

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

沈俊杰¹, 彭江^{1,2}, 郭坤银¹, 刘凯^{1*}

(1. 重庆大学计算机学院, 重庆 400044; 2. 重庆赛力斯凤凰智创有限公司, 重庆 400000)

摘要: 随着车联网(Internet of Vehicles, IoV)和智能交通系统的兴起, 计算成本的增加和问题规模的扩大使得实时应用的实现变得极具挑战性, 同时也为车载边缘计算(Vehicular Edge Computing, VEC)带来了大量亟待并行求解的组合优化问题. 这些复杂的实际问题往往具有非凸性、不可微性, 甚至存在黑盒目标与约束条件, 可能会超出传统数学方法的解决范围. 进化多任务优化(Evolutionary Multi-Task Optimization, EMTO)作为一种新兴的多任务优化范式, 通过充分利用任务间的潜在相关性, 能够有效地实现多个独立优化任务的并行求解. 本文设计了一种IoV显式EMTO框架, 结合IoV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IoV EMTO算法. 针对IoV环境下的多任务优化问题, 本文对车-路数据路由(Data Routing, DR)、车-路服务迁移(Service Migration, SM)、车-车消息传输(Message Transmission, MT)和车-车任务卸载(Task Offloading, TO)四个问题进行联合优化, 目标是在限定时间内最大化各个任务的交付率. 进一步地, 为了在任务相关性未知的情况下提升相关任务间的知识迁移效率, 本文在算法中设计并引入了基于任务相关性评估的迁移机制. 具体而言, 通过计算链路间最长公共子序列来计算链路的相似度, 针对不同的相关性分布情况设计了三种迁移策略, 以确保算法在不同场景下的知识迁移能力. 最后, 本文通过实验验证和性能评估, 验证了所提框架和算法的有效性, 与其他的EMTO算法相比, 本文所提算法在各优化问题上的收敛速度更快, 种群间知识迁移后的求解效果更好, 展现出良好的性能.

关键词: 车载边缘计算(VEC); 进化算法; 多任务优化; 显式知识转移; 任务相关性评估

基金项目: 国家自然科学基金(No.62472055, No.62172064)

中图分类号: TP393 **文献标识码:** A **文章编号:** 0372-2112(2025)05-1661-16

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20250053

Location Mapping and Correlation Assessment Based Evolutionary Multi-Task Optimization Algorithm in the Internet of Vehicles

SHEN Jun-jie¹, PENG Jiang^{1,2}, GUO Kun-yin¹, LIU Kai^{1*}

(1. College of Computer Science, Chongqing University, Chongqing 400044, China;

2. Chongqing Selis Phoenix Intelligent Innovation Technology Co., Ltd., Chongqing 400000, China)

Abstract: With the rise of the internet of vehicles (IoV) and intelligent transportation systems, the increasing computational costs and problem scale have made the implementation of real-time applications extremely challenging, while also bringing a large number of combinatorial optimization problems that are in urgent need of parallel solving to vehicular edge computing (VEC). Often, these complex practical problems may possess non-convex, non-differentiable or even black-box objectives and constraints, which may go beyond the scope that traditional mathematical methods can handle. In this context, evolutionary multi-task optimization (EMTO), as a new paradigm in the field of multi-task optimization, effectively solves multiple independent optimization tasks in parallel by fully exploiting the potential correlations between tasks. An explicit EMTO framework tailored for IoV is designed. By integrating the unique characteristics of IoV tasks and deeply exploring the implicit correlations among them, a novel EMTO approach for IoV is proposed, which establishes mappings based on vehicle location information. This paper focuses on the multi-task optimization problem in the context of IoV, jointly optimizing four aspects: vehicle-to-road data routing (DR), vehicle-to-road service migration (SM), vehicle-to-vehi-

cle message transmission (MT), and vehicle-to-vehicle task offloading (TO), with the objective of maximizing the delivery rate of each task within a specified time frame. Furthermore, to enhance the efficiency of knowledge transfer among related tasks when their correlations are unknown, a migration mechanism grounded in task correlation assessment is introduced. Specifically, the longest common subsequence between links is utilized to calculate their similarity, and three migration strategies are devised according to different correlation distributions, ensuring the algorithm's capability of knowledge transfer across various scenarios. Finally, through experimental validation and performance evaluation, the effectiveness of the proposed framework and algorithm is demonstrated. Compared with other EMTO algorithms, the algorithm presented in this paper exhibits faster convergence speeds for various optimization problems and yields better solutions after knowledge transfer among populations, showcasing impressive results.

Key words: vehicular edge computing (VEC); evolutionary algorithm; multi-task optimization; explicit knowledge transfer; task correlation assessment

Foundation Item(s): National Natural Science Foundation of China (No.62472055, No.62172064)

1 引言

随着无线通信技术的飞速发展、汽车工业的技术革新、人工智能算法的突破以及车路协同体系的日益完善,车联网(Internet of Vehicles, IoV)边缘智能作为新兴物联网产业的代表,正展现出蓬勃的发展态势^[1]. 然而,车辆终端在计算和存储能力上的局限性与日益增长的应用需求之间的矛盾日益凸显. 这使得现有车辆终端的计算和存储能力面临严峻考验,车辆信息收集、流量预测^[2]、资源调度^[3]、推理加速^[4]等具体任务的实现面临重重困难. 为应对计算需求在网络边缘产生的问题,车载边缘计算(Vehicular Edge Computing, VEC)应运而生. 它将计算和存储资源下沉至车辆用户附近的网络边缘端,如路侧基站、路边单元、边缘服务器等固定基础设施,从而为车辆用户提供低延迟、高可靠性的计算服务,以支持车辆的实时需求,提升服务质量^[5,6].

在VEC体系中,一系列复杂的优化问题亟待解决. 例如,车辆任务卸载(Task Offloading, TO)到边缘设备的负载问题^[7]可视为带约束的最小损失函数优化问题,车间和车辆到路侧的通信路由问题也可视为带约束的最大通信完成率优化问题和最大传输质量优化问题等. 这些问题不仅涉及到计算和通信资源的有效分配^[8],还需考虑实时性和服务质量的要求.

进化多任务优化(Evolutionary Multi-task Optimization, ETMO)作为一种新兴的优化范式,为多个不同优化任务的求解提供了新的思路^[9]. 其对待复杂问题的数学性质不做严格假设,有利于求解各类相关优化问题,可以充分发挥进化算法的并行求解能力,并利用不同求解种群在求解过程中的迁移实现知识的提取与转移. 在IoV环境下,EMTO可以充分利用任务间的潜在关联进行知识转移,在多个搜索空间同时求解不同任务,从而更为有效地解决组合优化问题. 除此之外,进化算法的高效性和鲁棒性也使其在低时延要求的汽车

环境中具有广泛的应用前景. 然而,目前针对VEC场景应用ETMO的研究仍处于起步阶段. 已有的一些尝试并未充分结合VEC场景的特点进行特殊处理,导致知识映射过程中产生了额外的预处理开销. 此外,在VEC场景下,不同求解问题之间并不一定具有极强的相关性,来自其他问题的求解知识对于同一问题的转移效益也可能存在差异.

针对以上分析,本文从全局视角出发,对VEC场景下的多个优化问题进行同步求解,深入挖掘同一场景内优化问题间的相关性,实现问题的协同求解. 进一步地,针对VEC场景的特点提出可解释性强的快速知识映射策略和高效的迁移控制策略. 本文的主要贡献包括3个方面:

(1)针对IoV环境下可能存在的多任务优化问题,本文设计了一种IoV显式ETMO框架. 用于对数据路由(Data Routing, DR)、服务迁移(Service Migration, SM)、TO等问题进行联合优化,提高任务在限定时间内的交付率.

(2)分析IoV环境下任务间隐含的关联性,提出了一种基于车辆位置映射和相关性评估的IoV ETMO方法,加快了优化问题的收敛速度.

(3)在算法中设计并引入了一种基于任务相关性评估的迁移机制,针对不同的相关性分布情况给出三种迁移策略,即混合迁移策略. 在知识迁移时,使用基于临时种群的两阶段迁移机制,确保算法在不同场景下的知识迁移能力,提高优化任务的求解效果.

2 相关工作

2.1 IoV环境下的多目标优化问题

多目标优化(Multi-Objective Optimization, MOO)是一类优化问题,涉及同时优化两个或多个目标函数. 在实际问题中,许多工程问题和科学问题都具有多个相互冲突的目标,这些目标通常无法同时达到最佳值. 因此,MOO方法需要在多个目标之间找到一种平衡.

MOO 方法能够处理一个任务下的多个目标,充分考虑它们之间可能存在的潜在冲突.该方法并不追求于单一目标下的最优解,而是通过生成一种均衡解,即 Pareto 最优集合,来满足所需目标并实现不同目标之间的平衡.

在 IoV 环境下也存在多个互相冲突的目标,例如车辆路径规划问题中的交通吞吐率和总体能耗这两个目标.因此在 IoV 领域,MOO 方法得到了广泛的应用.文献[10]针对 IoV 中的动态计算卸载问题,提出了一种融合深度强化学习的边缘计算策略,以优化边缘服务器资源的利用和减少系统延迟作为目标进行优化.文献[11]提出一种基于数字孪生的集成框架,通过设计数字孪生架构、个性化路线规划算法、全局交通调度算法及联合优化算法,解决了现有交通方案无法满足对车辆个性化路线规划和全局交通调度的 MOO 问题.文献[12]针对具有多种通信技术和多种任务类型的异构 IoV 边缘计算环境,提出了一种有效的资源分配策略,目标在最小化系统效用的同时满足超可靠低延迟的通信要求.文献[13]提出了一种关于消除冗余任务的 TO 算法,解决了移动边缘计算中的车载任务冗余问题,有效提高了任务完成率,同时增加了车辆与基站的收益.文献[14]考虑了 IoV 云边协同计算场景下的卸载决策和协同资源分配问题,对缓存任务进行分类并引入相关策略,考虑卸载方案的多个目标,提出了一种基于 MOO 免疫算法的卸载决策方案,结合免疫思想和参考点策略实现对多目标问题的优化.

