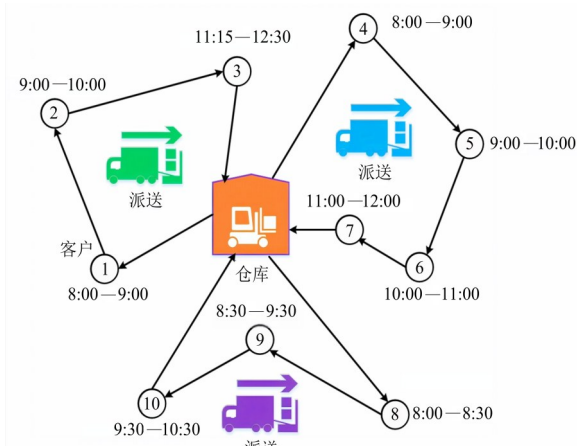


图1 多目标车辆路径规划图示

Figure 1 Illustration of multi-objective vehicle path planning

后,需要在规定的时间内返回配送中心。

(4)所有配送车辆的速度、载重均一致。

(5)每条路线的运输总量不能超过车辆的最大容量。

根据以上假设,本文研究的MOVRP主要需要优化两个目标:分配给客户服务的车辆数量和所有车辆的总行驶距离。本文构建的MOVRP数学模型目标函数为

$$\min \begin{cases} f_1 = C \\ f_2 = \sum_{i=1}^N \sum_{j=0}^N \sum_{c=1}^C d_{ij} a_{ijc} \end{cases} \quad (1)$$

其中, f_1 为所有客户提供服务所需的车辆数量; f_2 为计算所有车辆的总行驶距离; C 为车辆的使用数量; d_{ij} 为客户节点 N_i 和客户节点 N_j 之间的距离; a_{ijc} 为一个二进制变量,表示客户 N_i 和客户 N_j 是否同时由第 c 辆车提供服务。如果两个客户都使用同一辆车则 a_{ijc} 的值为1,否则为0。

本文构建的MOVRP约束条件为

$$\sum_{c=1}^C \sum_{j=0}^N x_{0jc} \leq C \quad (2)$$

$$\sum_{j=1}^N y_{0jc} = \sum_{j=1}^N q_j \sum_{i=0}^N x_{ijc} \leq Q \quad (3)$$

$$y_{ijc} \leq x_{ijc} Q, i=1, 2, \dots, N; k=1, 2, \dots, C \quad (4)$$

$$\sum_{c=1}^C \sum_{i=0}^N x_{ijc} = 1, j=1, 2, \dots, N \quad (5)$$

$$\sum_{i=0}^N x_{ijc} = \sum_{i=0}^N x_{jic} \quad (6)$$

$$a_i + s_i + t_{ij} \leq b_i \quad (7)$$

$$x_{ijc} = \{0, 1\}, i, j=1, 2, \dots, N; c=1, 2, \dots, C \quad (8)$$

$$y_{ijc} \geq 0, i, j=1, 2, \dots, N; c=1, 2, \dots, C \quad (9)$$

式(2)表示运输的车辆数不能超过最大车辆数;

式(3)限定车辆服务的客户节点总需求不超过其最大载重能力;式(4)要求各路径中任一客户节点处的车辆载重量均小于最大容量;式(5)确保每个客户只有一辆车提供服务;式(6)规定需平衡客户节点的进出车辆数量;式(7)限制车辆服务客户的时间处于其指定时间窗内,对于后续不满足该约束的解决方案将被舍去;式(8)和式(9)为相关变量约束。

2 算法设计

2.1 MO-MTEA 总体框架

为有效地解决多目标车辆路径规划问题,本文提出一种面向多目标车辆路径问题的进化多任务算法(Multi-Objective vehicle routing MultiTasking Evolutionary Algorithm, MO-MTEA),该算法采用了进化多任务技术,通过将复杂的原任务拆解成多个简单的子任务以降低问题的复杂度,提高算法的求解效率。具体算法流程图如图2所示。

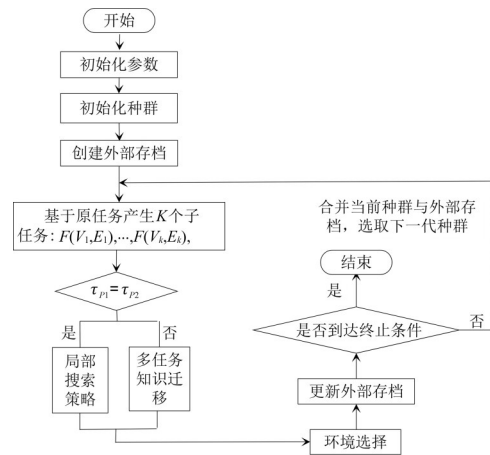


图2 MO-MTEA算法流程图

Figure 2 MO-MTEA flowchart

MO-MTEA首先使用混合策略初始化种群并创建一个外部存档以储存后续精英个体;其次通过EMT技术构造多个简单且相似的子任务,并在所有任务中评估每条染色体,以获得相应的因子成本、因子等级、标量适应度和技能因子;然后根据各任务的技能因子是否相等来决定执行交叉方法或迁移方法产生子代,对子代进行环境选择操作并更新外部存档;最后判断是否满足终止条件并输出MOVRP最优解。

2.2 混合策略初始化种群

初始种群的质量对种群的收敛性具有关键作用。为防止随机初始化种群出现“早熟”以及对解空间覆盖不均匀的现象,本文引入佳点集方法^[18],利用佳点集策略与随机初始化结合的混合策略来初始化种群,其中这两种方式生成的种群比例为1:1。这种方法

能够生成分布更为均匀的初始个体,降低初始个体的重复率并拓宽搜索范围,有助于在全局搜索过程中更加高效地接近全局最优解,从而提升算法的求解精度。

佳点集的基本定义如下:设 S_n 是 n 维欧式几何空间,对任意给定中的点 $r \in S_n$,那么空间中的点集可以表示为

$$P_m(k) = \{(r_1k), (r_2k), \dots, (r_nk)\}, k = 1, 2, \dots, m$$

取点 $r_k = 2\cos(2\pi k/p)$, $1 \leq k \leq n$, p 是满足 $(p-3)/2 \geq n$ 的最小素数,或取 $r_k = e^k$, $1 \leq k \leq n$,则称

$P_m(k)$ 为佳点集,称 r_k 为佳点。

图3是不同策略下的种群分布图,从图3(a)可以看出,随机初始化的种群呈散乱无序分布,解空间覆盖率较低,存在明显空白区域;从图3(b)可以看出,采用佳点集法初始化的种群虽具有数学规则性(线性均匀排列),但受限于确定性生成机制,导致个体分布模式固化,缺乏必要的随机扰动;而从图3(c)可以看出,采用混合策略(随机与佳点集按1:1比例配置)初始化的种群既通过随机分布保持灵活性,又利用佳点集规律性提升覆盖均匀度,最终在避免个体重叠的同时显著提升了种群多样性。




