

进化多任务优化综述

蒋 恽¹⁾ 詹志辉²⁾ 张 军²⁾

¹⁾(汉阳大学 安山 15588 韩国)

²⁾(南开大学人工智能学院 天津 300350)

摘 要 进化多任务优化是进化计算研究领域的一个新兴研究热点。通过共享多个任务之间的相关知识,进化多任务优化算法能高效地同时求解多个优化任务,并在求解实际应用中的复杂多任务优化问题上具有显著性能优势。为了充分梳理进化多任务优化的研究和应用现状,本文围绕可跨任务共享的知识,从知识选择、知识迁移和知识运用三个主要方向全面阐述进化多任务优化领域的研究前沿。在知识选择方面,本文探讨了基于相似性和基于性能反馈的知识选择相关研究,分析了相关策略从源任务中选择知识的能力。在知识迁移方面,本文从种群层面、个体层面和维度层面对知识迁移相关研究进行介绍,分析了不同知识迁移机制的适用性和优劣势。最后,在知识运用方面,本文介绍了基于交叉变异、信息融合和行为模仿的知识运用相关研究,分析了其在提升目标任务优化性能的效果。通过对现有研究的分类和总结,梳理了进化多任务优化领域的研究脉络,并为未来研究方向提供了有价值的参考,以期推动该领域的持续发展。

关键词 进化计算;进化多任务优化;知识选择;知识迁移;知识运用

中图法分类号 TP18

DOI号 10.11897/SP.J.1016.2025.02735

A Survey on Evolutionary Multitask Optimization

JIANG Yi¹⁾ ZHAN Zhi-Hui²⁾ ZHANG Jun²⁾

¹⁾(Hanyang University, Ansan 15588 Republic of Korea)

²⁾(College of Artificial Intelligence, Nankai University, Tianjin 300350)

Abstract Evolutionary multitask optimization is an emerging research topic in the evolutionary computation community. By sharing knowledge across related tasks, evolutionary multitask optimization algorithms can efficiently and simultaneously solve multiple optimization tasks and have encouraging performance in solving complex multitask optimization problems in real-world applications. To promote the development and application of evolutionary multitask optimization, this paper describes the research frontiers of evolutionary multitask optimization around the knowledge that can be shared across tasks from three main directions: knowledge selection, knowledge transfer, and knowledge utilization. In the aspect of knowledge selection, this paper reviews the related studies on similarity-based and performance-feedback-based knowledge selection strategies and analyzes their abilities to select knowledge from source tasks. In the aspect of knowledge transfer, this paper reviews the related studies on population-level, individual-level, and dimension-level knowledge transfer strategies, and analyzes their advantages. Finally, in the aspect of knowledge utilization, this paper reviews the research related to knowledge utilization based on crossover and mutation, information fusion, and behavioral imitation, and analyzes their effects

收稿日期:2025-01-15;在线发布日期:2025-07-28。本课题得到国家重点研发计划项目(No. 2024YFF0509600)、国家自然科学基金面上项目(No. 62176094)、国家自然科学基金企业联合重点项目(No. U23B2039)和天津市顶尖科学家工作室项目(No. 24JRRRCRC00030)的资助。蒋 恽,博士,中国计算机学会(CCF)会员,主要研究领域为进化计算、多任务优化。E-mail:vladimir_jiangyi@qq.com。詹志辉(通信作者),博士,教授,中国计算机学会(CCF)杰出会员,主要研究领域为人工智能、进化计算、群体智能及其应用。E-mail:zhanapollo@163.com。张 军,博士,教授,主要研究领域为人工智能、进化计算。

in assisting the optimization of the target task. By categorizing the existing studies, this paper summarizes the research lineage of evolutionary multitasking optimization and provides valuable ideas for future research, intending to promote the continuous development of this field.

Keywords evolutionary computation; evolutionary multitask optimization; knowledge selection; knowledge transfer; knowledge utilization

1 引 言

进化计算 (Evolutionary Computation, EC) 是一类模拟生物进化现象和群体智能行为的元启发式优化算法,通过模拟遗传、变异、自然选择及群体竞争合作机制,不断迭代搜索问题的最优解或近似最优解^[1-3]。与传统优化算法相比,EC 具有全局搜索能力强、适应性强、不依赖精确数学模型等特点,已在诸多实际优化问题中展现出卓越性能^[4-6]。

传统 EC 通常设计以求解独立存在的优化问题。然而,实际应用中的优化问题通常存在一些相似或相关问题,在求解优化问题过程中产生的知识可用于辅助求解其他相关优化问题^[7-9]。此类多任务优化问题 (MultiTask Optimization Problem, MTOP) 的涌现^[10-12],亟待设计高效算法,以同时求解多个相关优化任务。与传统单任务优化相比,MTOP 因需同步处理多任务而具有更高复杂度。