2.2 ETMO 问题

上述的 MOO 方法针对同一问题下的多目标进行求解,然而考虑到 IoV 场景的复杂性,实际存在大量需要同时求解的不同优化问题.进一步地,考虑到这些异构任务处于同一场景下,对多任务进行联立求解可能取得相比单任务更优的解决方案.不同于以上研究,ETMO 关注如何同时解决多个独立优化任务,通过挖掘任务间的潜在关联,利用一个任务的中间知识来加速其他任务的求解.其不仅针对每个具体任务求最优解,在不需要任务间相关性的先验知识的情况下,还可以通过传递相关任务间知识建立协同搜索作用.具体而言,ETMO 主要分为两种类型:一种基于隐式知识迁移;另一种基于显式知识迁移.这两种方式分别构建了在不同种群间的映射和转移策略.

基于隐式知识迁移的 ETMO 方法,通过构建不同问题下的统一表示解,即不同种群的染色体构成完全相同的方式,来完成知识在不同求解问题下的迁移.文献[15]首先提出了基于隐式迁移的多任务优化算法(Evolutionary Multitasking Algorithm, MFEA),其建立任务的同一表示解,对所有任务进行染色体表达,并修改交叉算

子对跨任务知识迁移进行表示和控制.一些工作^[16]探讨了任务之间的相似性对多任务优化性能的影响,并归纳了最适合求解的问题类型.文献[17]在 MFEA 的基础上进行了优化,将同时求解的问题数量推广到了两个以上,并实现了参数的自动调整以应对多任务下的迁移强度问题,其引入了在统一表示解的基础上对于不同任务的概率分布估计,并根据分布的重叠情况对任务相关性进行评估.文献[18]提出了一种新的基于动态分解的进化算法,以提高多目标算法的适应性和泛化能力.文献[19]研究了多因素进化在解决约束优化问题中的优点,对于所求优化问题进行拆分,并引入了差分进化方法加速求解过程,其还考虑了差分方法对种群多样性的影响,并给出具体维护策略以应对复杂情况.文献[20]集成了萤火虫算法的强大开发能力,在面对低相似性任务时增强每个任务的自我进化,同时通过提供更高质量的解来改善任务间的知识转移,尤其在输入任务数量较大时取得较好效果.文献[21]通过将原始问题构建新的简化问题,在简化空间而不是原始问题空间中执行优化,使得性能在一定程度上得到了改善,其通过基于分解的方法将变量分组,构造原始问题的多个简单变量,并通过动态任务替换更新搜索空间,进一步地利用简化问题辅助原始任务进行优化.文献[22]设计了一种基于自动编码器的问题转换的大规模多目标进化优化算法.利用自动编码器确定变量的相对重要性,实现无函数评估的变量分组,并根据分组构建自动编码器将原始大规模搜索空间转换为较小的表示空间,在该空间中进行后代解的生成.

基于显式知识迁移的进化多任务方法允许每个任务生成自己独有的种群,且不同种群可以使用完全不同的染色体组成,并结合不同的搜索机制来解决各类优化任务,具有较强的灵活性.进一步地,针对异构的染色体组成提出显式的迁移方法来实现个体在不同种群间的转化和知识的传递.文献[23]使用自动编码器将一个问题的解当作另一个问题的损坏版本,通过去噪过程获得相应任务的映射.文献[24]通过聚类和距离学习不同解的稀疏映射来进行知识转移,引入流形对齐方式建立不同任务在公共子空间的投影,进而在不需要先验知识输入的前提下建立多种群间的映射关系.文献[25]提出了一种新的显式知识转移策略,此策略首先将不同任务的解决方案置于对齐子空间中表示,然后通过学习子空间内任务间的映射来实现知识转移,旨在根据任务间的相关性自动调控知识转移过程.文献[26]设计了一种分布式知识转移的进化多任务多模态优化方法,该方法基于进化路径的相似度测度来衡量种群间的相似度,并用子种群交叉匹配策略

对于种群进行知识转移. 此外, 该方法还引入了知识转移概率的自调整策略, 以平衡知识转移与自我进化之间的关系. 文献[27]提出了一种基于自适应求解器选择的多任务进化框架, 其中框架明确为每个任务分配多个求解器子种群, 并自适应地为每个任务选择最合适的求解器, 利用任务间的隐含相似性实现知识转移. 文献[28]开发了一种自适应任务选择机制, 借助最大均值差异合理选择源, 使用多臂老虎机模型控制任务间知识转移的强度, 利用受限玻尔兹曼机提取任务间的潜在特征以减少它们之间的差异.

同时, ETMO方法可以很好地用于解决各种实际问题. 文献[29]提出了一种进化多任务卷积神经网络搜索框架, 在多个搜索过程中实现一种知识共享机制, 以优化卷积神经网络的搜索问题. 文献[30]提出了一种基于图形处理单元(Graphics Processing Unit, GPU)的多任务进化框架, 其中包括多流多线程机制、多块同步进化机制和多岛流水线并发机制. 通过实验证明了框架在解决高维问题的有效性, 减少搜索时间. 文献[31]提出了一种基于多任务的进化算法来解决自动驾驶中的车辆路径问题. 通过生成多个辅助任务来辅助优化过程, 并用进化多任务方法生成后代解, 实现有价值的路径信息在任务间的转移, 促进进化搜索. 文献[32]针对多目标机器人路径规划问题展开研究, 旨在寻找在不确定路径危险情况下能实现旅行时间与安全性最佳平衡的解决方案. 文献[33]详细介绍了EMT(Evolutionary MultiTasking)的六类应用领域, 展示了MFEA在无人机路径规划、复杂工艺设计等各个领域的扩展应用, 并且在这些领域都取得了优秀的成果.

3 问题定义

3.1 IoV 多任务优化问题

本文定义了一个IoV环境下的多任务优化问题, 该问题能够应对较为普遍的优化场景, 即存在两个以上的优化任务, 且任务间的相关性未知. 如图1所示, 构建了一个IoV环境下的多任务优化系统架构. 在路侧设置了多个如路侧单元(Road Side Unit, RSU)的边缘节点, 这些节点不仅提供了稳定可靠的通信和计算服务, 还在带宽、通信覆盖范围和计算能力上表现出异构性, 能够高效支撑资源有限的车辆运行各种应用服务. 所有车辆均配置了蜂窝网络和专用短程通信(Dedicated Short-Range Communications, DSRC)接口, 实现车-路通信(Vehicle-to-Infrastructure, V2I), 同时确保一定范围内的车-车通信(Vehicle-to-Vehicle, V2V). 车辆按预设周期广播其数据信息, 这些信息经边缘节点处理后, 被主干网络采集并上传至云. 其中, 所涉及的全局信息涵盖车辆的任務需求以及车辆实时状态信息, 例如位置、行




图1 系统架构

驶方向和可用的通信资源等, 云的主干调度器依据这些信息开展任务优化工作.

IoV任务展现出高度的多样性与复杂性, 广泛涵盖车辆信息采集、流量预估、资源调配、应急广播、安全机制及娱乐服务等多个维度. 本架构针对IoV中的车-路DR, 车-路SM, 车-车消息传输(Message Transmission, MT)和车-车TO四类核心任务实施联合优化. DR^[34]、SM^[35,36]和TO^[37]这些问题精准覆盖了IoV环境下优化目标冲突最显著、研究最为集中的场景. 值得重点关注的是, IoV的主流应用的数据流走向或运行步骤, 基本上均可拆解并表示为这四类核心任务的组合.

首先是DR. DR任务包括三个主要组成部分: 请求车辆、目标节点和中继节点. 具体而言, 车辆需要将自身收集的交通状况、道路安全、服务信息等数据上传至边缘节点并汇入主干网络, 考虑到特定应用要求以及车辆移动性, 必须在特定时间限制前完成上传请求的数据项. DR任务的目标是在一定的时间约束内找到一个合理的通信链路, 以将指定的大量数据从请求车辆传输到临近节点.

接下来是SM. 在VEC架构中, 车辆往往将TO到边缘侧处理, 但一些任务无法在短时间内完成, 或任务本身需要较长的维持时间. 由于车辆的高度移动性和边缘节点的覆盖范围有限, 车辆可能会驶出边缘节点的覆盖范围或移动到延迟更高的区域, 需要将其服务从一个边缘节点移交到另一个边缘节点. SM任务的目标是识别适当的迁移边缘节点和服务的传输链路, 使车辆能够在给定的时间约束内获得完成计算和传输的服务结果.

将DR问题和SM问题组合优化问题合称为V2I优化问题, 在此基础上引入车辆之间的V2V问题. 在现有的移动边缘计算架构中, 车辆可能遇到自身无法处理但计算量并不庞大的任务, 车辆可选择将任务交付给附近的高性能车辆进行计算, 而非依赖边缘设备, 从而以更低的时间成本获取服务, 从而产生车间的TO优化问题. TO包括三个主要组成部分: 发起车辆、目标车辆和中继节点. 发起车辆将性能要求高于自身条件的TO

到周边的高性能服务车辆而不是边缘节点,以期在更严格的时延要求下获得结果. 考虑到计算任务的耗时性和车辆移动性,应在特定时间限制前完成计算任务并返回结果. TO 任务的目标是找到一组合理的卸载和结果反馈通信方案,在规定时间内完成尽可能多的任务交付.

此外,这些高性能车辆也需要从周边车辆周期性获取信息,因此产生车间的 MT 优化问题. MT 包括三个主要组成部分:发送车辆、目标车辆和中继节点. 具体而言,发起车辆(通常是可以为附近车辆提供服务的高性能车辆)向目标车辆请求将自身缺乏或无法收集的数据(如激光雷达的探测数据、道路感知信息等)传输给自己,考虑到特定应用要求以及车辆移动性,应当在特定时间限制之前完成传输请求的数据项. MT 任务的目标是找到一组合理的通信链路,以在一定的时间约束内将指定的大量数据从目标车辆传输到请求车辆.

3.2 四类优化任务

接下来对系统架构中涉及的符号以及四类优化任务进行集中说明. 在所提出的架构中,将时间片的集合定义为 $T=\{t_1, t_2, \dots, t_{|T|}\}$. 车辆的集合表示为 $V=\{v_1, v_2, \dots, v_{|V|}\}$, 其中 $|V|$ 表示车辆的总数. 任意车辆 $v \in V$ 的基本属性都可以由一个二元组 (l'_v, δ_v) 来表示, 其中 l'_v 表示车辆 v 在时间片 $t(t \in T)$ 时的位置, δ_v 表示车辆 v 的无线通信范围. 对于任意两个车辆 $v, v' \in V$, 使用 $\tau_{v,v'}$ 表示它们之间的传输速率. 边缘节点的集合表示为 $E=\{e_1, e_2, \dots, e_{|E|}\}$, 其中 $|E|$ 表示边缘节点的总数. 每个边缘节点 $e \in E$ 的基本属性由一个三元组 (l_e, c_e, δ_e) 来描述, 分别表示边缘节点 e 的位置、计算能力和无线通信范围. 为了便于描述,将车辆和边缘节点统称为节点, 任意两个节点 n, n' 之间的传输速率表示为 $\tau_{n,n'}$. 进一步地,采用 $[\text{et}_{n,n'}, \text{lt}_{n,n'}]$ 来表示节点 n 在 n' 的覆盖范围内的停留时间间隔, 其中, $\text{et}_{n,n'}$ 和 $\text{lt}_{n,n'}$ 分别表示进入和离开的时间.