图3 各种策略下的种群分布图

Figure 3 Population distribution under different strategies

2.3 进化多任务方法

求解多目标车辆路径问题的关键是得到在满足约束条件下规划出来的多条配送路径,而这些配送路径之间相互独立但结构相似且具备一定的关联,这与进化多任务方法设计理念相契合,因为 EMT 方法是通过降维的方式将复杂的原始任务拆分成若干个独立进化的子任务,并利用不同任务之间的信息交流,将有用的信息以知识的形式在不同任务之间进行迁移,以实现各个任务间的资源共享。进化多任务方法主要包括:子任务的生成、多任务的知识迁移。首先引入几个 EMT 的定义^[12]。

定义 1 因子排位 r (factorial rank)。 r_p 表示个体 P 在种群成员列表中的索引,该列表是按种群个体在一个特定任务上的因子代价升序排序的。

定义 2 因子代价 f (factorial cost)。 个体 P 的因子代价 f_p 表示其在特定任务上的适应度或目标值。对于 $k+1$ 个任务,会有一个长度为 $k+1$ 的向量,其中每个维度给出 P 在相应任务上的适应度。

定义 3 标量适应度 φ (scalar fitness)。 标量适应度是用于衡量个体在多任务环境下综合表现的一个重要指标,对于个体 P ,其标量适应度 φ_p 是基于它在

所有任务中的最佳排名来确定的,其计算公式为

$$\varphi_p = \left[1 / \min_{j \in \{0, \dots, k\}} r_p^j \right]_0$$

定义 4 技能因子 τ (skill factor)。 P_i 的技能因子 τ_{P_i} 是种群中个体在所有其他任务中最有效的一个任务,用于衡量个体在多任务环境中的相对优势。其计算公式为 $\tau_p = \operatorname{argmin}_j r_p^j, j \in \{0, 1, \dots, k\}$ 。

2.4 子任务的生成

子任务生成操作是进化多任务算法的重要步骤,MO-MTEA 通过降维的方式,将原任务拆分、重构成多个规模较小的子任务,以降低原任务的计算难度。子任务生成操作主要包括以下几个步骤。

(1) 产生一个随机数 ran , 其中 a 表示子任务设定的最低维度, b 表示原任务的维度;然后根据公式 $N = \operatorname{ran} \times |V|$ 计算出子任务所包含的顾客数目即子任务的维度。

(2) 遍历每个子任务中的所有顾客,得到顾客形成的节点信息 V_i 和边集 E_i , 将所有边集之和最小的路径集作为子任务 $G(V_i, E_i)$ 。

(3) 计算种群 P 中所有个体的因子代价 f_p 、因子排位 r_p 、标量适应度 φ_p 和技能因子 τ_p 。

具体流程如算法 1 所示。

算法 1 子任务的生成

输入: 子任务个数 k , 种群 P

输出: k 个子任务 $G(V_1, E_1), G(V_2, E_2), \dots, G(V_k, E_k)$, 种群 P

1. FOR $i=1:k$ DO
2. 产生一个随机数 $\text{ran} \in (a, b)$
3. $N = \text{ran} \times |V|$
4. 选择 $G(V_i, E_i)$ 中索引为 1 到 N 的 N 个客户形成节点信息 V_i 和对应边集 E_i 作为子任务 $G(V_i, E_i)$
5. END FOR
6. FOR $p \in P$ DO
7. 计算 P 在对应的 $k+1$ 个任务上的适应值向量作为因子代价 f_p
8. 计算 P 的排位向量作为因子排位 r_p
9. 计算 P 的标量适应度 ϕ_p 和技能因子 τ_p
10. END FOR

图 4 是 MO-MTEA 算法生成子任务的示意图。在图中, MO-MTEA 将复杂的原任务通过降维的方式生成多个简单的子任务, 每个子任务既相互独立, 又具有一定的关联。该方式能够有效地降低原任务的空问维度和算法的运行难度, 以加快种群的收敛速度。




图 4 子任务生成

Figure 4 The process of generating sub-task

图 5 给出了从维度为 10 的候选解 $[4, 6, 2, 3, 8, 9, 7, 1, 5, 10]$ 中生成子任务的示例。例如, 当生成的随机数 $\text{ran} = 0.6$ 时, 则表示子任务的维度是 6, 这时 MO-MTEA 便从原任务中选择索引 1~6 的节点作为子任务 1 的候选解 $[4, 6, 2, 3, 1, 5]$; 同理, 当生成的随机数 $\text{ran} = 0.8$ 时, 则从原任务中选择索引 1~8 的节点作为子任务 2 的候选解 $[4, 6, 2, 3, 8, 7, 1, 5]$ 。由于子任务是从原任务中随机选择 n 个客户生成的, 这确保了子任务的多样性, 并有助于原任务跳出局部最优解。此外, 子任务是通过将原任务拆分、降维后得到的, 所以其拓扑结构与原任务相似, 求解相对简单。

2.5 多任务迁移

多任务知识迁移机制的具体流程如算法 2 所示。

其中, 算法 2 有两个输入, 分别是所有任务




图 5 子任务生成例子

Figure 5 An example of generating sub-task

算法 2 多任务知识迁移

输入: 任务 $G(V, E), G(V_1, E_1), \dots, G(V_k, E_k)$, 种群 P

输出: 子代 O_0

1. 通过二元锦标赛从 P 中选出父代 P_1, P_2
2. 产生一个随机数 $\text{ran} \in (0, 1)$
3. IF $\tau_{p_1} = \tau_{p_2}$ OR $\text{ran} < \text{rmp}$ DO
4. 根据任务 $G(V_{\tau_{p_1}}, E_{\tau_{p_1}})$ 将 P_1, P_2 进行解码得到父代 P'_1, P'_2
5. 将 P'_1 和 P'_2 执行扩展分割操作
6. 将 P'_1, P'_2 通过交换突变方法产生子代 O_1, O_2 , 将 O_1, O_2 合并为子代 O_0
7. ELSE
8. 根据原任务 $G(V, E)$ 将 P_1, P_2 进行解码得到父代 P'_1, P'_2
9. 将 P'_1, P'_2 通过迁移操作生成子代 O_1, O_2 , 将 O_1, O_2 合并为子代 O_0
10. END IF
11. RETURN O_0

$G(V, E), G(V_1, E_1), \dots, G(V_k, E_k)$ 和种群 P 。然后通过二元锦标赛操作从种群 P 中选出两个父代 P_1 和 P_2 并计算得出父代 P_1 和 P_2 的技能影响因子 τ_{p_1} 和 τ_{p_2} 。然后判断 τ_{p_1} 是否等于 τ_{p_2} , 这会出现以下两种情况:

情况 1: $\tau_{p_1} = \tau_{p_2}$, 或者 $\text{ran} \leq \text{rmp}$, 则表明 P_1 和 P_2 的解在该任务表现一样好。那么先将父代 P_1 和 P_2 根据任务 $G(V_{\tau_{p_1}}, E_{\tau_{p_1}})$, 按图 5 方法得到父代的染色体 P'_1, P'_2 。然后将父代 P'_1 和 P'_2 执行扩展分割操作进行解码, 最后将解码后的父代采用基于交换突变方法产生子代 O_1, O_2 。