对此,研究人员提出了 EC 领域的一个新兴研究方向,称为进化多任务优化 (Evolutionary Multi-Task Optimization, EMTO)^[13-15],旨在运用求解相关优化任务过程中产生的可迁移知识,设计高效 EC 算法,对多个优化任务进行同步且有效地求解。近年来,EMTO 研究取得了长足的发展。图 1 展示了自 2016 年 EMTO 概念提出以来^[16]至 2025 年 4 月,三种主流学术数据库 Google Scholar、Web of Science 和 IEEE Xplore 上 EMTO 相关研究论文发表数量统计结果。其中,在 Google Scholar 数据库上的搜索关键词为“multitask optimization” OR “multi-task optimization” OR “evolutionary multitasking”,在 Web of Science 数据库上的搜索关键词为“multitask optimization” (Topic) OR “multi-task optimization” (Topic) OR “evolutionary multitasking” (Topic),而在 IEEE Xplore 数据库上的搜索关键词为 (“All Metadata”: “multitask optimization”) OR (“All Metadata”: “multi-task optimization”) OR (“All Metadata”: “evolutionary multi-

tasking”)。其中图 1 左侧坐标轴对应 Google Scholar 数据库中 EMTO 相关论文数量,而右侧坐标轴对应 Web of Science 和 IEEE Xplore 数据库中 EMTO 相关论文数量。从图 1 中数据可看出,自 2016 年以来,EMTO 相关研究逐年快速增加。尤其是从 2021 年至今,相关研究激增,EMTO 已成为进化计算和人工智能领域的研究热点。

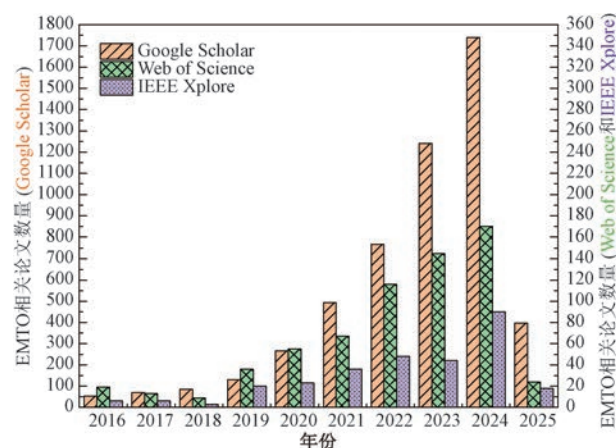


图 1 自 2016 年至 2025 年 EMTO 相关研究发表数量

为了使 EC 算法高效求解多个任务,现有 EMTO 研究主要通过利用不同任务的知识提升算法性能,具体包括知识选择、知识迁移和知识运用三个方面。本文对现有 EMTO 研究分类总结如图 2 所示。

图 2 将 EMTO 的研究按照 what 和 how 的两个基本问题分为两个角度。首先是 what 的角度,在进行知识选择、知识迁移和知识学习的时候,需要考虑选择、迁移或运用何种知识 (what kind of knowledge) 的基本问题,就是 what 的问题。现有的 EMTO 研究在何种知识方面主要包括解知识^[16]、元知识^[17]、参数知识^[18]与分布知识^[19]。

其次是 how 的角度,知识选择、知识迁移和知识运用需要考虑如何处理这些知识的问题 (how to deal with the knowledge),也就是 how 的问题。具体包括以下三点:第一,如何从源任务中选择出有效的知识? 第二,如何将知识从源任务空间迁移到目标任务空间? 第三,如何运用知识以高效求解目标任务?

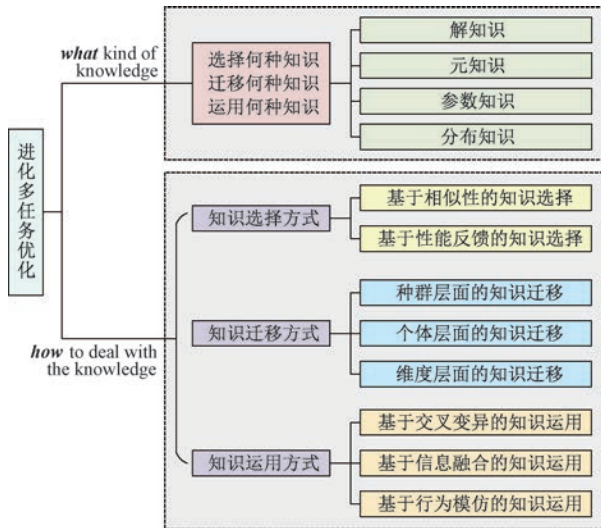


图2 现有EMTO研究分类

本综述以知识处理方法(how问题)角度为主线梳理文献,同时分析其与知识内容类型(what问题)角度的交互关系。为了更直观地反映EMTO在how角度的三个研究方向(即知识选择、知识迁移和知识运用)上研究论文的变化和趋势,图3展示了Google Scholar数据库中,EMTO的以上三个研究方向自2016年至2025年4月间发表论文情况。




图3 EMTO各研究方向各年发表论文情况

鉴于进化多任务优化的快速发展,对相关研究进行综述愈显重要。虽然目前已有一些EMTO相关研究的综述^[20-22],但这些综述集中于针对EMTO算法的应用场景进行描述,或按技术手段对EMTO中策略进行分散讨论,没有深入针对近年研究中EMTO算法设计和运行过程中的主要组件进行系统性的分析和总结,存在局限性。