将 DR 任务的集合定义为 $D=\{d_1, d_2, \dots, d_{|D|}\}$. 每个任务可以由一个四元组 $(\sigma_{d_i}, \text{ddl}_{d_i}, v_{d_i}, \text{ob}_{d_i})$ 表示, 其中, σ_{d_i} 表示待传输的数据大小, ddl_{d_i} 表示该任务截止时间, v_{d_i} 表示请求发起任务的车辆编号, ob_{d_i} 表示将要传输数据的目标节点. 而 SM 任务的集合表示为 $S=\{s_1, s_2, \dots, s_{|S|}\}$. 每个任务可以由一个六元组 $(\alpha_{s_i}, u_{s_i}, \sigma_{s_i}, \text{ddl}_{s_i}, v_{s_i}, \text{or}_{s_i})$ 表示, 其中, $\alpha_{s_i}, u_{s_i}, \sigma_{s_i}, \text{ddl}_{s_i}, v_{s_i}, \text{or}_{s_i}$ 分别表示服务所需的计算量、虚拟机大小、返回的结果数据大小、任务截止时间、请求维持服务的车辆索引和上一时间片中维护服务的原始节点. 对于 TO 任务, 其集合表示为 $O=\{o_1, o_2, \dots, o_{|O|}\}$. 每个任务与一个四元组 $(\alpha_o, \sigma_o, \text{ddl}_o, v_o)$

相关联, $\alpha_o, \sigma_o, \text{ddl}_o, v_o$ 分别表示待卸载任务的估计计算量、返回的结果数据大小、任务截止时间、请求维持服务的车辆索引. 定义 MT 任务的集合为 $M=\{m_1, m_2, \dots, m_{|M|}\}$. 每个任务与一个四元组 $(\sigma_{m_i}, \text{ddl}_{m_i}, v_{m_i}, \text{ob}_{m_i})$ 相关联, $\sigma_{m_i}, \text{ddl}_{m_i}, v_{m_i}, \text{ob}_{m_i}$ 分别表示待传输的数据大小、任务截止时间、请求发起任务的车辆、获取数据的目标车辆.

下面具体定义四类优化问题.

(1) DR 优化问题

对于任务 d_i , 请求车辆 v_{d_i} 和目标节点 ob_{d_i} 之间的路由路径为 $U_{d_i}=(v_{i,1}, v_{i,2}, \dots, v_{i,n})$. 为了计算 d_i 的路由时间, 需要考虑两个因素, 即传输时间和等待时间. 对于传输时间, 路由路径上的任意两个中继节点 $v_{i,j}, v_{i,j+1}$ 计算 MT 所需的时间. 给定传输速率 $\tau_{v_{i,j}, v_{i,j+1}}$ 和数据大小 σ_{d_i} , 传输时间可表示为

$$t_{v_{i,j}, v_{i,j+1}}^{\text{trans}} = \frac{\sigma_{d_i} \times \theta_{v_{i,j}, v_{i,j+1}}}{\tau_{v_{i,j}, v_{i,j+1}}} \quad (1)$$

其中, θ 表示节点之间传输的任务数.

对于等待时间, 车辆传输的数据根据截止时间的升序进行排队. 截止时间最早的数据首先进行传输. 等待时间计算为

$$t_{v_{i,j}, v_{i,j+1}}^{\text{wait}} = \sum_{k=1}^{j-1} t_{v_{i,k}, v_{i,j+1}}^{\text{trans}} \quad (2)$$

则 d_i 的路由传输总时间为

$$t_{d_i} = \sum_{j=1}^{|U_{d_i}|-1} t_{v_{i,j}, v_{i,j+1}}^{\text{trans}} + t_{v_{i,j}, v_{i,j+1}}^{\text{wait}} \quad (3)$$

另外, DR 任务只有满足以下约束条件才能成功完成. 首先, 目标节点要在截止时间之前接收到数据. 其次, 两个相邻节点和之间的传输时间间隔应在其可通信的时间之内. 最后, DR 的目标是找到一组 DR 任务的合理路由路径, 以最大化当前时间片的传输任务完成比例. 将满足条件的任务数量记为 W_D , DR 问题可以表示为

$$\begin{cases} P_1: \max_{U_{d_i}} f_1 = \frac{W_D}{|D|}, \text{ s.t. } t_{d_i} \leq \text{ddl}_{d_i}, \forall d_i \in D \\ \left[\text{st}_{i,j}, \text{st}_{i,j} + t_{v_{i,j}, v_{i,j+1}}^{\text{trans}} \right] \subseteq \left[\text{et}_{v_{i,j}, v_{i,j+1}}, \text{lt}_{v_{i,j}, v_{i,j+1}} \right] \\ \forall d_i \in D, \forall d_j \in (V \cup E) \end{cases} \quad (4)$$

(2) SM 优化问题

对于 SM 任务 s_i , 引入二进制变量 $X_{i,m,m'}$, 表示是否将 s_i 从 e_m 迁移到 $e_{m'}$. 如果该二进制变量的值为 1, 则表示需要 SM. 否则保留 s_i 在原边缘节点 e_m . 给定任务计算量、迁移虚拟机大小和所需下载的结果数据大小, 总服务时间可以分为四个部分: 迁移时间、等待时间、计算时间和传输时间.

迁移时间是指 s_i 的服务虚拟机从 e_m 迁移到 $e_{m'}$ 所需的时间. 若不发生迁移, 则该值为 0. 计算式为

$$t_{s_i}^{\text{mig}} = \frac{u_{s_i}}{\tau_{e_m, e_{m'}}} \quad (5)$$

由于服务计算遵循边缘节点上的最短截止时间优先策略, 等待时间定义为在边缘节点上等待计算的服务持续时间. 将 $e_{m'}$ 的等待队列表示为 $S_{e_{m'}}$. 等待时间可以表示为

$$t_{s_i}^{\text{wait}} = \sum_{k=1}^{i-1} (t_{e_{m'}, k}^{\text{mig}} + t_{S_{e_{m'}}, k}^{\text{cal}}) \quad (6)$$

计算的消耗时间可表示为

$$t_{s_i}^{\text{cal}} = \frac{\alpha_{s_i}}{c_{e_{m'}}} \quad (7)$$

计算完成后, 需将服务结果返回给发起请求的车辆, 其传输时间的计算式为

$$t_{s_i}^{\text{trans}} = \frac{\sigma_{s_i}}{\tau_{e_m, v_{s_i}}} \quad (8)$$

所以, SM 任务的总服务时间计算式为

$$t_{s_i} = t_{s_i}^{\text{mig}} + t_{s_i}^{\text{wait}} + t_{s_i}^{\text{cal}} + t_{s_i}^{\text{trans}} \quad (9)$$

将满足条件的服务数量记为 W_S , SM 任务的目标是通过将 SM 到适当的边缘节点来最大化服务比例, 问题可以表示为

$$\begin{cases} P_2: \max_{e_{m'}} f_2 = \frac{W_S}{|S|}, \text{ s.t. } x_{i, m, m'} \in \{0, 1\}, \forall s_i \in S, e_m \in E \\ \sum_{m=1}^{|E|} x_{i, m, m'} = 1, \forall s_i \in S, e_m \in E, t_{s_i} \leq \text{ddl}_{s_i}, \forall s_i \in S \end{cases} \quad (10)$$

上述约束条件保证了每个服务最多可以迁移到一个节点, 并且迁移过程必须在截止时间内完成.

(3) TO 优化问题

给定任务计算量和需下载的结果数据大小, 引入二进制变量 $X_{i, o, o'}$ 来表示是否进行 TO. 总服务时间可以分为三个部分: 等待时间、计算时间和传输时间.

其中, 等待时间对于服务车辆上进行的计算任务 o_i , 依然采用最短截止时间优先服务策略, 以获得尽可能大的任务完成率, 等待时间定义为在卸载到服务车辆上的任务等待进行计算所耗费的时间. 对于当前方案决定将 TO 到的服务车辆, 其任务等待队列中的任务表示为 $O_{ob_{o_i}}$, 则该任务需要等待优先级比它更高的任务先行计算完成, 等待时间为

$$t_{o_i}^{\text{wait}} = \sum_{k=1}^{i-1} (t_{O_{ob_{o_i}}, k}^{\text{cal}}) \quad (11)$$

为了完成任务, 服务车辆 ob_{o_i} 进行计算的时间开销可表示为

$$t_{o_i}^{\text{cal}} = \frac{\alpha_{o_i}}{c_{ob_{o_i}}} \quad (12)$$

计算完成后, 需要将任务的计算结果返回给发起请求车辆, 其传输耗时计算式为

$$t_{o_i}^{\text{trans}} = \frac{\sigma_{o_i}}{\tau_{ob_{o_i}, v_{o_i}}} \quad (13)$$

所以, 卸载任务 o_i 的总耗时为

$$t_{o_i} = t_{o_i}^{\text{wait}} + t_{o_i}^{\text{cal}} + t_{o_i}^{\text{trans}} \quad (14)$$

将成功在时间约束内完成的任务数量记为 W_O , TO 的目标是通过将 TO 到适当的临近服务车辆来最大化任务交付的比例, 该问题可表示为

$$\begin{cases} P_3: \max_{ob_{o_i}} f_3 = \frac{W_O}{|O|}, \text{ s.t. } x_{i, o, o'} \in \{0, 1\}, \forall o_i \in O, ob_{o_i} \in V \\ \sum_{o'=1}^{|V|} x_{i, o, o'} = 1, \forall o_i \in O, ob_{o_i} \in V, t_{o_i} \leq \text{ddl}_{o_i}, \forall o_i \in O \end{cases} \quad (15)$$

同样, 上述约束条件保证每个任务只能被卸载到最多一个服务车辆, 即不考虑任务同时被多个车辆进行计算的情况, 并且计算和交付必须在截止时间之内完成.