情况 2: $\tau_{p_1} \neq \tau_{p_2}$, 则说明当前任务的路径信息并不相等。那么将父代 P_1 和 P_2 根据原任务 $G(V, E)$, 并按图 5 得到父代的染色体 P'_1, P'_2 。最后将父代采用基于知识迁移的操作生成子代 O_1, O_2 。

最后将子代 O_1 和 O_2 合并为子代 O_0 , 并输出 O_0 。

为控制多任务知识迁移的频率, 本文引入了一个参数 $\text{rmp}^{[12]}$ 。当 rmp 值设置得较大时, 可以降低各任务之间共享信息的频率; 而当其设置得较小时, 则允许各个任务之间共享更多路径信息。

多任务知识迁移方法能够有效提高种群进化效率, 其中最主要的操作包括: 扩展分割操作、基于交换突变方法产生子代和基于知识迁移操作产生子代。具体操作如下:

(1) 扩展分割操作

扩展分割方法主要是将基于排列的染色体解码成可行的车辆路径的过程,在车辆路径规划领域,一般通过插入行程分隔符对染色体进行分割,并选择最佳分区作为输出路径的解决方案^[19]。

图6是本文设计的个体的扩展分割操作示意图。假设当前父代P的编码为[1,2,3,4,5],说明需要服务5个顾客。每个顾客到配送中心的距离、顾客与顾客之间的距离、每个顾客的时间窗口、每个顾客的需

求量以及每辆车的满载已经在图中给出。在满足车辆容量与时间窗约束的前提下,当前个体会被解码出3种路径。其中路径a=[0,1,0,2,0,3,0,4,0,5,0]需要的车辆数为5,总路径长度为300;路径b=[0,1,2,0,3,4,0,5,0]需要的车辆数为3,总路径长度为220;路径c=[0,1,0,2,3,0,4,5,0]需要的车辆数为3,总路径长度为215。最后按所用车辆数最少,总路程最小,得出父代P的解码路径为c=[0,1,0,2,3,0,4,5,0]。

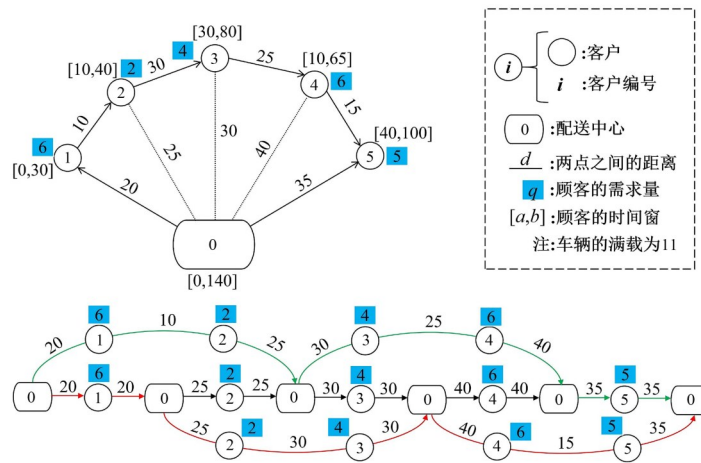


图6 扩展分割操作

Figure 6 Extended split operation

(2) 基于交换突变方法产生子代

当父代P₁和P₂的技能因子相等时,即τ_{p1}=τ_{p2},此时将采用交换突变方法产生子代。如图7所示,首先在父代1和父代2的染色体中分别选择出需要进行交换突变的基因序列:[2]、[7]和[7]、[6];然后将父代1的基因序列进行交换,得到子代1的基因序列:[4,6,7,3,8,9,2,1,5,10]。重复上述操作,可以得到子代2的基因序列:[3,2,6,4,8,5,7,1,9,10]。




图7 交换突变方法

Figure 7 Exchange and mutation

- (a) 随机生成编码长度相同的0或1数列R1。
- (b) 将父代P₁的对应数列R1为1位置工序直接复制至子代C1,并保持其在序列中的位置不变。同样,父代P₂的对应数列R1为1位置工序也直接复制至子代C2。
- (c) 父代P₂的对应数列R1为0位置工序被赋予子代C1,而父代P₁的对应数列R1为0位置工序则赋予子代C2,均保持其原始位置。

(3) 基于知识迁移操作产生子代

在种群P进行解码的过程中,得到的技能因子τ_p代表着当前任务最有用的路径信息。由于不同的个体可能具有不同的技能因子,因此每个个体都包含特

定任务的有价值的路径信息。当MO-MTEA将具有不同技能因子的个体进行交叉操作时,就会自动实现跨任务之间的知识迁移^[20],并完成不同MOVRP任务间的经验共享。因此,设计交叉操作产生子代对子任务之间的路径信息交换,以及促进任务间的知识自动化转移至关重要,这可以有效提升各独立任务的求解效率。

当父代P₁和P₂的技能因子不相等时,即τ_{p1}≠τ_{p2},说明父代P₁和P₂的当前任务的路径信息存在明显差异,此时将P₁和P₂执行交叉操作就能将父代个体的路径信息进行知识迁移,具体交叉操作如图8所示。

在图8中,首先在父代1和父代2的染色体中分别选择出待交叉的基因序列:[3,8,9,7]和[4,8,5,6],然后将父代1的基因序列插入父代2的染色体前端,并将它们合并成一个大的染色体序列,然后将这

个染色体序列里的重复片段删除,最终得到子代1的基因序列:[3,8,9,7,2,4,5,6,1,10]。重复上述操作,可以得到子代2的基因序列:[4,8,5,6,2,3,9,7,1,10]。




图8 交叉操作

Figure 8 Crossover operation

2.6 环境选择

环境选择操作的目的是将子代种群和父代种群进行筛选,保留最好的个体。MO-MTEA算法的环境选择输出端有3个:所有任务 $G(V, E), G(V_1, E_1), \dots, G(V_k, E_k)$ 、种群 P 、子代 O_1 和 O_2 ,具体操作如算法3所示。

算法3 环境选择

输入:任务 $G(V, E), G(V_1, E_1), \dots, G(V_k, E_k)$,

种群 P ,子代 O_1 和 O_2

输出:种群 Q 和存档种群

1. FOR $O' \in \{O_1, O_2\}$ DO
2. IF O' 有两个父母 DO
3. 生成一个随机数 $\text{ran} \in (0, 1)$
4. IF $\text{ran} < 0.5$ DO
5. O' 继承父代 P_1 的技能因子 τ_{p_1}
6. ELSE
7. O' 继承父代 P_2 的技能因子 τ_{p_2}
8. END IF
9. ELSE
10. O' 继承父代的技能因子 τ_p
11. END IF
12. END FOR
13. O' 对任务 $G(V_{\tau_{o'}}, E_{\tau_{o'}})$ 采用局部搜索策略
14. 将其他未评估任务的因子代价 f_c 设置为 ∞
15. 将种群 P 和子代 O' 合并成新种群 Q ,即 $Q = P \cup O'$
16. 更新种群 Q 中个体的因子排位和标量适应度
17. 通过染色体评估保存 Q 中最好的 N_p 个解,记为 Q_{arc} ,将 Q_{arc} 加入存档种群
18. RETURN 种群 Q 和存档种群