因此,本文针对现有的EMTO研究进行系统性地综述,从知识选择、知识迁移和知识运用这三个研究方向全面阐述EMTO的研究前沿。如图2所

示,首先,在知识选择方面,本文将知识选择策略分为基于相似性的和基于性能反馈的知识选择进行阐述。其次,在知识迁移方面,本文将知识迁移策略分为种群层面、个体层面和维度层面的知识迁移进行阐述。最后,在知识运用方面,本文将知识运用策略分为基于交叉变异的、基于信息融合的和基于行为模仿的知识运用进行阐述。在分析现有EMTO研究后,本文将对EMTO领域的未来研究方向进行讨论和展望。本文通过知识选择、知识迁移和知识运用三阶段流程整合研究进展,揭示了EMTO各环节的内在逻辑关联,为EMTO算法设计提供了更清晰的脉络。这一结构化的综述模式显著区别于现有文献,弥补了对EMTO系统性综述的不足。

基于图2的EMTO的研究分类,由于文献众多,本文在综述分析过程中,重点考虑IEEE Transactions系列的顶尖国际学术期刊论文。具体地,首先从IEEE Xplore数据库中采用搜索关键词(“All Metadata”: “multitask optimization”) OR (“All Metadata”: “multi-task optimization”) OR (“All Metadata”: “evolutionary multitasking”)进行检索自2016年以来的所有EMTO文献,共计得到327篇相关文章。然后筛选出了其中发表在IEEE Transactions系列汇刊上的国际期刊文献共计113篇。本文的核心议题是进化多任务优化中的知识选择、知识迁移和知识运用的相关研究综述,因此对于研究领域重复、低质量或与研究方向偏离较远的论文予以剔除,并通过通读文献从中选择了56篇相关文献进行综述介绍,确保收录领域内高质量、经过同行评议的文献。此外,本文还从IEEE Transactions以外的一些重点国际期刊和会议论文中筛选一些引用较高的、与知识选择、知识迁移、知识运用等EMTO领域关键研究方向相关的学术论文共计25篇进行综述介绍,以期对知识选择、知识迁移和知识运用等EMTO领域关键研究方向进行系统性的分析和总结。

本文结构总结如下:首先,第2节介绍进化多任务优化的研究背景和多任务优化问题模型。第3节介绍知识选择方面的研究现状。第4节介绍知识迁移方面的研究现状。第5节介绍知识运用方面的研究现状。第6节对未来潜在研究方向进行讨论。最后,第7节对全文进行总结。

2 进化多任务优化

2.1 多任务优化问题与进化多任务优化

一个MTOP中包含了多个优化任务,其中每个

优化任务都是一个可以独立求解的优化问题。具有 M 个优化任务的 MTOP 表示如下:

$$x_i = \operatorname{argmin}(f_i(X_i)), i = 1, 2, 3, \dots, M \quad (1)$$

其中, $f_i(\cdot)$ 和 X_i 分别代表第 i 个优化任务的目标函数和搜索空间, x_i 代表优化得到第 i 个任务的最优解。任务数大于 3 ($M > 3$) 的 MTOP 称为超多任务优化问题 (Many-Task Optimization Problem, MaTOP)。根据 MTOP 中优化任务的特性, 也就是目标函数 $f_i(\cdot)$ 的特点, 除了超多任务优化外, EMTO 领域还包含其他一些重要研究分支, 如多目标多任务优化^[23]、多峰多任务优化^[24] 和大规模多任务优化^[25] 等, 也是本文综述的对象。

EMTO 算法的设计目的旨在高效求解 MTOP。EMTO 的灵感来源于人类大脑对多个相关任务的同时处理能力, 旨在利用 EC 算法合理发现和运用相互关联的优化任务中的可迁移知识, 实现对 MTOP 的高效求解^[26-27]。在 EMTO 算法中的知识选择、知识迁移和知识运用的流程框架如图 4 所示。知识选择是 EMTO 的首要环节, 其核心在于从源任务中选择高质量知识。知识迁移是将选定的知识从源任务映射到目标任务的过程, 通常需要解决跨任务间的非线性关系建模问题。知识运用是 EMTO 的最后一步, 其目标是将迁移后的知识有效地融入目标任务的优化过程。首先, 在知识选择阶段对源任务集合 $\{T_1, T_2, \dots, T_M\}$ 中存在的潜在知识 (可以是解知识、元知识、参数知识、分布知识等) 进行选择, 得到其中对目标任务 T_i 有效且可迁移的知识。之后, 知识迁移阶段根据源任务空间和目标任务空间的差异性, 将获取到的知识转化成适用于目标任务空间的知识。在知识运用阶段, 目标任

务自身知识和从源任务中获取的知识将结合并帮助目标任务生成下一代种群。

2.2 进化多任务优化中的知识

现有的 EMTO 研究在知识选择方面主要集中在四种类型的知识: 解知识^[16]、元知识^[17]、参数知识^[18] 与分布知识^[19]。这些知识类型在 EMTO 算法中扮演着不同的角色, 共同促进多任务优化问题的高效解决。