(4) MT 优化问题

对于任务 m_i , 请求车辆 v_{m_i} 和目标节点 ob_{m_i} 之间的路由路径为 U_{d_i} . 为了计算 m_i 的传递时间, 考虑两个因素: 传输时间和等待时间.

对于传输路径上的任意两个中继节点 $v_{i,j}, v_{i,j+1}$ 计算 MT 所需的时间. 给定传输速率 $\tau_{v_{i,j}, v_{i,j+1}}$ 和数据大小 σ_{m_i} , 传输时间可表示为

$$t_{v_{i,j}, v_{i,j+1}}^{\text{trans}} = \frac{\sigma_{m_i}}{\tau_{v_{i,j}, v_{i,j+1}}} \quad (16)$$

对于等待时间, 由 v_{m_i} 传输的数据根据截止时间的升序进行排队, 将容易过期的数据优先进行传输. 等待时间计算式为

$$t_{v_{i,j}, v_{i,j+1}}^{\text{wait}} = \sum_{k=1}^{j-1} t_{v_{i,k}, v_{i,k+1}}^{\text{trans}} \quad (17)$$

所以, m_i 的路由传输总耗时计算式为

$$t_{m_i} = \sum_{j=1}^{|U_{d_i}|-1} t_{v_{i,j}, v_{i,j+1}}^{\text{trans}} + t_{v_{i,j}, v_{i,j+1}}^{\text{wait}} \quad (18)$$

MT 任务只有满足以下约束条件才能成功. 首先, 目标车辆在截止时间之前接收到数据. 其次, 两个相邻节点和之间的传输时间间隔应在其可通信的时间之内. 最后, MT 任务的目标是找到一组 MT 的合理通信路径, 以最大化当前时间片的传输任务完成比例. 将满足条件的任务数量记为 W_M , MT 问题可以定义为

$$\begin{cases} P_4: \max_{U_m} f_1 = \frac{W_M}{|M|}, \text{ s.t. } t_{m_i} \leq \text{ddl}_{m_i}, \forall m_i \in M \\ \left[\text{st}_{i,j}, \text{st}_{i,j} + t_{v_{i,j}, v_{i,j+1}}^{\text{trans}} \right] \subseteq \left[\text{et}_{v_{i,j}, v_{i,j+1}}, \text{lt}_{v_{i,j}, v_{i,j+1}} \right] \\ \forall m_i \in M, \forall v_i \in V \end{cases} \quad (19)$$

3.3 问题分析

首先,关注 DR 问题和 SM 问题. 尽管 DR 和 SM 的应用场景一致,但问题属性和解决方案空间方面各不相同. DR 侧重于有限的通信能力和中继节点负载,而 SM 主要考虑提供计算服务的边缘节点及其维持的总服务量. 它们都属于异构跨域任务,通过多任务优化方法可以传递一定的隐含关联知识. 具体而言,DR 和 SM 共享同一时间片内车辆的相同地理分布和移动特征,并通过完全相同的边缘节点组满足车辆的通信和服务需求,这自然地将两个问题的解决方案限制在相似的空间中. 此外,SM 任务需要从边缘节点下载数据,当车辆移出覆盖范围时,结果将通过 DR 返回到请求的车辆,导致 SM 和 DR 之间在通信路径探索上存在依赖关系(尽管它们的传输内容和数据量不同).

其次,观察 MT 和 TO 问题. MT 和 TO 问题可以看作是一种另类的 DR 和 SM 问题,其目标和计算方法与原问题组近似,但由于这两类问题不与边缘节点产生关联,而存在一个已知的目标服务车辆,其解空间完全不依赖车辆与边缘节点的分布关系. 这两种优化问题可以作为 V2V 场景的典型问题,由于通信链路终点的拓扑分布差异,其求解空间与上述 V2I 优化问题存在明显差异,可以认为在一般情况下,其相关性较弱. 由于求解空间的显著差异,虽然问题组内部的问题之间可以通过知识迁移取得较好效果,但在不同问题组之间的知识迁移效益通常不明显,即存在相关性未知的任务. 原有的进化多任务方法不区分任务间的相关性,可能导致迁移资源的浪费. 因此,对相关性未知的任务进行相关性评估,动态调整迁移策略,确保知识迁移的有效性显得尤为重要.

综上,DR、SM、MT、TO 问题共享车辆动态、资源、数据依赖、独立优化会忽略关联性,导致冲突或低效. 同时系统边缘服务器的带宽与计算资源有限,需根据不同任务协同分配. 基于这些特点,设计的 EMTO 方法通过在优化过程中的信息共享和迁移机制,能够提高多任务优化效率与求解质量. 此外,在 IoV 边缘计算环境下,同时利用 ETMO 方法解决我们所定义的 V2I 问题组与 V2V 问题组,需要对任务间的相关性进行评估. 在利用进化算法联合求解时,必须有效地进行知识间的迁移. 如何有效利用任务相关性信息来动态调整迁移策略,以实现高效的知识迁移和资源共享,成为了我们研究的重点.

4 IoV ETMO 算法设计

4.1 算法工作流程

本文研究了在 IoV 环境下,如何为多任务优化问题构建 ETMO 方法. 由于四个优化任务的解结构复杂,可以进一步拆分为同一任务车辆的子任务甚至独立子任务,直接采用隐式映射方案建立统一表示解可能导致信息损失. 特别是当同一车辆发起不同数量的任务或仅发起一种任务时,统一对齐方案可能会传递无用解. 因此,本文探索显式迁移方法,采用多个独立种群来解决这一问题.

图 2 展示了一种具备显式知识迁移特性,具有相关性评估机制的多种群 EMTO 方法的工作流程. 首先,该方法采用了独立种群的进化求解器,这些求解器分别针对四类优化问题进行求解,并根据各自任务的特点采用不同的优化策略进行搜索,在不存在种群间迁移的情况下,这些算法可视为传统的单任务单目标进化算法. 为了建立跨任务域间的联系,实现知识在不同任务域之间的有效转移,在属于不同任务的种群间交换优化解. 本文根据车辆的位置信息确立其映射函数,构建任务间的映射关系矩阵. 该方法在种群迁移之前,通过选择性知道种群迁移来提高优化效率. 首先,针对相关性未知的多优化任务提出一种任务相关性评估机制,根据当前阶段不同任务解的相似度计算进行评估. 然后,针对不同的相关性因素,执行不同的迁移策略. 在种群迁移时,采用基于临时种群的两阶段迁移机制,避免负迁移的影响使得过早收敛到局部最优解,影响优化问题的求解.

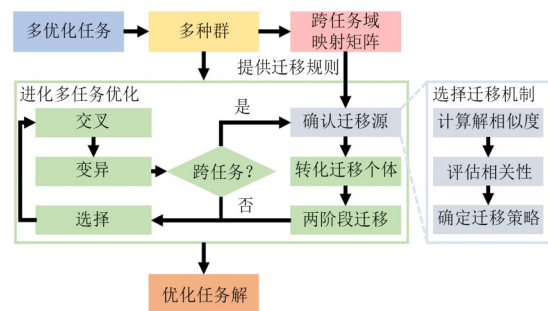


图 2 带有相关性评估机制的 ETMO 工作流程

本文所设计的 ETMO 算法将 IoV 环境下的 V2I 问题组与 V2V 问题组通过位置信息的映射关系矩阵关联起来,再利用契合所优化任务的知识迁移机制进行联合优化. 充分考虑在求解过程中任务间转换与知识迁移的效率,实现高效求解. 按照算法的工作流程,后文将逐一对进化任务求解器设计,基于任务信息映射的多任务对齐方法,基于通信链路相似度的任务相关性评估,混合迁移策略和基于临时种群的两阶段迁移机制

进行阐述.

4.2 进化求解器设计

本文所设计的带有任务相关性评估的 ETMO 算法, 针对单个问题采用独立种群的进化求解器进行求解. 在此框架下, 对进化算法的细致参数配置以及各任务种群中染色体的精妙设计显得尤为重要. 具体而言, 为了确保算法的有效性和高效性, 需精心设定进化算法的各项关键参数, 包括但不限于种群大小、交叉概率、变异概率、进化代数等. 这些参数的合理选择能够直接影响算法的搜索能力和收敛速度, 是优化过程中不可或缺的一环.

首先设计各个种群的染色体构成, 采用实数编码策略来表示各个任务的解. 以 DR 任务与 SM 任务为例, 其具体解可以通过统一方式表示, 因为两者均可用一组中转车辆和一个边缘节点来表示具体方案, 即数据从任务车辆经由中转车辆抵达边缘节点, 或边缘节点完成运算后经由中转车辆将结果反馈给任务车辆. 设 N 是最大路由跳数, 可将单个任务的染色体长度设为 N . 染色体中每个元素由一个整数表示, 该整数表示按索引排序的所有节点中的索引. 当前一个基因已经获得目标边缘节点的索引时, 该元素被设置为 0, 表示任务已经完成. 进一步地, 将多个 $1 \times N$ 的单任务染色体排列成二维数组, 则可表示整个任务组的染色体构成. 例如, 对于 DR 任务组, 染色体被编码为一个 $|D| \times N$ 的二维数组, 其中 $|D|$ 是 DR 任务的数量.

随后设计交叉和变异算子, 由于每个染色体对应多个车辆请求的任务解, 交叉操作是基于同一车辆的交叉单元进行的. 对于 $v_i \in V$, 分别用 sp_i 和 ep_i 表示 v_i 的解对应基因的起始位置和结束位置, 可以得到交叉范围 $[sp_i, ep_i]$. 在此基础上, 根据交叉概率 p_c 进行双点交叉操作. 变异算子则遍历整个染色体, 并根据变异概率 p_m 随机决定是否进行变异操作. 考虑到变异操作可能会产生不可行解, 在其对应车辆的相邻节点范围内寻找变异解, 从而避免生成超出通信范围的链路.

4.3 基于位置信息映射的多任务对齐方法

在完成各问题的进化求解器设置后, 需要探索如何进行不同任务间的对齐. 通过构建跨任务域映射矩阵, 为知识转移以及联合优化求解打下基础.

各个优化任务有着迥异的搜索空间, 直接将一个任务的可行解转移到另一个任务中显得较为困难. 因此需要建立任务之间的正确映射关系. 在 IoV 的环境下, 直接使用常用的流形对齐建立任务间的映射是有缺陷的, 可能导致过大的时间开销, 并且并不一定能获得良好的迁移效果. 如图 3 所示, 本文关注任务发起车辆的物理位置对通信和负载产生的重要影响, 并提取此属性作为映射的依据. 通过使用位置信息来提取任

务组的低维投影, 利用任务间的空间关系, 搜索具有相似物理位置的对应任务, 并进行映射.