在算法3中,首先将所有子代个体记为 O' ,并产生一个随机数 $\text{ran} \in (0, 1)$ 。接着判断 O' 的父母是单亲还是双亲。

(1)如果 O' 的父母是双亲,这说明 O' 是通过交叉操作产生的子代。那么当 ran 小于0.5时, O' 继承父代 P_1 的技能因子 τ_{p_1} 。否则 O' 将继承父代 P_2 的技能因子 τ_{p_2} 。

(2)如果 O' 的父母是单亲,则表明 O' 是通过交换突变操作产生的子代,将 O' 继承父代 P 的技能因子 τ_p 。

然后,将子代个体 O' 对任务 $G(V_{\tau_{o'}}, E_{\tau_{o'}})$ 采用局部搜索策略,并将对应其他未评估任务的因子代价 f_c 设置为 ∞ 。然后将父代种群 P 和子代 O' 合并成新种群 Q 。同时更新种群 Q 中个体的因子排位和标量适应度,并将种群 Q 进行染色体评估,保存 Q 中最好的 N_p 个解,记为 Q_{arc} ,最后 Q_{arc} 将加入存档种群。

算法3中染色体评价(步骤18)采用标量适应度来进行染色体评估。对于两个染色体 P_1 和 P_2 :如果 φ_{P_1} 小于 φ_{P_2} ,那么说明染色体 P_1 优于染色体 P_2 ;否则,表示染色体 P_1 劣于染色体 P_2 。

2.7 算法复杂度分析

MO-MTEA主要包括种群初始化、外部存档、进化多任务方法和环境选择四个部分。假设 N 为种群中个体数量, M 为目标个数,其中种群初始化和设置外部存档的计算复杂度为 $O(MN)$ 。进化多任务方法又包括子任务的生成和多任务知识迁移操作,从算法1可以得出,随机生成 k 个子任务的复杂度是 $O(MN)$,而在算法2中,多任务知识迁移操作中扩展分割的复杂度为 $O(MN^2)$,其他步骤复杂度均为 $O(MN)$,所以进化多任务方法的计算复杂度为 $O(MN^2)$ 。在算法3中,MO-MTEA环境选择最坏情况下的复杂度为 $O(MN^2)$ 。综合以上分析,MO-MTEA的总体复杂度为 $O(MN^2)$ 。

3 实验及分析

3.1 测试问题

本文使用的测试数据集来源于著名的Solomon基准测试集。Solomon基准数据集由56个典型测试案例构成。根据数据分布的特点,可以将这些算例分为三大类^[21],分别命名为C(聚集分布型)、R(随机分布型)、RC(随机聚集分布型)。其每个算例包含100个客户,算例规模适中,与实际的车辆路径规划问题较为接近。

图9绘制了三种不同类型数据集的分布,图(a)、(b)和(c)分别为C101、R101和RC101的数据分布。其中,红色小车代表配送中心,蓝点小人代表客户点。

根据客户需求、配送车辆载重限制和服务时间等




图9 三种不同类型数据集的分布概况

Figure 9 The distribution of three datasets

因素,可以将 Solomon 测试集分为 6 个不同的组: R1、R2、C1、C2、RC1 和 RC2。具体数据见表 2。

表 2 Solomon 标准测试集数据

Table 2 Datas about Solomon test set

算例集	客户数量	客户需求	配送车辆载重限制	服务时间
C101-C107	100	10~50	200	90
C201-C208	100	10~50	700	90
R101-R112	100	1~41	200	10
R201-R211	100	1~41	1 000	10
RC101-RC108	100	2~40	200	10
RC201-RC208	100	2~40	1 000	10

3.2 对比算法及其参数设置

(1) 对比算法

为验证算法的有效性,本文将所提出的 MO-MTEA 算法与两个启发式算法(蚁群算法和禁忌搜索算法)组成的混合算法^[22](ACO-Tabu)、混合多目标模因算法 HMOMA^[23],以及两个著名的进化算法 M-MOEA/D、CCMO^[24]进行对比实验。启发式算法在求解车辆路径问题上一直有不俗的效果^[3],故对比算法选择两个启发式算法。M-MOEA/D 算法是将一个多目标问题分解成多个单目标问题进行求解,而 CCMO 算法则是采取双种群协同进化,两个种群分别致力于满足约束和优化目标,这两种算法与 EMT 技术类似,因此加入进行对比。

(2) 实验参数设置

实验参数设置见表 3。

本文算法子任务个数设置为 2, rmp 和局部搜索概率 P_{ls} 按文献^[12]分别设置为 0.3 和 0.1 效果最优。为保证实验环境的公平性,各算法迭代次数和交叉变异参数根据文献^[15]统一进行设置。

表 3 参数设置

Table 3 Parameter setting

参数	值
子任务个数	2
rmp	0.3
搜索概率 P_{ls}	0.1
迭代次数	100
交叉概率	0.8
突变概率	0.2
交叉参数	20
变异参数	20

3.3 实验结果与分析

在车辆路径规划领域,已知最优解(Best Know Solution, BKS)由挪威工业研究院(SINTEF)在其官方网站(<https://www.sintef.no/projectweb/top/vrptw/>)发布,该平台是国际公认最具权威性的算法测试结果比较和提交平台。

表 4 是 5 种算法及已知最优解(BKS)在 C 类型数据集上获得的结果,其中各算法获得的最优解以红色字体标注,下同。C 类算例因其客户点呈聚类分布特性,通常被视为结构复杂度较低的问题集。由表 4 可知,在 15 个 C 类问题中:ACO-Tabu 算法获得了 1 个最优解;M-MOEA/D 和 HMOMA 算法并未获得最优解;CCMO 算法获得了 8 个最优解;而 MO-MTEA 算法表现最优,共获得了 13 个最优解。进一步分析显示,MO-MTEA 的最优解获取率相较于 ACO-Tabu、M-MOEA/D、HMOMA、CCMO 算法,分别提高了 80%、86.7%、86.7%、33.3%,其综合最优解获取率提高了 71.6%。这一结果表明,MO-MTEA 算法在求解具有聚类特征的 C 类问题算例时,展现出明显的优势。