首先, 解知识是 EMTO 中最基础的知识类型, 它主要指将源任务中找到的较优解作为知识。解知识不仅可以包括最优解的具体数值, 还可以包括解在搜索空间中的位置信息。例如, 在一些 EMTO 算法中, 源任务中被选中的优质解会被迁移到目标任务空间中, 通过与目标任务的个体进行交叉和变异等进化操作, 实现解知识的选择、迁移和运用^[15, 28]。这种策略能有效利用源任务中的优质解, 加速目标任务优化过程。

其次, 元知识是对知识的进一步抽象, 即“如何找到最优解”的知识^[17]。元知识可理解为一系列策略、方法和规律, 帮助算法在搜索过程中有效地找到最优解。例如, 元知识可能包括如何选择初始种群、如何调整进化参数、如何评估解质量等。通过迁移元知识, EMTO 算法能够在不同的任务之间共享优化经验和策略, 从而提高整体的优化效率。

第三, 参数知识涉及算法在进化过程中的特定参数设置^[18]。这些参数包括交叉率、变异率、选择压力等, 它们对算法的性能有着直接的影响。在 EMTO 中, 参数知识的迁移可以帮助算法在不同任务之间共享成功的参数设置, 避免在每个任务上重新调整参数的开销。源任务进化过程中产生的历史成功交叉率和变异率等参数设置可以被迁移到目标任务中, 从而加快目标任务的收敛速度。

最后, 分布知识关注的是种群在搜索空间中的分布情况和模式^[19], 包括种群的中心位置、分布范围、协方差特征等。通过分析和迁移分布知识, EMTO 算法可以更好地理解种群在不同任务中的搜索行为, 从而优化种群的分布, 提高搜索效率。例如, 源任务种群分布的均值和协方差特征可以被用来指导目标任务的种群初始化和进化过程, 使得目标任务的搜索更加高效。

综上所述, 解知识、元知识、参数知识和分布知识构成了 EMTO 算法中知识的四个重要方面。通过合理地选择和迁移这些知识, EMTO 算法能够更有效地解决多任务优化问题, 提高优化过程的效率

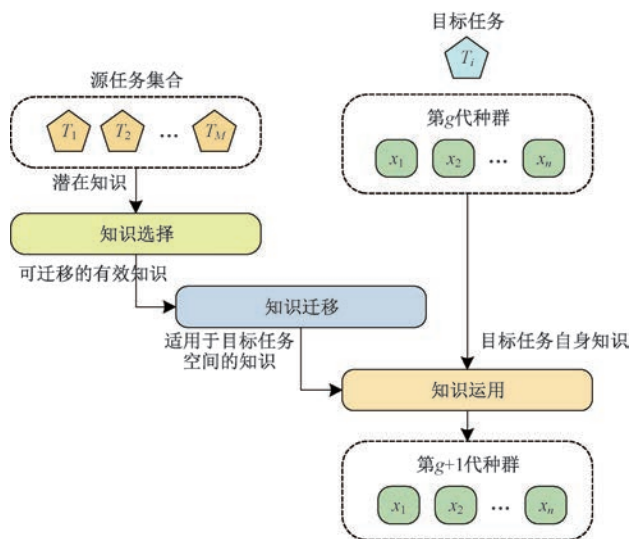


图 4 知识选择、知识迁移和知识运用的 EMTO 框架

和效果。

3 知识选择

在 EMTO 中,知识选择指根据源任务和目标任务之间的相似性或性能反馈,从源任务中选择适当知识的过程。现有知识选择策略主要分为基于相似性的知识选择策略和基于性能反馈的知识选择策略。通过合理选择有效知识,EMTO 算法能够更好地利用任务间的潜在关联性,从而实现更高效的优化。

3.1 基于相似性的知识选择

基于相似性的知识选择策略的主要思想是通过评估任务之间的相似性,并基于相似性选择适当的知识来指导目标任务的优化。若源任务与目标任务在某些方面具有较高相似性,则其间可共享的知识通常也更具相关性,因而能够更有效地利用相关知识提高优化的效率和性能^[29-31]。因此,相似性度量是 EMTO 算法设计中的关键组成部分,此类策略通常倾向于选取与目标任务更相似的知识作为迁移对象。基于相似性的知识选择策略通过对当前目标任务与不同知识源之间的相似性进行评估,从与当前目标任务相似程度最高的知识源选择知识。如图 5 所示,实线箭头所指的知识源与当前目标任务相似性最高因而被选中用于为目标任务提供知识,而虚线所指的知识源未被选择。