图3 基于位置信息建立映射的多任务对齐方法

以从 A 任务组到 B 任务组的映射为例, 单方向的任务映射关系可以按照以下步骤建立. 具体的算法如算法 1 所示.

算法 1 基于位置信息建立映射的 IoV 多任务对齐方法

输入: 问题 A 的任务组 attri_A , 问题 B 的任务组 attri_B , 距离矩阵 M_D , 车辆数量 num_V

初始化: 问题 A 的车辆数量 vehicleNum_A , 问题 B 的车辆数量 vehicleNum_B , AB 任务的相关车辆距离矩阵 M_{dis} , 问题 A 到问题 B 的任务映射矩阵 $M_{A \rightarrow B} = \text{zeros}(\text{num}_V, \text{num}_V)$, 映射来源车辆

$\text{vehicle}_{\text{mapping}} = \text{vector}_{A \rightarrow B}[i]$, 来源车辆任务 $\text{num}_{\text{source}}$, 目标任务数 $\text{num}_{\text{target}}$

输出: 问题 A 到问题 B 的任务映射矩阵 $M_{A \rightarrow B}$

1. /*筛选和 AB 任务相关的车辆间距离*/
2. for $i = 1:\text{vehicleNum}_A$ do
3. for $j = 1:\text{vehicleNum}_B$ do
4. $M_{\text{dis}}[i][j] = M_D[i][j]$
5. end
6. end
7. 过滤, 问题 A 到问题 B 的车辆映射向量 $\text{vector}_{A \rightarrow B} = \min(M_{\text{dis}}, \text{col})$, 问题 B 到问题 A 的车辆映射向量 $\text{vector}_{B \rightarrow A} = \min(M_{\text{dis}}, \text{row})$
8. for $i = 1:\text{num}_V$ do
9. if $\text{num}_{\text{source}} > \text{num}_{\text{target}}$ then
10. 将来源车辆的前 $\text{num}_{\text{target}}$ 任务加入映射矩阵 $M_{A \rightarrow B}$
11. else then
12. 将来源车辆的前 $\text{num}_{\text{source}}$ 任务加入映射矩阵 $M_{A \rightarrow B}$
13. 来源车辆任务组随机抽取 $\text{num}_{\text{target}} - \text{num}_{\text{source}}$ 个任务加入映射矩阵 $M_{A \rightarrow B}$
14. end

建立车辆的任任务与映射车辆任务之间的映射关系. 将车辆 v_i^B 的任务集合表示为 $D_i^B = \{d_{i,1}^B, d_{i,2}^B, \dots, d_{i,n}^B\}$, 将映射车辆 v_j^A 任务集合表示为 $S_j^A = \{s_{j,1}^A, s_{j,2}^A, \dots, s_{j,n}^A\}$. 任务映射的目标是将 S_j^A 转换为 D_i^B . 当 $|D_i^B| \leq |S_j^A|$ 时, $d_{i,k}^B = s_{j,k}^A$. 否则

$$d_{i,k}^B = \begin{cases} s_{j,k}^A, & k \leq |S_j^A| \\ s_{j,\text{rand}(1, |S_j^A|)}^A, & |S_j^A| < k \leq |D_i^B| \end{cases} \quad (20)$$

其中, $\text{rand}(1, |S_j^A|)$ 表示在 $[1, |S_j^A|]$ 中取随机整数. 进一步地, 确定每个 B 任务的源转化为对应的 A 任务, 并建立 A 和 B 之间的映射关系. 使用同样的策略, 也可以将 B 问题映射到 A 问题. 通过使用稀疏矩阵 $M_{A \rightarrow B}$, 可以简单地表示如何将任务组 A 的求解知识迁移到任务组 B, 且便于使用矩阵乘法进行变换, 这种知识转移策略可以促进任务组之间的知识共享, 有助于提高优化算法的性能和收敛速度.

4.4 基于通信链路相似度的任务相关性评估

由于缺乏任务相关性的先验知识, 导致难以在求解工作开始前确定合适的迁移策略. 在求解的早期阶段, 由于各个优化任务尚未收敛, 即使在实际不相关的优化任务也可能由于求解空间的相似而产生较好的迁移效果. 而在求解的中后期, 仅有强相关的任务可能在收敛后依然存在较好的迁移效果. 考虑到知识迁移在求解前期的巨大收益, 即使是未收敛的弱相关任务之间的迁移收益也不应该被忽视. 进一步考虑上述架构的染色体构成, 可以发现所设计的任务解本质上包含了一组通信链路, 这不仅直接决定了任务的通信成本, 还以组的形式确定了一套负载方案(包括通信和计算两方面). 可见两个解给出的一组通信链路越相似, 其包含的解决方案相似的可能性越高, 其方案隐含的知识越可能具有传递价值. 因此, 本节提出一种基于通信链路相似度的任务相关性评估机制.

首先, 本文提出了一种基于优质个体相似度的任务相关性评估方法, 使用种群内较为优质的部分个体的解的相似度来评估任务本身的相关性. 如图 4 所示, 种群 1 和种群 2 的优势个体分布比整体分布更适合作为当前潜在最优解, 故不同种群的优势个体分布相比于整体分布更适合作为当前潜在的最优解, 故可考虑使用不同种群的优势个体分布重心的距离反映其对应任务的相关性.

由于各个问题空间中的解无法直接进行比较, 因此需要提出一种方法, 将原本不可直接比较的公共空

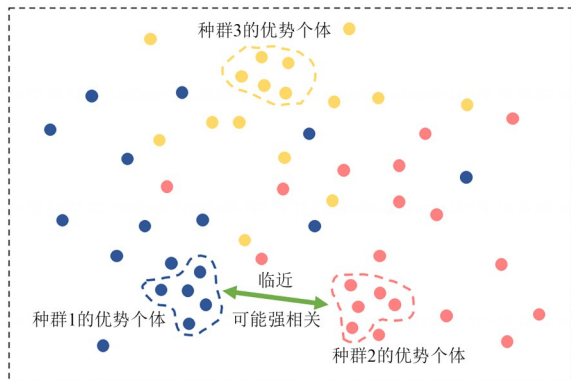


图 4 基于优势个体的相关性评估

间转化为可比较的公共空间, 从而能够对异构任务的个体进行距离比较.

如图 5 所示, 给出一种针对同一具体任务的两条通信链路的相似度评估方法. 使用了一种节点投票机制确定潜在最优解的通信方案, 以近似反映优质个体的重心分布. 首先抽取适应度最好的前 k 名个体, 将其染色体转化为具体任务的通信方案并进行投票. 然后, 将每一跳中得票数量最多的节点相连, 作为最优解的通信链路. 然后, 提出了一种利用最大公共子序列(Longest Common Sub-Sequence, LCSS)的通信链路相似度计算方法. 该方法通过搜索两条通信链路中存在的尽可能长的, 可非连续的公共节点排列来确定链路的相似度, 同时可以通过跳过离群点的方式在一定程度上忽略噪声, 从而实现有效的近似度计算. 具体的算法如算法 2 所示.

这种量化的相似程度作为一种任务相关性的评估结果, 协助进行迁移策略的选择. 通过重复考察任务相关性, 可尽可能地选取相关性更高的任务用于知识迁移.

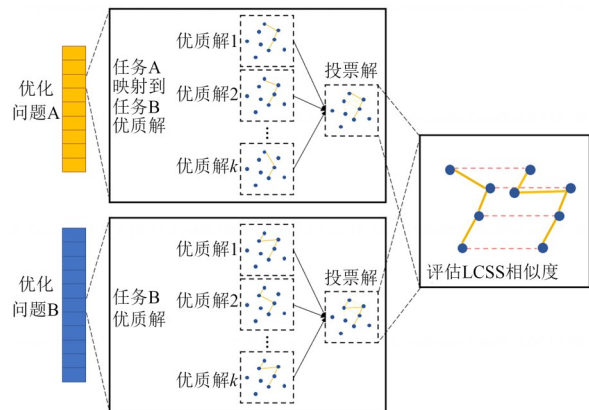


图 5 最长公共子序列相似度评估流程

4.5 混合迁移策略

在进行知识迁移时, 应当根据解相似度的具体情况动态地调整迁移策略. 为评估解相似度的具体情况, 本节首先将任务 j 对任务 i 的解相似度记为 $\text{sim}_i(j)$, 并对任务的解相似度提出最大相似率(Maximum Similarity Rate, MSR), 可反映当前与目标任务最相关的候选迁移任务是否具有绝对优势, 从而决定具体的迁移策略. MSR 表示解相似度最大的任务相似度在所有待评估任务相似度中的比例, 可表示为

$$\text{MSR} = \frac{\max_{j \neq i} \text{sim}_i(j)}{\sum_{j \neq i} \text{sim}_i(j)} \quad (21)$$

MSR 越高表示除了与目标任务的解相似度最大的任务外, 其他任务进行有效知识迁移的可能性越小, 而

算法 2 基于通信链路相似的任务相关性评估算法

输入: 优化问题 A 的优势个体集 pop_A , 优化问题 B 的优势个体集

pop_B , 映射矩阵 $M_{A \rightarrow B}$, 最大相近节点距离数量 maxDist , 链路相似度阈值 $\text{threshold}_{\text{sim}}$

初始化: 优化问题 B 的子任务数 num_{task} , 优化问题 B 的最大转发次数 $\text{num}_{\text{trans}}$, 动规数组 LCSS_{DP}

输出: 问题 A 针对问题 B 每个具体任务的解相似度 x_{out}

```

1. 转化,通过  $M_{A \rightarrow B}$  将  $\text{pop}_A$  转化为具有问题 B 染色体类型的个体集  $\text{pop}_T$ 
2. for  $i = 1:\text{num}_{\text{task}}$  do
3.   /*计算每个具体任务下投票路径的相似度*/
4.   投票,  $\text{pop}_T$  全部个体投票得到路径  $\text{pop}_T$ ,  $\text{pop}_B$  全部个体投票得到路径  $\text{path}_B$ 
5.   for  $j = 1:\text{num}_{\text{trans}}$  do
6.     for  $l = 1:\text{num}_{\text{trans}}$  do
7.       if  $\text{dist}(\text{path}_B, \text{path}_T) < \text{maxDist}$  then
8.          $\text{LCSS}_{\text{DP}}[j+1][l+1] = \text{LCSS}_{\text{DP}}[j+1][l] + 1$ 
9.       else if  $\text{LCSS}_{\text{DP}}[j+1][l] > \text{LCSS}_{\text{DP}}[j][l+1]$  then
10.         $\text{LCSS}_{\text{DP}}[j+1][l+1] = \text{LCSS}_{\text{DP}}[j+1][l]$ 
11.       else then
12.         $\text{LCSS}_{\text{DP}}[j+1][l+1] = \text{LCSS}_{\text{DP}}[j][l+1]$ 
13.       end
14.     end
15.   end
16. if  $\text{LCSS}_{\text{DP}}[\text{num}_{\text{trans}}+1][\text{num}_{\text{trans}}+1] > \text{threshold}_{\text{sim}}$ 
17.   then  $x_{\text{out}} += 1$ 
18. end