表 5 是已知最优解(BKS)与 5 种算法在 R 类型数据集上获得的结果,这类算例呈现随机分布,所有客

表 4 各算法在 C 类型数据集上求解结果

Table 4 Results of the algorithms on C-type dataset

测试问题	BKS(已知最优解)		ACO-Tabu		M-MOEA/D		HMOMA		CCMO		MO-MTEA	
	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2
C101	10	828.9	11	831.7	13	837.3	10	838.9	10	828.9	10	828.9
C102	10	828.9	12	849.8	13	850.4	11	852.2	10	850.1	10	828.9
C103	10	828.0	13	855.2	15	858.8	11	860.0	10	857.1	10	828.0
C104	10	824.7	10	845.4	14	849.0	10	850.8	10	850.6	10	845.6
C105	10	828.9	11	829.7	13	833.3	10	838.9	9	830.2	10	828.9
C106	10	828.9	11	830.5	13	834.1	10	839.9	9	828.9	10	828.9
C107	10	828.9	12	831.3	14	834.9	7	840.7	11	831.4	10	828.9
C201	3	591.6	4	593.6	6	599.2	7	602.0	3	591.6	3	591.6
C202	3	591.5	4	594.5	6	600.1	7	602.9	3	591.6	3	591.5
C203	3	591.2	4	592.2	6	597.8	7	600.6	3	591.2	3	591.2
C204	3	590.6	4	598.6	6	604.2	7	607.0	3	596.6	4	619.7
C205	3	588.9	4	590.8	6	596.4	7	599.2	3	588.9	3	588.9
C206	3	588.5	4	590.5	6	596.1	7	598.9	3	588.5	3	588.5
C207	3	588.3	4	590.3	6	595.9	7	598.7	3	588.3	3	588.3
C208	3	588.3	3	588.1	6	591.7	7	593.5	3	588.3	3	588.3

户点相对分散,导致此类算例较为复杂,对求解算法来说具有一定的考验。由表 5 可知,在 23 个 R 类问题中:ACO-Tabu 算法获得了 1 个最优解;M-MOEA/D、HMOMA 和 CCMO 算法均未获得最优解;而 MO-MTEA 算法获得了 7 个最优解。MO-MTEA 的最优解获取率相较于 ACO-Tabu、M-MOEA/D、HMOMA、CCMO 算法,分别提高了 26.1%、30.4%、30.4%、30.4%,综合最优解获取率提高了 29.3%。这一结果表明,MO-MTEA 算法在求解 R 类算例上相较于其他算法具有一定的优势。

表 6 是已知最优解(BKS)与 5 种算法在 RC 类型数据集上获得的结果,这类算例属于随机聚集分布型,中间客户点呈现随机分布,边缘客户点呈现聚集分布。这类算例比单一随机或者聚集分布更加难以求解,对求解算法提出了很大的考验。由表 6 可知,在 16 个 RC 类问题中:ACO-Tabu、M-MOEA/D、HMOMA 和 CCMO 算法均未获得最优解;只有 MO-MTEA 算法获得了 3 个最优解。MO-MTEA 的最优解获取率相较于对比算法提高了 18.8%。这一结果表明,MO-MTEA 算法在求解 RC 类算例上相较于其他算法具有一定的优势。

图 10 是 MO-MTEA 算法求解 Solomon 数据集中 C 类部分算例的最优路径图。其中,图 10 (a)和图 10 (b)分别对应 C101 和 C201 算例的最优路径图,不同车辆的配送路径采用不同颜色进行绘制。由 C101 算例路径图可知,MO-MTEA 算法通过 10 辆车完成全部客户点的准时配送;由 C201 算例路径图可知,MO-MTEA 仅使用 3 辆车即可满足所有顾客的配送要求。由于两

组算例规划的路径均未出现交叉现象,这不仅说明了 MO-MTEA 算法在空间规划上的合理性,而且直观反映了 MO-MTEA 算法获得的高质量解。

图 11 展示了 5 种算法在求解 R101 和 R112 算例的 HV 指标的收敛曲线对比结果。图 11(a)显示,MO-MTEA 算法在迭代早期和后期均保持优势,且求解效果显著优于其他 4 种算法。图 11(b)显示,本文所提算法的收敛性虽然在迭代中期不如 ACO-Tabu 和 CCMO 算法,但其在迭代前期和后期仍优于所有对比算法,这一结果说明,MO-MTEA 算法的整体收敛性更优。

3.4 算法优势分析

从上述实验的统计结果可知,MO-MTEA 算法的最优解获取率在三类算例上均优于其他对比算法。具体分析如下。

(1) 优于 ACO-Tabu 和 HMOMA 算法。启发式算法通常对复杂的原始问题直接进行搜索求解,而原始问题往往包含多个约束和冲突的目标,直接求解很容易陷入局部最优解甚至无可行解的情况。MO-MTEA 算法则将复杂的原任务拆分成多个简单且相似的子任务,分别对子任务进行求解以达到简化问题的目的,故 MO-MTEA 优于 ACO-Tabu 和 HMOMA 算法。

(2) 优于 M-MOEA/D 和 CCMO 算法。M-MOEA/D 算法的策略是将一个多目标问题分解成多个单目标问题进行求解,这虽然达到了简化问题的目的,但这种硬性分割未能充分考量目标与约束之间,以及多个目标本身之间的复杂关系,导致求解效果不佳。

表5 各算法在R类型数据集上求解结果
Table 5 Results of the algorithms on R-type dataset

测试问题	BKS(已知最优解)		ACO-Tabu		M-MOEA/D		HMOMA		CCMO		MO-MTEA	
	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2
R101	19	1 650.8	19	1 655.0	20	1 644.7	20	1 651.7	20	1 652.4	19	1 652.4
R102	17	1 486.1	18	1 491.1	18	1 473.7	18	1 480.6	18	1 482.7	17	1 486.1
R103	13	1 292.7	14	1 243.2	14	1 213.6	14	1 225.8	14	1 224.7	13	1 292.7
R104	9	1 007.3	10	982.0	11	991.9	11	1 002.5	11	999.8	10	1 022.3
R105	14	1 377.1	16	1 380.4	15	1 366.6	15	1 377.4	15	1 379.2	14	1 452.6
R106	12	1 252.0	13	1 265.3	13	1 249.2	13	1 256.8	13	1 254.6	12	1 252.0
R107	10	1 104.7	11	1 100.2	11	1 086.2	12	1 099.7	12	1 095.2	11	1 092.4
R108	9	960.9	9	958.6	10	965.5	10	966.7	10	956.2	9	972.7
R109	11	1 194.7	12	1 101.9	13	1 155.4	13	1 159.2	13	1 165.3	13	1 159.2
R110	10	1 118.8	12	1 119.5	12	1 106.0	12	1 088.3	12	1 085.2	12	1 106.0
R111	10	1 096.7	12	1 091.1	11	1 073.8	12	1 066.7	12	1 064.8	10	1 096.7
R112	9	982.1	10	974.7	10	981.4	11	988.6	11	982.9	9	985.6
R201	4	1 252.4	9	1 185.5	9	1 186.1	9	1 187.2	7	1 192.4	4	1 252.4
R202	3	1 191.7	8	1 072.9	8	1 073.6	8	1 074.2	6	1 070.2	6	1 053.1
R203	3	939.5	7	900.1	7	901.8	7	902.5	5	899.8	3	939.5
R204	2	825.5	5	766.0	5	767.7	5	768.4	3	768.9	6	755.6
R205	3	994.4	7	998.5	7	999.2	7	999.9	5	999.8	5	962.9
R206	3	906.1	5	918.6	5	919.3	5	920.0	4	918.5	6	903.0
R207	2	890.6	5	860.4	5	861.1	5	861.8	3	858.2	2	890.6
R208	2	726.8	6	735.8	6	736.5	6	737.2	4	731.6	4	726.4
R209	3	909.2	6	898.2	6	898.9	6	899.6	4	894.0	5	905.1
R210	3	939.3	7	962.1	7	962.8	7	963.5	5	957.9	6	940.3
R211	2	885.7	5	796.6	5	797.3	5	798.0	3	799.3	5	788.2