图 5 基于相似性的知识选择框架

针对 EMTO 中基于相似性的知识选择问题,一些研究提出从相似任务和相似种群中进行知识选择。这些选择相似任务和相似种群的知识选择研究大多集中于求解 MaTOP,这是因为在 MaTOP 中,随着任务数量的增加,任务之间的相似性会降低,因而选择更为相似的任务和种群至关重要。例如,Chen 等^[32]引入了 KL 散度(Kullback-Leibler di-

vergence),通过分析两两任务的种群分布相似性间接评估任务间相似性,并提出了一种基于自适应存档的多任务进化算法(Many-Task Evolutionary Algorithm, MaTEA)。本节以 MaTEA 中的知识选择过程为例,以清晰具体地描述知识选择的一般过程:首先, MaTEA 记录分属不同任务种群的分布信息,并基于 KL 散度计算其余各种群与目标任务种群分布间的相似性。KL 散度值越小,表明任务间分布相似性越高。此外, MaTEA 设计了一种自适应奖励策略,借鉴强化学习的反馈学习方法,通过对以往的知识选择操作所造成的性能反馈进行分析,结合 KL 散度计算的任务间相似性,计算选择不同任务作为源任务的概率。最后,通过轮盘赌选择机制,从各任务中筛选最合适的知识源。由于搜索空间不同,不同任务通常具有不同的维度,而 KL 散度仅能用于评估部分维度间的相似性。例如,当用于评估两个维度分别为 D_1 和 D_2 的任务间相似性时,如果 $D_1 < D_2$,那么 KL 散度仅计算两个任务前 D_1 维的相似性,存在一定精度不足。

在评估任务间相似性方面, Hou 等^[33]基于 MaTEA 框架提出了一种基于双空间相似性的多任务差分进化算法(Many-Task Differential Evolutionary based on Bi-Space Similarity, MaTDE-BSS)。MaTDE-BSS 引入了一种双空间相似性评估标准,旨在同时考虑任务在决策空间及目标空间中的相似性,以满足精准评估任务相似性的需求。Qiu 等^[34]采用协方差矩阵分布情况之间的差值评估任务间相似性,并使用不同任务个体中心位置之间的距离评估任务之间差异性,从而选择出相似源任务。Xu 等^[35]设计了一种基于相似性的任务选择策略,通过分析种群分布信息来评估任务间相似性,并将提出的算法在多态复杂系统的选择性维护问题上进行验证,说明了其优越的应用前景。Gao 等^[24]面向多峰 MTOP,设计了一种基于进化路径的相似性度量策略来测量不同任务的子群体之间的潜在相似性,并引入子群体交叉匹配策略来选择与当前任务匹配的子群体中的解作为知识源。

针对个体层面相似性选择的关键问题, Wang 等^[36]设计了一种基于异常检测模型的个体选择机制,通过拟合目标任务种群对应的多元高斯分布,并基于该分布,评估属于其他任务的所有个体的异常程度,从而选择那些异常程度最低个体的解知识作为知识源。同时,基于上述机制提出了基于异常检测的多任务进化算法(MultiTask Evolutionary Al-

gorithm based on Anomaly Detection, MTEA-AD)。实验结果表明,无论是在求解 MTOP 还是 MaTOP 方面,MTEA-AD 都实现了优异的性能。Wang 等^[37]提出了一种基于置信度下界的个体选择策略,通过迁移高斯过程模型分析源任务和目标任务解分布信息,并计算每个待迁移个体的置信度下界值。其中,具有较低置信度下界值的个体被视为是目标任务的相似个体从而被选择。

针对相似性度量准确性问题,Jiang 等^[38]发现任务间的相似性存在多种不同类型,而已有研究仅采用了单一的相似性度量方式,难以实现对任务间相似性的准确评估。为解决上述问题,Jiang 等讨论了四种不同的任务相似性类型,并提出了基于双目标知识迁移(Bi-objective Knowledge Transfer, BoKT)框架,通过从领域相似性和形状相似性两个方面对任务间相似性实现精准评估,从而选择那些更为相似的任务作为知识源,为目标任务提供解层面的知识。实验结果表明,基于 BoKT 框架设计的差分进化算法与遗传算法均能对相似任务的精确选择,从而在求解 MaTOP 方面取得了比对比算法更好的性能。同时,BoKT 的性能也在实际应用中的平面机械臂控制多任务优化问题上进行验证,实验结果表明 BoKT 在 87.5% 的测试样例中取得了优于对比算法的结果。

3.2 基于性能反馈的知识选择

在知识尚未迁移与应用前,其他任务的知识对目标任务是否有效尚不可知。虽然那些与目标任务更为相似的知识潜在有效性更好,但一些并不相似的知识也能辅助目标任务高效优化。基于上述考虑,一些现有研究提出了基于性能反馈的知识选择策略。基于性能反馈的知识选择框架如图 6 所示。基于性能反馈的知识选择策略的主要方法是从不同知识源获取知识,并根据不同知识所带来的性能反馈决定后续由哪些知识源提供知识。

针对如何选择高质量知识的问题,一些现有研究提出在任务层面基于性能反馈的知识选择策略,旨在选取那些对性能提升最大的任务作为知识源。例如,Wu 等^[39]设计了一种多源知识获取策略以及双反馈自适应机制来从不同任务中选择知识,并基于此提出了一种带有进化状态估计器的多任务反馈优化算法。在知识表示方面,多源知识获取策略将个体的进化方向作为知识,而非现有研究常用的个体位置知识。该策略还引入了置信系数和迁移密度两个额外参数,分别控制从源任务中选择知识的比