```

迁移最相似任务知识的价值越大. 当前迁移个体总数量为 Q , 待迁移任务数量为 N 时, 基于以上内容, 本节提出了一种在线调节迁移机制, 该机制将迁移数量名额分为两个部分: (1) 供所有待迁移任务均分的恒定迁移名额, 对于任意待迁移任务, 其分得的恒定迁移名额恒为 $\text{quota}_{\text{const}} = \lambda \times Q/N$. 其中 $\lambda \in (0, 1)$ 为恒定权重系数, 其值应设为一个较小值. 此部分名额保证无论任务相关性强弱, 每个任务都能获得一定的迁移机会, 避免完全忽视弱相关性任务的潜在价值. (2) 根据任务相关性进行分配的动态迁移名额, 其总额为 $\text{quota}_{\text{dynamic}} = (1 - \lambda) \times Q$. 进一步地, 针对动态迁移名额的分配方式, 提出如下三种迁移策略.

(1) 最相似迁移策略. 对于指定阈值 μ_{MSR} , 当 MSR 大于 μ_{MSR} 时, 可以认为除最相似任务外的其他任务含有有效迁移知识的可能性非常低, 迁移最相似任务知识的价值则非常大. 因此, 所有动态迁移名额均分配给最相似任务的种群, 即最相似任务的迁移个体数量为 $\text{quota}_{\text{dynamic}}$, 其余任务则均为 0. 由于 μ_{MSR} 是一个相当高的值, 当触发最相似迁移策略时, 可以认为其他任务的最优解提供有效迁移知识的可能性相当低, 为引入更

多解分布的可能性, 这些弱相关任务从种群中随机选择迁移个体, 而非仅选择最优个体.

(2) 权重迁移策略. 当 MSR 小于 μ_{MSR} 时, 次相似任务的重要性是难以忽视的. 由于解相似度的差异性, 进行选择时应该更侧重于迁移相似度更高的任务知识, 同时一定程度地从相似度低的任务中传递知识. 对于任意任务 j , 定义其相对任务的权重为 weight_j , 则其分配到的动态迁移名额数量为 $\text{quota}_{\text{dynamic}} \times \text{weight}_j$. 此策略可以保证每个任务均能够进行知识迁移, 但更侧重从更相似任务中进行选择. 当所有备选任务的相关性大致相当时, 此策略也可看作一种平均迁移策略.

(3) 平均迁移策略. 特别地, 当所有待迁移任务的相关性均为 0 时, 采用平均迁移的策略. 这种情况往往在求解过程的前期或后期出现, 即随机散布的个体尚未收敛, 或已经收敛到差异性较大的优质解的时候, 此时认为无法通过相关性评估结果确定合理的迁移方案, 所有候选任务均分动态迁移名额, 此迁移机制允许求解过程仅依赖解相似度这一充分不必要条件, 进而实现在线动态迁移, 尽可能从有效知识可能性更高的任务中获取信息, 在确保收敛速度的同时, 仅产生微小的额外开销.

4.6 基于临时种群的两阶段迁移机制

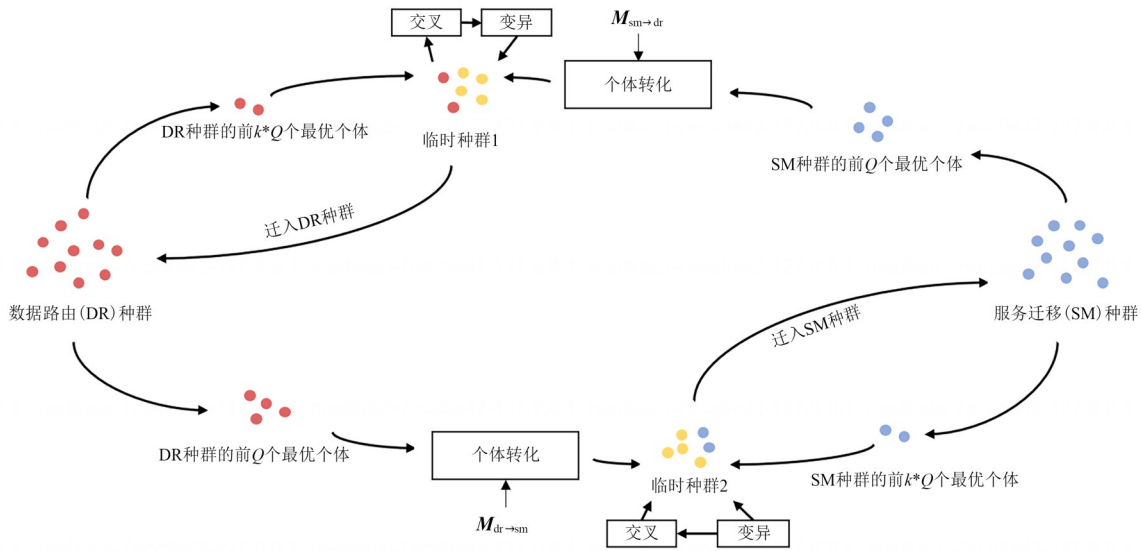
在进行相关任务的知识迁移时, 效果并不都是有益的. 以高强度的迁移力度进行迁移时, 可能会导致种群过早收敛到次优解, 有时效果甚至不如单任务优化的结果.

为了改善这一问题, 本节提出了一种利用临时种群的迁移引入噪声的方法, 以减小迁移机制中产生相同个体数量. 如图 6 所示, 本节提出了一种两阶段的迁移策略, 通过在种群 pop_A 和种群 pop_B 之间选择和交换个体来显式地在两个种群之间转移知识. 以 pop_A 到 pop_B 的转移为例, 可进行如下步骤.

(1) 在第一阶段, 从中选择 pop_A 排名靠前的 Q 个最佳个体, 并转换为 B 种群类型的个体. 这些转换后的个体存储到临时种群 pop_T 中.

(2) 在第二阶段, 从 pop_B 中随机选择 $k \times Q$ 个个体与 pop_T 中的随机个体进行交叉操作. 然后, 对剩下 $(1-k) \times Q$ 个上阶段迁入的个体进行变异操作. 最后, 将交叉和变异生成的新个体转移到 pop_B 中.

通过采用两阶段迁移机制, 转移到 pop_B 的个体与所选个体相似但不完全相同, 此方法可以有效减轻强相关任务过度转移的负面影响. 该机制确保了一致的个体不再充斥整个种群, 从而维持了种群的多样性. 即使在极大的迁移力度下, 此方法依然可以保证种群的多样性, 同时由于部分噪声来源于目标种群, 临时种群新生成的个体在新种群中依然可以表现出良好的适应性.

图6 基于临时种群的两阶段迁移机制^[34]

5 实验与分析

5.1 实验设置

本节基于上文提到的任务相关性未知的IoV多任务优化架构建立仿真模型,且使用Matlab实现了所有算法.该仿真模型基于成都出租车轨迹数据集,从成都市中心提取区域进行模拟,具体为2014年8月20日成都青羊区的1.5 km × 1.5 km区域.通过随机抽样获取了180个数据样本,以此模拟20个提供服务车辆和160个寻求服务车辆.同时,在真实的道路网络上随机生成边缘节点.该仿真场景中车辆平均停留时间为251.6 s,每秒平均车辆数为151.6,用于验证算法在IoV环境下的实时性和任务调度效率.鉴于边缘节点位置与车辆轨迹的双重随机性,所构建的仿真模型能够有效模拟现实中充满不确定性的交通场景.此外,该模型具备良好的扩展性,能够灵活适应不同规模和复杂程度的应用需求.

作为默认设置,在所关注的区域内模拟了10个边缘节点.每个边缘节点的计算能力在50~60个周期/s内随机生成.任意两个边缘节点之间的传输速率在10~15单位/秒随机生成,边缘节点与车辆之间的传输速率在5~10单位/秒内生成.对于车辆,任意两辆车之间的传输速率设置在2~5单位/秒.提供服务车辆的计算能力被设置为10~15周期/秒.实验涉及的DR任务和SM任务设置如下:车辆请求的DR任务数量在1~10随机生成,而车辆请求的SM任务数量在1~8随机生成.具体而言,对于每个DR任务,数据大小和截止时间分别在1~6单位和160~280 s生成.对于每个SM任务,计算需求、大小和截止时间分别在2~12周期、2~8单位和200~360 s内生成.DT任务和TO任务设置如下:车辆请求的

DT任务数量在1~6随机生成,而车辆请求的TO任务数量在1~5随机生成.具体而言,对于每个MT任务,数据大小和截止时间分别在1~5单位和120~240 s内生成.对于每个TO任务,计算需求、结果大小和截止时间分别在1~6个CPU周期、1~5单位和150~260 s内生成.最大迭代次数设置为1000,种群大小设置为100,中转跳数最大值设置为2,交叉概率设置为0.95,变异概率设置为0.01.为限制迁移强度,设置显式的个体转移在每10代中以12个个体的频率发生.对于任务相关性的计算中, topK值设为5, threshold_{sim}设为两链路中较长者的一半, μ_{MSR} 设为0.8.实验结果均取独立运行20次后的平均结果.

为了评估仿真模型的性能,实验实现了本文所设计的基于位置信息映射和相关性评估的进化多任务优化(Location Mapping based Evolutionary MultiTasking with LCSS, LM-EMT-LCSS)算法,并与之前工作(Location Mapping based Evolutionary MultiTasking, LM-EMT^[38])算法进行比较.此外还复现了另一种竞争算法,一种利用流行对齐建立任务映射的多种群显式EMT算法(Explicit Evolutionary MultiTasking Algorithm, EEMTA^[24]).本文选择EEMTA作为竞争算法,主要基于其与本文所提算法在任务映射和知识迁移实现机制上的显著差异.本文算法依托车辆位置信息构建任务映射关系,而EEMTA则采用流形对齐方法.这种本质区别使得两者在应对IoV多任务处理时,会呈现出不同的性能特征.同时EEMTA在IoV任务以及多任务优化的显式知识迁移方面具有典型性.我们还将该算法也加入了LCSS的任务相关性评估机制,形成了带有评估机制的EEMTA算法(EEMTA-LCSS),并与上述算法进行对比.同时实

验还引入了单任务优化的进化算法 SOEA (Single Objective Evolutionary Algorithm) 进行实验, 验证联合优化的有效性. 并使用 (Number of Positive Transferred Individuals, NPTI) 正向转移的个体数量考察迁移后个体的存活率.