表6 各算法在RC类型数据集上求解结果
Table 6 Results of the algorithms on RC data sets

测试问题	BKS(已知最优解)		ACO-Tabu		M-MOEA/D		HMOMA		CCMO		MO-MTEA	
	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2
RC101	14	1 697.0	18	1 671.9	19	1 680.3	20	1 683.8	17	1 672.3	16	1 670.0
RC102	12	1 554.8	16	1 511.4	17	1 516.9	18	1 520.7	15	1 514.5	14	1 495.1
RC103	11	1 261.7	13	1 353.2	14	1 357.7	15	1 360.6	12	1 349.6	13	1 363.1
RC104	10	1 135.5	11	1 160.2	12	1 165.0	13	1 167.8	10	1 156.6	10	1 135.5
RC105	13	1 629.4	18	1 573.1	19	1 578.9	20	1 582.8	17	1 577.4	16	1 617.4
RC106	11	1 424.7	15	1 420.0	16	1 425.7	17	1 429.5	14	1 422.3	13	1 438.8
RC107	11	1 230.5	13	1 232.5	14	1 238.2	15	1 242.0	12	1 232.0	11	1 230.5
RC108	10	1 139.8	12	1 150.1	13	1 154.9	14	1 157.8	11	1 145.6	12	1 328.5
RC201	4	1 406.9	9	1 306.4	10	1 312.2	11	1 316.1	8	1 102.6	7	1 292.8
RC202	3	1 365.7	9	1 165.9	10	1 171.7	11	1 175.6	6	1 188.2	5	1 116.5
RC203	3	1 049.6	6	975.6	7	981.4	8	985.3	5	977.3	3	1 049.6
RC204	3	798.5	5	842.6	6	848.4	7	852.3	4	788.5	4	808.7
RC205	4	1 297.7	8	1 225.1	9	1 230.9	10	1 234.8	5	1 226.5	5	1 180.4
RC206	3	1 146.3	6	1 134.5	7	1 140.3	8	1 144.2	5	1 132.5	5	1 112.6
RC207	3	1 061.1	6	1 015.4	7	1 021.2	8	1 025.1	5	1 013.5	5	1 003.0
RC208	3	828.1	5	837.2	6	843.0	7	846.9	4	831.2	5	833.0

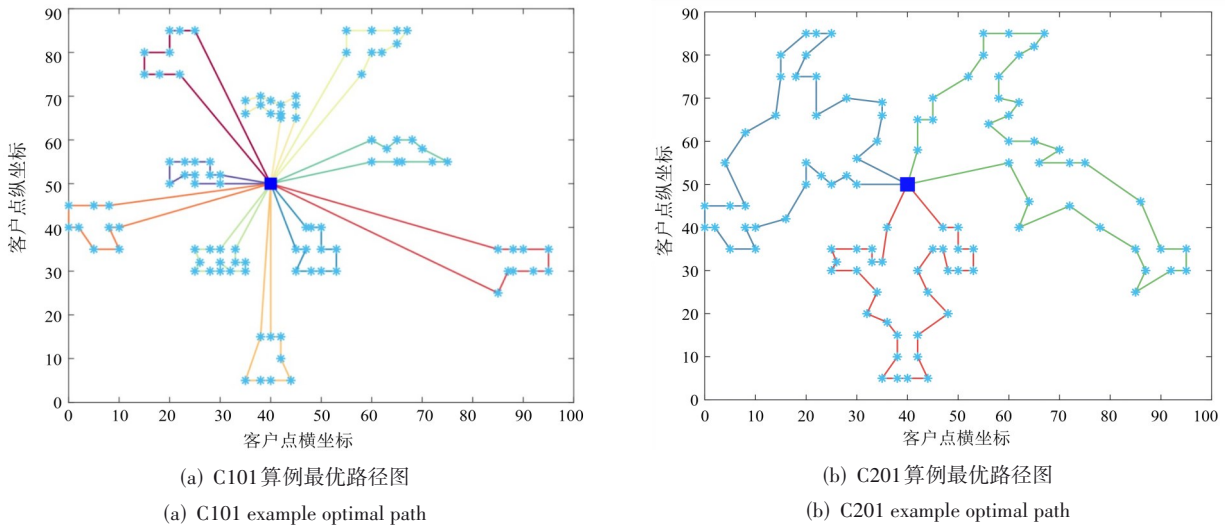


图 10 C类部分算例最优路径图

Figure 10 Optimal path diagram of some examples in category C




图 11 算法收敛性对比

Figure 11 Comparison of algorithm convergence

CCMO算法采取的是双种群协同进化,两个种群分别致力于满足约束和优化目标,这虽然实现了种群间的资源共享,但两个种群仅仅将约束和目标进行分割,而未考虑多个目标间的内在关联,故其难以获得实际最优解。相比之下,MO-MTEA算法基于进化多任务技术,先将原问题通过降维拆分为若干相似子任务,再通过知识迁移机制在任务间共享信息。该方法不仅有效降低了问题复杂度,同时还充分挖掘并利用了任务间的关联性,因此能够取得更优的求解效果。

3.5 算法消融实验

为了进一步验证各个策略对MO-MTEA算法的贡献程度,本文采用三种方法进行消融实验,分别是:

将混合初始化策略替换为随机初始化的MO-MTEA¹、移除进化多任务方法改为直接对原问题进行搜索的MO-MTEA²,以及将存档种群替换为仅保存最好的 N_p 个解的MO-MTEA³。最后,将MO-MTEA¹、MO-MTEA²、MO-MTEA³和MO-MTEA算法加入算法消融对比实验。

表7是MO-MTEA¹、MO-MTEA²、MO-MTEA³和MO-MTEA算法在C、R和RC类数据集上的统计结果,由表可知:

(1) MO-MTEA¹在C类测试问题(C105、C203和C207)中表现不佳,但在R类和RC类测试问题中几乎不受影响,这是因为采用随机策略生成初始种群较为分散,而C类算例的顾客呈聚集分布型,导致种群

搜索难度增加,故求解效果较差。

(2) MO-MTEA²在 C、R 和 RC 类测试问题上均找不到最优解决方案,可见 EMT 技术对 MO-MTEA 算法起着决定性的作用,采用进化多任务方法求解 MOVRP 问题非常有效。