图6 基于性能反馈的知识选择框架

例和目标任务中个体获得知识的比例。而双反馈自适应机制则根据从源任务中选择的知识对于目标任务的贡献度,动态自适应地调整从不同源任务中选择知识的比例。Han 等^[40]提出了一种采用动态按需分配策略的多任务粒子群优化,通过对历史信息性能反馈,以对不同任务的复杂度进行分析,实现计算资源在不同任务间的动态分配。实验结果表明,在与其他三种 EMTO 算法的对比中,无论是求解单目标还是多目标的 MTOPs,基于动态按需分配策略的多任务粒子群优化算法实现了更为高效的性能。

同时,一些研究提出在个体层面进行基于性能反馈的知识选择。例如,Liaw 等^[41]提出了一种基于共生生物群落进化(Evolution of Biocoenosis through Symbiosis, EBS)的 EMTO 框架。EBS 框架首先将目标任务以外的所有任务中的个体聚集起来,为每个目标任务赋予一个概率,并根据该概率决定是否从其他任务获取知识。如果选择从其他任务获取知识,则随机选择个体转移到当前种群中,并根据这些个体在目标任务中的性能自适应调节概率。

Xu 等^[42]提出了一种自适应进化多任务优化框架(Adaptive EMTO, AEMTO)。在知识选择方面,AEMTO 引入了源任务选择概率自适应技术,赋予所有任务一个选择概率值,并基于该概率,从除目标任务外的其余 $T-1$ 个任务中选择个体,迁移并运用于当前目标任务以生成子代。同时,基于生成子代的适应值自适应调整每个任务的选择概率。在实验中,AEMTO 与三种先进 EMTO 算法进行了比较,包括基于相似性知识选择的代表性算法 MaTEA。实验结果表明,AEMTO 在求解基准测试集中的 MTOP 和 MaTOP,甚至在求解实际应用中具有 2000 个任务的超多任务平面机械臂控制问

题上都取得了优异的性能。通过与 MaTEA 的对比,说明了在任务间相似性不明显但存在潜在相关性的情况下,基于性能反馈的策略相比基于相似性的知识选择策略更具优势。

3.3 分析与总结

在 EMTO 中,知识选择是实现高效优化的重要手段。基于相似性的知识选择策略通过评估任务之间的相似性,选择与目标任务最相似的知识来指导优化过程。通过选择与目标任务相似的知识,这种策略能够充分利用任务之间的关联性,从而提升优化效率和性能。此外,相对于基于性能反馈的知识选择,基于相似性的知识选择无需消耗额外的评估和反应时间,有助于知识在目标任务上的快速起效。然而,基于相似性的知识选择策略依赖于相似性度量方法,如果度量方法不准确,可能会影响知识选择的效果。对此,Jiang 等^[38]提出的 BoKT 从领域相似性和形状相似性两个方面对任务间相似性实现了精准评估,为后续研究提供了有价值的解决方案。

基于性能反馈的知识选择策略通过监测知识选择的实际效果,根据性能反馈动态调整知识选择,从而更灵活地适应不同任务的需求。在任务数量多或任务间相似性低时,这种策略能够发现虽然不相似但对优化有帮助的知识,从而提高整体优化效果。然而,基于性能反馈的知识选择策略也存在一些不足。在知识迁移初期,因缺乏反馈,所选知识或不适用于目标任务,易导致初期性能波动。此外,由于依赖性能反馈,在反馈延迟或评估存在偏差时,其对知识选择的准确性和有效性会受到影响。此外,该策略需监测并评估各知识源反馈,可能引入额外计算开销。

4 知识迁移

EMTO 中的知识迁移是指将知识从源任务空间迁移到目标任务空间的过程。本文梳理相关研究后,将现有的知识迁移策略归纳为种群层面的知识迁移策略、个体层面的知识迁移策略以及维度层面的知识迁移策略等三个层面,遵循知识迁移所在层面从宏观到微观的递进原则,以明确区分不同迁移策略的核心差异,体现策略的互补性。在知识迁移过程中,由于源任务和目标任务通常处于不同的决策空间,因此知识迁移通常需要对知识进行操作,以适应目标任务空间。

4.1 种群层面的知识迁移

种群层面的知识迁移策略中通常采用多个种群分别求解多个任务,即每个种群负责一个任务的求解^[43-45]。种群层面的知识迁移框架如图 7 所示,由于不同任务对应的种群分处不同的搜索空间中,为了在种群间进行知识迁移,种群层面的知识迁移策略通常会采取平移或映射等操作将源任务空间的知识迁移到目标任务空间。




图 7 基于种群层面的知识迁移框架

例如,Feng 等^[28]提出了一种通过显式自编码器的进化多任务算法(Evolutionary Multitasking via Explicit Autoencoding, EMEA)。作为知识迁移中具有先驱性的工作,本文以 EMEA 为例,具体说明知识迁移过程:EMEA 通过多个种群分别求解处于多个不同搜索空间中的任务。针对如何在不同空间的两两种群间知识迁移问题,EMEA 首次提出采用线性自编码器学习从源任务空间到目标任务空间的映射关系,将源任务空间的个体映射到目标任务空间,实现知识在不同种群间的迁移。首先,EMEA 维护一个线性自编码器,通过线性矩阵运算将源任务空间的个体特征映射至低维子空间;之后,自编码器将低维子空间中的特征重构为目标任务空间的个体,从而建立跨任务知识迁移,最后实现源任务个体和目标任务个体之间的交配过程以生成子代个体。实验结果表明,EMEA 在求解单目标或多目标的 MTOP 上比对比算法更为精准。