此外, 为确认混合策略机制的有效性, 分别对三种单一策略和混合策略进行设置, 其简要描述如下: 权重迁移策略 *weight*, 将候选任务与待迁入任务的相关性作为权重, 决定任务的实际迁移个体数量; 最相似迁移策略 *maximum*, 每次仅迁移相关性最大的候选任务; 平均迁移策略 *average*, 所有候选任务的迁移个体数量相等; 上文中提出的混合迁移策略 *mix*, 其根据候选任务的

MSR 决定采用何种策略, 即在 MSR 较高时使用最相似迁移策略, 较低时使用权重迁移策略, 无法评估相关性 (相似度均为 0) 时使用平均迁移策略.

5.2 实验结果与分析

(1) 联合优化的有效性. 实验结果如图 7 所示, 表明在使用 LM-EMT-LCSS 算法进行四个问题的联合优化时, 效果比 SOEA 单独优化更为出色. 这是因为本文算法利用不同任务之间的互补知识, 基于种群的搜索并行性同时优化四个不同任务. 有效地利用任务之间的互补性实现多任务同时高效优化, 获得更高的任务优化效率与求解质量. 同时联合优化将较与单独优化, 并行搜索多个任务, 有着更好的时间效率.

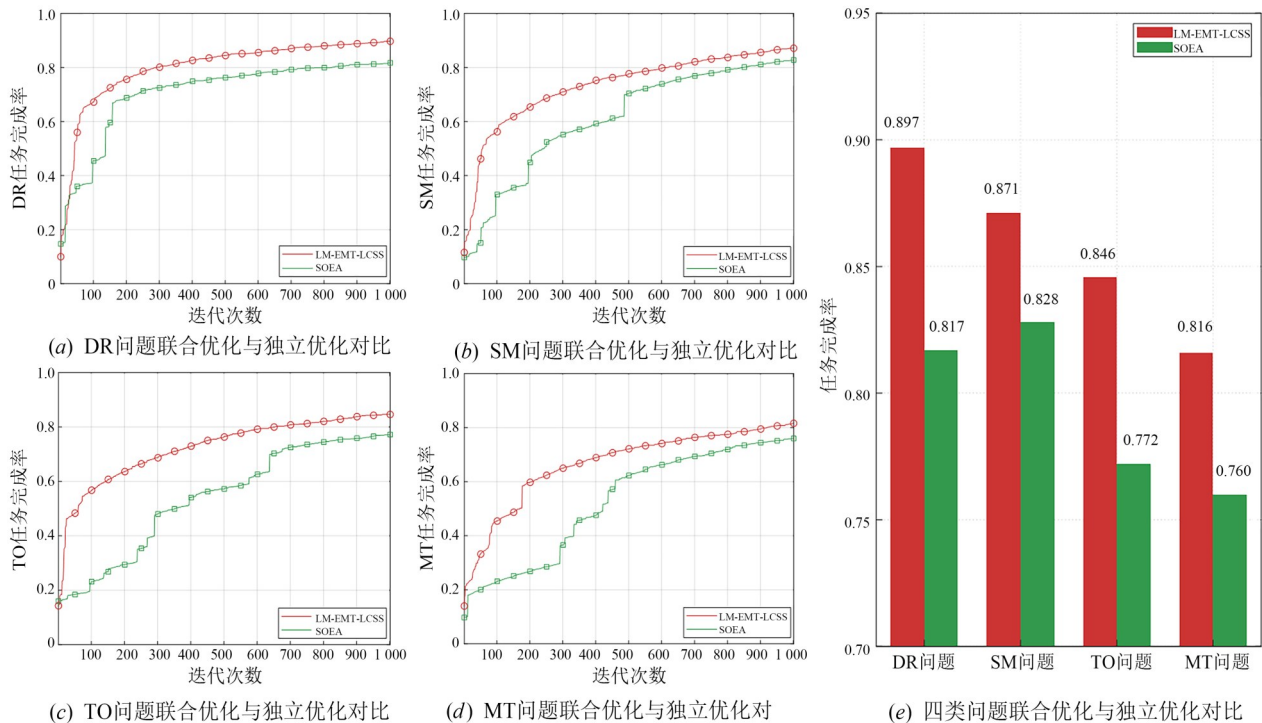


图7 LM-EMT-LCSS联合优化与SOEA单独优化的效果对比图

(2) 任务相关性评估机制对求解收敛的作用. 实验结果如图 8 所示, 表明无论是基于 LM-EMT 算法还是 EEMTA 算法, 加入任务相关性评估机制均对求解收敛有一定的促进作用, 证明了所提任务相关性评估机制可用于不同的显式多任务优化方法, 其中本文提出 LM-EMT-LCSS 算法的效果最佳. 结果展示了该算法可以在缺少任务相关性先验知识的前提下, 对任务相关性做出较为准确的评估, 不仅加快了求解器的收敛速度, 还在大部分任务中获得了更好的收敛结果. 值得注意的是, LM-EMT-LCSS 算法的优势比 EEMTA-LCSS 算法更加明显, 这是由于该机制的实现依赖于显式映射机制, 即在越准确的映射关系上效果越好.

(3) 转移个体的生存情况. 通过分析图 9, 可以看到任务相关性评估机制在整个优化过程中均能提高转移个体的生存率, 这是由于评估机制迁入了更多的强相关任务个体, 其在迁入种群的表现比起弱相关任务个体更好. 这些具备更强适应性的个体在整个求解过程中提供了有效的转移知识, 并将知识传递到后续的进化周期中. 同时, 评估机制在迭代的早期阶段对于 NPTI 的提升也更加显著, 因为在任务优化早期, 强相关任务的解分布往往是最为相似的, 后期则会由于求解收敛而减小相似度, 使得其提升效果有所削弱.

(4) 相关性评估预期与实际转移数量的关系. 图 10




图 8 算法在多任务中的收敛情况

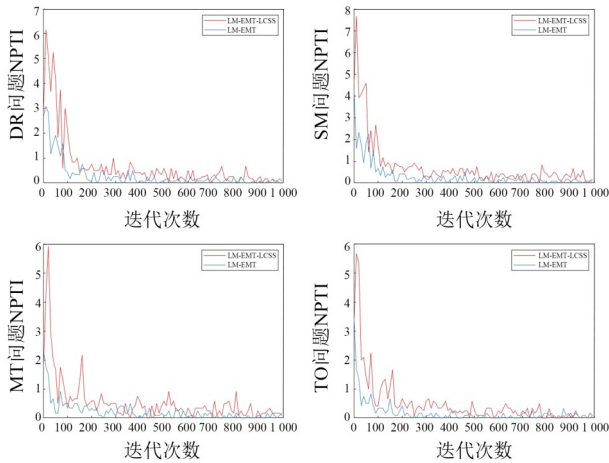


图 9 不同任务下转移个体的生存情况

表示了任务相关性评估结果与实际迁移效果间的关系. 对于任意两组优化任务, 计算其 LCSS 相似度与 NPTI 的肯德尔相关系数, 并绘制热力图. 结合实验数据, 考虑到进化算法本身的随机性干扰, 对于强相关任务 (如 DR 和 SM, DT 和 TO), 其 LCSS 相似度较高, 且肯德尔相关系数也处于较高水平. 而弱相关任务间的 LCSS 相似度较低, 肯德尔相关系数较为不显著. 其证明了 LCSS 相似度可作为正迁移的充分不必要条件, 即当 LCSS 相似度较高时, 可以认为任务相关性较强, 迁移往往取得较好效果, 其同样证明了混合迁移策略的必要性.

(5) 迁移策略对比情况. 图 11 对比了混合迁移策略与单一策略在迭代停止时的求解效果. 其中, 平均迁移策略往往取得较差效果, 这是由于其引入了过多弱相关任务个体的迁移. 权重迁移策略和最相似迁移策




图 10 评估结果与实际迁移效果的相关系数分布

略往往取得较好效果, 因为其关注了任务相关性, 但不对其相关性的分布情况作区分, 可能不充分引入强相关任务或完全忽视弱相关任务. 混合迁移策略则取得最好效果, 证明了该策略的有效性, 即其不但关注了最相关任务的有用知识, 同时没有忽视其他次相关任务的潜在促进作用, 与单一策略相比, 混合策略可以最好地利用任务相关性评估结果, 实现多任务高效联合求解.




图 11 不同迁移策略的求解效果

(6) 建立映射耗时对比. 如图 12 所示, 展示了 LM-EMT-LCSS 和 EEMTA 在不同任务数量下所消耗的建立任务间映射的时间. 为便于展示, 将总任务数逐渐从 200 增加到 2 000. 随着任务数量的增加, 两种方法的耗时增长趋势也增大, 这是因为查找单个任务的映射任务的搜索空间变得更大. 然而, 就映射时间而言, LM-EMT-LCSS 明显优于 EEMTA, 即使在任务数量高达 2 000 时也仅需不到 0.02 s 的耗时, 而流形对齐方法则需要数分钟. 当求解多任务数量更多时, 两种方法的映射耗时差距将更加明显. 这是因为 LM-EMT-LCSS 采用了先降维到低维空间的方法, 不需要对流形进行复杂的线性变换以投影到公共子空间, 从而满足 IoV 环境对耗时的需求.




图12 建立显式映射关系的耗时

6 结论

本文基于ETMO方法对IoV环境下的多任务优化问题进行了探讨,构建了车辆为环境下的多任务优化架构,重点探索了基于位置信息映射的IoV多任务优化算法和基于任务相关性评估的选择迁移机制两方面内容.针对IoV多任务优化组合,提出了一种基于位置信息快速建立映射的IoV多任务优化算法.针对未知任务相关性的IoV多任务优化场景,设计了基于任务相关性评估的混合策略迁移机制.最后,进行实验并分析实验结果,证明了所提架构和算法的可行性.