(3) MO-MTEA³与 MO-MTEA 算法相比在三类测

试问题(C201、C208、R102、R201 和 RC107)中均表现不佳,可见缺乏存档种群的帮助,MO-MTEA³容易陷入局部最优解。

综合对比,随机策略、EMT 技术和存档种群策略对 MO-MTEA 算法获取最优解的贡献程度的排列顺序为:EMT 技术>存档种群策略>随机策略。

表 7 各算法在 C、R 和 RC 类数据集上求解结果

Table 7 The results of the algorithms on the C, R, and RC datasets

测试问题	MO-MTEA ¹		MO-MTEA ²		MO-MTEA ³		MO-MTEA	
	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2
C101	10	828.9	13	837.3	10	828.9	10	828.9
C102	10	828.9	13	857.4	10	828.9	10	828.9
C103	10	828.0	13	858.8	10	828.0	10	828.0
C104	10	847.4	12	855.0	10	847.3	10	845.6
C105	10	838.9	12	833.7	10	828.9	10	828.9
C106	10	828.9	13	832.1	10	828.9	10	828.9
C107	10	828.9	12	837.9	10	828.9	10	828.9
C201	3	591.6	5	599.9	6	599.7	3	591.6
C202	3	591.5	6	600.1	3	591.5	3	591.5
C203	4	592.2	6	597.8	3	591.2	3	591.2
C204	5	633.1	5	607.3	4	631.2	4	619.7
C205	3	588.9	5	595.2	3	588.9	3	588.9
C206	3	588.5	6	596.1	3	588.5	3	588.5
C207	4	590.3	5	595.1	3	588.3	3	588.3
C208	3	588.3	6	591.7	6	591.3	3	588.3
R101	19	1 652.4	20	1 655.7	20	1 684.4	19	1 652.4
R102	17	1 486.1	18	1 473.7	18	1 536.3	17	1 486.1
R103	13	1 292.7	14	1 213.6	13	1 292.7	13	1 292.7
R104	10	1 022.3	11	991.9	11	1 027.2	10	1 022.3
R105	14	1 452.6	15	1 378.6	14	1 454.8	14	1 452.6
R106	12	1 252.0	13	1 255.7	12	1 252.0	12	1 252.0
R107	11	1 092.4	11	1 086.2	11	1 098.6	11	1 092.4
R108	9	972.7	10	977.5	9	983.1	9	972.7
R109	13	1 159.2	13	1 165.4	13	1 274.2	13	1 159.2
R110	12	1 136.7	12	1 136.0	12	1 123.0	12	1 106.0
R111	10	1 096.7	11	1 073.8	10	1 096.7	10	1 096.7
R112	9	988.3	10	988.4	9	984.2	9	985.6
R201	4	1 252.4	9	1 286.1	6	1 256.8	4	1 252.4
R202	7	1 054.2	8	1 173.6	6	1 073.6	6	1 053.1
R203	3	939.5	6	1 034.8	3	939.5	3	939.5
R204	6	758.6	6	767.7	6	755.1	6	755.6
R205	6	962.9	7	999.2	5	967.3	5	962.9
R206	6	903.6	5	919.3	6	903.8	6	903.0
R207	2	890.6	5	861.1	2	890.6	2	890.6
R208	4	734.9	6	732.5	4	756.4	4	726.4
R209	5	905.1	6	955.9	5	975.3	5	905.1
R210	6	955.1	7	962.3	6	955.0	6	940.3
R211	5	788.2	5	792.1	5	783.2	5	788.2

续表

测试问题	MO-MTEA ¹		MO-MTEA ²		MO-MTEA ³		MO-MTEA	
	f_1	f_2	f_1	f_2	f_1	f_2	f_1	f_2
RC101	16	1 673.2	18	1 673.9	16	1 683.3	16	1 670.0
RC102	15	1 495.3	16	1 511.4	14	1 522.3	14	1 495.1
RC103	14	1 369.7	13	1 383.2	13	1 368.7	13	1 363.1
RC104	10	1 135.5	11	1 160.2	10	1 135.5	10	1 135.5
RC105	16	1 637.4	18	1 673.1	16	1 617.4	16	1 617.4
RC106	13	1 457.8	15	1 480.3	13	1 438.8	13	1 438.8
RC107	11	1 230.5	13	1 232.5	12	1 277.1	11	1 230.5
RC108	12	1 328.5	12	1 450.1	12	1 348.7	12	1 328.5
RC201	7	1 292.8	9	1 306.4	7	1 292.8	7	1 292.8
RC202	5	1 116.5	9	1 165.9	5	1 116.5	5	1 116.5
RC203	3	1 049.6	7	1 057.6	3	1 049.6	3	1 049.6
RC204	4	808.7	5	842.6	4	808.7	4	808.7
RC205	5	1 180.4	7	1 225.1	5	1 197.3	5	1 180.4
RC206	5	1 112.6	6	1 134.5	5	1 141.6	5	1 112.6
RC207	5	1 003.0	6	1 015.4	5	1 003.0	5	1 003.0
RC208	5	833.0	6	837.2	5	833.0	5	833.0

4 结论

本文提出一种面向多目标车辆路径问题的进化多任务算法(MO-MTEA)。MO-MTEA创新点主要包括以下3个方面。

(1)针对进化算法采用随机初始化,导致初始种群对解空间覆盖不均匀的现象,引入佳点集初始化策略,提出了一种结合佳点集和随机初始化的混合策略来初始化种群,有效地生成分布更为均匀的初始个体,降低初始个体的重复率。

(2)基于进化多任务技术将原问题通过降维的方式拆分成若干个简单且相似的子任务,用于简化问题的复杂度;改进交叉突变和交叉操作,将搜索到的信息在子任务之间通过基因的形式进行传递,以辅助原任务的求解。

(3)引入存档种群将种群中的精英个体独立保存到存档种群中,以防止种群陷入局部最优。

为验证本文所提出算法的性能,将MO-MTEA算法在经典的Solomon测试数据集上与ACO-Tabu、M-MOEA/D、HMOMA和CCMO算法进行对比实验。实验结果表明,MO-MTEA性能显著优于其他对比算法,能够较好地求解MOVPR。

参考文献

[1] Pan Lili, Hu Bing, Sun Zhe, et al. A review of the evolutionary algorithm based VRP problem[C]//Proceedings of 2023 42nd Chinese Control Conference. Piscataway: IEEE, 2023: 1939-1944.

[2] 张歆悦, 靳鹏, 胡笑旋, 等. 时间依赖型多配送中心带时间窗的开放式车辆路径问题研究[J]. 中国管理科学, 2024, 32(1): 146-157.

Zhang Xinyue, Jin Peng, Hu Xiaoxuan, et al. Research on the time-dependent multi-depot open vehicle routing problem with time windows[J]. Chinese Journal of Management Science, 2024, 32(1): 146-157. (in Chinese)

[3] 蒋华伟, 郭陶, 杨震. 车辆路径问题研究进展[J]. 电子学报, 2022, 50(2): 480-492.

Jiang Huawei, Guo Tao, Yang Zhen. Research progress of vehicle routing problem[J]. Acta Electronica Sinica, 2022, 50(2): 480-492. (in Chinese)

[4] 刘东升, 王俊生. 非结构化环境中基于拓扑约束的地面无人驾驶路径规划算法[J]. 控制与决策, 2022, 37(12): 3103-3114.