基于 EMEA 方法和框架,一些工作进行了更为深入的研究。例如,Feng 等^[15]将 EMEA 的方法应用于求解多任务车辆路由问题,取得了优越的性能。Huang 等^[25]提出了基于岛屿模型的进化多任务框架,其中采用显式映射和隐式交叉结合的方式实现跨种群的知识迁移,实现了对于大规模 MTOP 的高效求解。Zhou 等^[9]发现原始 EMEA 中采用的线性自编码器难以拟合某些任务之间的非线性映射关系,从而提出了一种基于内核化自编码器的进化搜索框架,通过自适应选择线性的或非线性的自编码器,实现在不同任务间的高效知识迁移。实验结果表明,采用内核化自编码器相比于采用线性自编码

器的 EMTO 算法取得了更为优异的性能。

除了 EMEA 框架外,一些现有研究还提出了其他基于映射的知识迁移策略。例如,Tang 等^[19]提出了一种基于对齐子空间连续性迁移策略的多因子差分进化算法,通过主成分分析法将源任务的知识映射到一个对齐的低维度子空间中,并将子空间中的知识映射回到目标任务空间中,以实现在目标任务空间中的知识迁移。而在考虑到从源任务空间映射到对齐子空间,再映射到目标任务空间中的过程会破坏知识结构的问题,Jiang 等^[46]提出了一种基于知识结构保留的进化算法,通过在映射过程中保留知识的局部结构,实现在不同搜索空间的知识迁移过程中的知识结构保留,保证了知识的质量。

针对源任务种群和目标任务种群分别处于不同区域的问题,一些研究采用平移的方式使两两种群更为接近,以实现更为有效的知识迁移。例如,Wu 等^[47]提出了一种多任务遗传算法,通过计算两种群中心点之间的偏差值,将源任务种群平移到目标任务种群的中心位置,以消除两两种群间的偏差,以方便进行知识迁移。Li 等^[17]提出了一种基于元知识迁移的差分进化算法(Meta-Knowledge Transfer-based Differential Evolution, MKTDE),旨在迁移求解 MTOP 过程中产生的元知识,即任务过程中产生的成功进化模式的知识。MKTDE 的元知识迁移策略首先计算源任务和目标任务种群的种群中心值,随后基于该中心值将源任务种群平移到目标任务种群所在区域,并基于合并后的种群来生成子代个体。在实验中,MKTDE 与 EMEA 等七种基于映射或基于平移的知识迁移方法进行了全面的对比实验。实验结果表明,MKTDE 在 69.1% 的测试任务上取得了比对比算法更为优秀的性能。而在与基于映射的知识迁移代表算法 EMEA 的对比中,MKTDE 在 18 个测试任务中的 13 个任务中都取得了比 EMEA 更精确的求解性能。

4.2 个体层面的知识迁移

个体层面的知识迁移策略通常采用一个单独种群求解多个任务,种群中的不同个体分属不同的优化任务^[48-50],通过交叉变异等进化操作实现在分属不同优化任务的个体间知识迁移。同时,这些个体的维度通常设置为所求 MTOP 中任务的最大维度,使得所有个体具有相同维度,以方便个体间的知识迁移。个体层面的知识迁移框架如图 8 所示,源任务将个体知识通过交叉变异等操作迁移到目标任务空间中。




图 8 基于个体层面的知识迁移框架

现有的个体层面的知识迁移策略大多基于多因子优化(MultiFactorial Optimization, MFO)框架进行。MFO 的概念由 Gupta 等^[16]首先提出,并基于 MFO 框架提出了多因子进化算法(MultiFactorial Evolutionary Algorithm, MFEA)。在个体层面,MFO 通过单个种群求解 MTOP,并为每个个体分配对应的技能因子,用于标识个体对应的优化任务。种群中所有个体采用统一维度 D_{max} ,其中 D_{max} 为所有任务的最大维度值。每个个体还被赋予了因子代价、因子排名和标量适应度等三项额外指标,以公平地实现属于不同任务的个体互相比。同时,个体层面的知识迁移通过选择性交配实现,允许不同任务的个体之间基于概率参数 rpm 进行交配并产生子代个体。

基于 MFO 和 MFEA 的概念和方法,一些工作进行了更为深入的研究。例如,Zhou 等^[51]提出了一种具有自适应知识迁移的 MFEA(MFEA with Adaptive Knowledge Transfer, MFEA-AKT),其中嵌入了多种具有不同功能的交叉操作,并根据这些操作的性能,自适应地选择效果最好的操作以在不同个体间高效迁移知识。实验结果表明,MFEA-AKT 在求解 MTOP 上表现出优越的性能。Mai 等^[52]将支持向量机嵌入 MFEA,提出了一种基于机器学习的演化多任务优化框架。在知识迁移方面,该框架利用支持向量机学习个体与技能因子之间的对应关系,通过训练后的支持向量机从源任务中自动选择个体进行迁移。Bali 等^[53]提出了 MFEA-II 算法,将概率参数 rpm 用矩阵表示,并在进化过程中在线更新 rpm 矩阵,实现了对 MFEA 的拓展。此外,Gupta 等^[54]还将 MFEA 拓展到求解多目标 MTOP 领域,提出了 MO-MFEA 算法。一些研究基于 MO-MFEA 提出了许多 EMTO 算法用于求解多目标 MTOP,如基于两阶段选择性交配的 MO-MFEA^[55]和 MO-MFEA-II^[56]等。