未来的工作包括2个方面:

(1)对于显式知识迁移架构的特征提取研究.在现实场景中的多任务优化情形往往更加复杂,需要提出更加精巧的降维方法以增强映射关系的可靠性.因此,在接下来的工作中,应考虑引入一些统计学方法对任务特征进行评估,具体地,提取分布差异较大的特征进行降维处理,挖掘异构任务间最有比较价值的公共子特征,并保证该方法的低时间开销,使得多任务优化算法的优势得以充分发挥.

(2)更深入的解相似度评估机制.对解相似度的评估应当考虑差异化特征对其的影响,保证任务相关性判定机制在复杂情况下的鲁棒性.在本文下一步工作中,如何细化解相似度评估机制,确定解相似度和任务相关性的联系,进一步提升算法的知识转移能力,是一个值得探讨的问题.

致谢 本研究工作受重庆市大数据智能与隐私计算重点实验室支持.

参考文献

[1] 江恺,曹越,周欢,等.车联网边缘智能:概念、架构、问题、实施和展望[J].物联网学报,2023,7(1):37-48.
JIANG K, CAO Y, ZHOU H, et al. Edge intelligence empowered internet of vehicles: Concept, framework, issues, implementation, and prospect[J]. Chinese Journal on Inter-

net of Things, 2023, 7(1): 37-48. (in Chinese)

- [2] XU X L, YANG C Y, BILAL M, et al. Computation offloading for energy and delay trade-offs with traffic flow prediction in edge computing-enabled IoV[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(12): 15613-15623.
- [3] FAN W H, SU Y, LIU J, et al. Joint task offloading and resource allocation for vehicular edge computing based on V2I and V2V modes[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(4): 4277-4292.
- [4] LIU K, LIU C H, YAN G Z, et al. Accelerating DNN inference with reliability guarantee in vehicular edge computing[J]. IEEE/ACM Transactions on Networking, 2023, 31(6): 3238-3253.
- [5] YAN G Z, LIU K, LIU C H, et al. Edge intelligence for Internet of vehicles: A survey[J]. IEEE Transactions on Consumer Electronics, 2024, 70(2): 4858-4877.
- [6] 许小龙,杨威,杨辰翊,等.车联网边缘计算环境下基于流量预测的高效任务卸载策略研究[J].电子学报,2025,53(2):329-343.
XU X L, YANG W, YANG C Y, et al. Research on efficient task unloading strategy based on traffic prediction in edge computing environment of internet of vehicles[J]. Aata Electronica Sinica, 2025, 53(2): 329-343. (in Chinese)
- [7] REN H L, LIU K, YAN G Z, et al. Truthful auction mechanisms for dependent task offloading in vehicular edge computing[J]. IEEE Transactions on Mobile Computing, 2024, 23(12): 14987-15002.
- [8] 李可,马赛,戴朋林,等.基于多目标深度强化学习的车车通信无线资源分配算法[J].计算机研究与发展,2024,61(9):2229-2245.
LI K, MA S, DAI P L, et al. Wireless resource allocation algorithm based on multi-objective deep reinforcement learning for vehicle-to-vehicle communications[J]. Journal of Computer Research and Development, 2024, 61(9): 2229-2245. (in Chinese)
- [9] ZHAO H, NING X H, LIU X T, et al. What makes evolutionary multi-task optimization better: A comprehensive survey[J]. Applied Soft Computing, 2023, 145: 110545.
- [10] YAO L, XU X L, BILAL M, et al. Dynamic edge computation offloading for Internet of vehicles with deep reinforcement learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(11): 12991-12999.
- [11] HUI Y L, WANG Q Q, SU Z, et al. Joint optimization of personalized route planning and global traffic scheduling: A DT-enabled integrated framework[J]. IEEE Transac-

- tions on Vehicular Technology, 2024, 73(10): 14474-14485.
- [12] WU Q, WANG W H, FAN P Y, et al. URLLC-awared resource allocation for heterogeneous vehicular edge computing[J]. IEEE Transactions on Vehicular Technology, 2024, 73(8): 11789-11805.
- [13] ZHANG R, WU L B, CAO S Q, et al. A vehicular task offloading method with eliminating redundant tasks in 5G HetNets[J]. IEEE Transactions on Network and Service Management, 2023, 20(1): 456-470.
- [14] 朱思峰, 蔡江昊, 柴争义, 等. 车联网云边协同计算场景下的多目标优化卸载决策[J]. 通信学报, 2022, 43(6): 223-234.
- ZHU S F, CAI J H, CHAI Z Y, et al. Multi-objective optimal offloading decision for cloud-edge collaborative computing scenario in Internet of vehicles[J]. Journal on Communications, 2022, 43(6): 223-234. (in Chinese)
- [15] GUPTA A, ONG Y S, FENG L, et al. Multiobjective multifactorial optimization in evolutionary multitasking[J]. IEEE Transactions on Cybernetics, 2017, 47(7): 1652-1665.
- [16] ZHOU L, FENG L, ZHONG J H, et al. A study of similarity measure between tasks for multifactorial evolutionary algorithm[C]//Proceedings of the Genetic and Evolutionary Computation Conference Companion. New York: ACM, 2018: 229-230.
- [17] BALI K K, ONG Y S, GUPTA A, et al. Multifactorial evolutionary algorithm with online transfer parameter estimation: MFEA-II[J]. IEEE Transactions on Evolutionary Computation, 2020, 24(1): 69-83.
- [18] YI J, ZHANG W, BAI J R, et al. Multifactorial evolutionary algorithm based on improved dynamical decomposition for many-objective optimization problems[J]. IEEE Transactions on Evolutionary Computation, 2022, 26(2): 334-348.
- [19] WANG B C, LIU Z Z, SONG W. Solving constrained optimization problems via multifactorial evolution[J]. Applied Soft Computing, 2022, 127: 109392.
- [20] THANG T B, BINH H T T. A hybrid multifactorial evolutionary algorithm and firefly algorithm for the clustered minimum routing cost tree problem[J]. Knowledge-Based Systems, 2022, 241: 108225.
- [21] FENG Y L, FENG L, KWONG S, et al. A multivariation multifactorial evolutionary algorithm for large-scale multiobjective optimization[J]. IEEE Transactions on Evolutionary Computation, 2022, 26(2): 248-262.
- [22] LIU S B, LI J, LIN Q Z, et al. Evolutionary large-scale multiobjective optimization via autoencoder-based problem transformation[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2024, 8(4): 2709-2722.
- [23] FENG L, ZHOU L, ZHONG J H, et al. Evolutionary multitasking via explicit autoencoding[J]. IEEE Transactions on Cybernetics, 2019, 49(9): 3457-3470.
- [24] FENG L, HUANG Y X, ZHOU L, 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.
- [25] TANG Z D, GONG M G, WU Y, et al. Regularized evolutionary multitask optimization: Learning to intertask transfer in aligned subspace[J]. IEEE Transactions on Evolutionary Computation, 2021, 25(2): 262-276.
- [26] GAO K L, YANG C E, DING J L, et al. Distributed knowledge transfer for evolutionary multitask multimodal optimization[J]. IEEE Transactions on Evolutionary Computation, 2024, 28(4): 1141-1155.
- [27] LI Y C, GONG W Y, LI S J. Multitasking optimization via an adaptive solver multitasking evolutionary framework[J]. Information Sciences, 2023, 630: 688-712.
- [28] ZHOU J J, RAO S J, GAO L, et al. Solving many-task optimization problems via online intertask learning[J]. Expert Systems with Applications, 2023, 225: 120110.
- [29] ZHOU X, WANG Z K, FENG L, et al. Toward evolutionary multitask convolutional neural architecture search[J]. IEEE Transactions on Evolutionary Computation, 2024, 28(3): 682-695.
- [30] MA Z T, ZHONG J H, LIU W L, et al. Accelerating evolutionary multitasking optimization with a generalized GPU-based framework[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2024, 8(6): 3995-4010.
- [31] LI J Q, CAI J C, SUN T, et al. Multitask-based evolutionary optimization for vehicle routing problems in autonomous transportation[J]. IEEE Transactions on Automation Science and Engineering, 2024, 21(3): 2400-2411.
- [32] YI J, BAI J R, HE H B, et al. A multifactorial evolutionary algorithm for multitasking under interval uncertainties[J]. IEEE Transactions on Evolutionary Computation, 2020, 24(5): 908-922.
- [33] GUPTA A, ZHOU L, ONG Y S, et al. Half a dozen real-world applications of evolutionary multitasking, and more[J]. IEEE Computational Intelligence Magazine, 2022, 17(2):

- 49-66.
- [34] LI W C. Multi-receiver data authorization with data search for data sharing in cloud-assisted IoV[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(5): 4233-4250.
- [35] FAN Q B, CHEN L, YOU C S, et al. Dependency-aware service migration for backhaul-free vehicular edge computing networks[J]. IEEE Transactions on Vehicular Technology, 2024, 73(1): 1337-1352.
- [36] CAO B Q, YE H F, LIU J X, et al. SMART: Cost-aware service migration path selection based on deep reinforcement learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(9): 12421-12436.
- [37] LIU C H, LIU K. Toward reliable DNN-based task partitioning and offloading in vehicular edge computing[J]. IEEE Transactions on Consumer Electronics, 2024, 70(1): 3349-3360.
- [38] ZHOU Y K, REN H L, XIAO K, et al. Joint Data Routing and Service Migration via Evolutionary Multitasking Optimization in Vehicular Networks[M]//International Conference on Neural Computing for Advanced Applications. Singapore: Springer Nature Singapore, 2023: 434-449.


作者简介



沈俊杰 男,2002年3月出生于四川省达州市.现为重庆大学计算机学院硕士研究生.主要研究方向为车联网、边缘计算、人工智能.
E-mail: shenjunjie@stu.cqu.edu.cn



彭江 男,1989年2月出生于湖北省恩施市.2016年硕士毕业于重庆理工大学车辆工程,现为重庆大学2024届博士研究生,赛力斯科技公司智能测试中心副总经理.主要研究方向为智能汽车智能化.
E-mail: jiang.peng@seres.cn



郭坤银 男,1982年7月出生于重庆市.现为重庆大学国家卓越工程师学院教师.主要研究方向为服务计算、创业教育.
E-mail: ess@cqu.edu.cn



刘凯 男,1984年8月出生于四川省成都市.现为重庆大学计算机学院、重庆大学国家卓越工程师学院教授,博士生导师.主要研究方向为车联网、自动驾驶、边缘智能等.
E-mail: liukai0807@cqu.edu.cn