Liu Dongsheng, Wang Junsheng. Path planning algorithm for ground unmanned vehicles based on topological constraints in unstructured environments[J]. Control and Decision, 2022, 37(12): 3103-3114. (in Chinese)

[5] Ren Teng, Xu Hongbo, Jin Kangning, et al. Optimisation of takeaway delivery routes considering the mutual satisfactions of merchants and customers[J]. Computers & Industrial Engineering, 2021, 162: 107728.

[6] Dabia S, Ropke S, van Woensel T, et al. Branch and price for the time-dependent vehicle routing problem with time windows[J]. Transportation Science, 2013, 47(3): 380-396.

[7] Azi N, Gendreau M, Potvin J Y. An exact algorithm for a

- single-vehicle routing problem with time windows and multiple routes[J]. *European Journal of Operational Research*, 2007, 178(3): 755-766.
- [8] 沈俊杰, 彭江, 郭坤银, 等. 车联网中基于位置信息映射和相关性评估的进化多任务优化算法[J]. *电子学报*, 2025, 53(5): 1661-1676.
Shen Junjie, Peng Jiang, Guo Kunyin, et al. Location mapping and correlation assessment based evolutionary multi-task optimization algorithm in the Internet of vehicles[J]. *Acta Electronica Sinica*, 2025, 53(5): 1661-1676. (in Chinese)
- [9] 陈凯, 龚毅光. 混合多目标灰狼算法求解多目标 VRPTW 问题[J]. *计算机工程与应用*, 2024, 60(11): 309-318.
Chen Kai, Gong Yiguang. Hybrid multiple-objective grey wolf algorithm solving multi-objective vehicle routing problem with time windows[J]. *Computer Engineering and Applications*, 2024, 60(11): 309-318. (in Chinese)
- [10] 王旭健, 张峰干, 姚敏立. 基于动态分解和角度惩罚距离的高维多目标进化算法[J]. *电子学报*, 2024, 52(8): 2773-2785.
Wang Xujian, Zhang Fenggan, Yao Minli. Many-objective evolutionary algorithm based on dynamic decomposition and angle penalty distance[J]. *Acta Electronica Sinica*, 2024, 52(8): 2773-2785. (in Chinese)
- [11] Gupta A, Ong Y S, Feng Liang. Multifactorial evolution: Toward evolutionary multitasking[J]. *IEEE Transactions on Evolutionary Computation*, 2016, 20(3): 343-357.
- [12] Feng Liang, Zhou Lei, Gupta A, et al. Solving generalized vehicle routing problem with occasional drivers via evolutionary multitasking[J]. *IEEE Transactions on Cybernetics*, 2021, 51(6): 3171-3184.
- [13] Wang Jiahai, Ren Wenbin, Zhang Zizhen, et al. A hybrid multiobjective memetic algorithm for multiobjective periodic vehicle routing problem with time windows[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, 50(11): 4732-4745.
- [14] Feng Liang, Huang Yuxiao, Zhou Lei, et al. Explicit evolutionary multitasking for combinatorial optimization: A case study on capacitated vehicle routing problem[J]. *IEEE Transactions on Cybernetics*, 2021, 51(6): 3143-3156.
- [15] Ding Xuefeng, Liu Tingting. A history information-guided evolutionary algorithm for the multiobjective vehicle routing problem with time windows[J]. *IEEE Sensors Journal*, 2024, 24(21): 35787-35800.
- [16] Qiao Kangjia, Liang Jing, Yu Kunjie, et al. A self-adaptive evolutionary multi-task based constrained multi-objective evolutionary algorithm[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, 7(4): 1098-1112.
- [17] 李坚强, 蔡俊创, 孙涛, 等. 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*, 2024, 50(3): 544-559.
Li Jianqiang, Cai Junchuang, Sun Tao, et al. Multitask-based assisted evolutionary algorithm for vehicle routing problems in complex logistics distribution scenarios[J]. *Acta Automatica Sinica*, 2024, 50(3): 544-559. (in Chinese)
- [18] 郭庆辉, 李媛, 杨东升. 一种改进麻雀搜索算法的收敛性分析及应用[J]. *控制与决策*, 2024, 39(8): 2502-2510.
Guo Qinghui, Li Yuan, Yang Dongsheng. Convergence analysis and application of an improved sparrow search algorithm[J]. *Control and Decision*, 2024, 39(8): 2502-2510. (in Chinese)
- [19] Mirabi M. A novel hybrid genetic algorithm for the multi-depot periodic vehicle routing problem[J]. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 2015, 29(1): 45-54.
- [20] Thang T B, Long N B, Hoang N V, et al. Adaptive knowledge transfer in multifactorial evolutionary algorithm for the clustered minimum routing cost problem[J]. *Applied Soft Computing*, 2021, 105: 107253.
- [21] Zhou Zifeng, Ma Xiaoliang, Liang Zhengping, et al. Multi-objective multi-factorial memetic algorithm based on bone route and large neighborhood local search for VRPTW[C]//*Proceedings of 2020 IEEE Congress on Evolutionary Computation*. Piscataway: IEEE, 2020: 9185528.
- [22] Jiang Dengying, Jiang Wenxia, Huang Zhangcan. A hybrid algorithm for vehicle routing problem with time windows[C]//*Proceedings of the 3rd International Symposium on Advances in Computation and Intelligence*. Heidelberg: Springer, 2008: 198-205.
- [23] Qi Yutao, Hou Zhanting, Li He, et al. A decomposition based memetic algorithm for multi-objective vehicle routing problem with time windows[J]. *Computers & Operations Research*, 2015, 62: 61-77.
- [24] Tian Ye, Zhang Tao, Xiao Jianhua, et al. A coevolutionary framework for constrained multiobjective optimization problems[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(1): 102-116.

作者简介



鲁宇明 女,1969年4月出生于江西省南昌市。现为南昌航空大学航空制造与机械工程学院教授、硕士生导师。主要研究方向为工程优化与智能算法。

E-mail: luyuming69@163.com



曹龙昊 男,2000年4月出生于江西省南昌市。硕士研究生,现为珠海京东方晶芯科技有限公司结构开发研究员。主要研究方向为机械设计、工程优化与智能算法。

E-mail: 31858112@qq.com



郭鑫 男,1983年12月出生于河南省社旗县。现为矿冶科技集团有限公司北京安期生技术有限公司总经理。主要研究方向为矿山智能化装备。

E-mail: guoxin@bgrimm.com



艾亿豪 男,2002年12月出生于江西省南昌市。硕士研究生。主要研究方向为优化算法。

E-mail: 2314927566@qq.com



陈昊 男,1982年9月出生于山东省平度市。现为南昌航空大学信息工程学院教授、博士生导师。主要研究方向为智能进化算法及应用,模式识别与人工智能。中国电子学会会员编号:E190014643M。

E-mail: chenhaoshl@163.com



揭丽琳 女,1987年4月出生于江西省抚州市。现为南昌航空大学仪器科学与光电工程学院副教授、硕士生导师。主要研究方向为情感脑机接口、智能计算理论及应用。

E-mail: jielilin@nchu.edu.cn