基于个体层面知识迁移的 EMTO 算法在求解其他类型复杂优化问题上也具有应用价值。例如,在求解昂贵多峰优化问题上,Ji 等^[57]提出了一种基

于迁移的多任务小生境粒子群优化(Transfer-based Multitasking niche Particle Swarm Optimization, TMPSTO)算法,通过将昂贵多峰优化问题转化为 MTOP,并设计基于 MFO 框架的粒子群优化算法,实现知识在个体层面的高效迁移,为求解昂贵多峰优化问题提供了新型高效求解框架。实验结果表明,TMPSTO 算法与针对昂贵多峰优化的先进算法相比,在求解精度方面总体更具优势。

4.3 维度层面的知识迁移

维度层面的知识迁移策略是一类新兴的知识迁移策略,其通常需要对任务或者个体的维度重新排序,或是将个体划分为若干低维度变量块,形成可迁移单元,使得知识能够在那些更为相关的、迁移效果更好的维度之间进行迁移。通过维度层面的知识迁移,知识可以在不同任务的不同维度之间进行迁移。维度层面的知识迁移框架如图 9 所示。

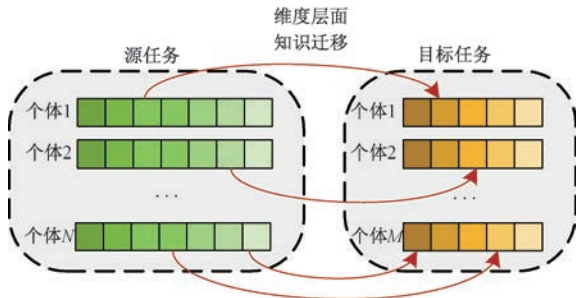


图 9 基于维度层面的知识迁移框架

维度层面的知识迁移策略在解决 MTOP 方面展现出显著的潜力,一些新兴的 EMTO 算法采用了这一策略并取得了优异的性能。例如,Jiang 等^[58]提出了基于积木块层面知识迁移的差分进化算法(Block-Level Knowledge Transfer-based Differential Evolution, BLKT-DE)。该算法核心在于将由大量维度组成的个体切分为多个由少量维度组成的积木块,并以积木块作为知识运用中的主要单元。首先,BLKT-DE 对分属不同任务的所有个体进行维度切分,将每个个体划分为若干连续维度构成的积木块。具体而言,一个 D 维个体可划分为 $\lceil D/K \rceil$ 个长度为 K 维的积木块,因此具有 M 个个体的种群在 BLKT-DE 中可以得到 $M \cdot \lceil D/K \rceil$ 个积木块。之后,BLKT-DE 将所有积木块集合到同一个种群中,并采用聚类方法将相似积木块划分到相同子种群中,确保知识能够在相似积木块之间进行迁移,以提高知识迁移的效果。最后,通过对积木块进行交叉和变异等操作,生成子代积木块,并将子代积木块重新重组成为新的个体,实现了知识在维

度层面的高效迁移。在实验中,BLKT-DE 与现有的四种分别在种群层面和个体层面进行知识迁移的 EMTO 算法在 CEC2017 以及 CEC2022 等两个标准测试集中的 19 个 MTOPs 上进行了对比实验。实验结果显示,BLKT-DE 表现出色:在与两种基于种群层面知识迁移的 EMTO 算法(即 EMEA^[15] 和 ASCMFDE^[19])的比较中,BLKT-DE 在 90.8% 的测试问题上取得了比对比算法优秀或相当的性能;而在与另外两种基于个体层面知识迁移的 EMTO 算法(即 MFEA-AKT^[51] 和 MFEA-II^[53])的比较中,BLKT-DE 在 82.9% 的测试问题上取得了比对比算法优秀或相当的性能,表明了积木块层面知识迁移的方法在相似但非对齐维度之间进行知识迁移的有效性。

基于 BLKT-DE 中对个体划分积木块的想法,Xue 等^[59]提出了一种多级多段学习多任务优化(Multi-level and Multi-segment Learning Multi-task Optimization, MMLMTO)算法。与 BLKT-DE 类似,MMLMTO 算法将候选个体分割成多个非重叠段,每个段对应连续的若干维度。然后将目标任务中的段与源任务的相似段进行匹配,形成子种群进行知识迁移。实验结果表明,MMLMTO 在 IEEE CEC2017 和 IEEE CEC2022 多任务基准测试中表现优异,优于或至少与其他分别在种群层面和个体层面进行知识迁移的 EMTO 算法相当。

针对如何将属于不同任务的相似维度配对的问题,Wu 等^[60]提出了一种基于正交迁移的多任务优化算法(Orthogonal Transfer-based MultiTask Optimization, OTMTO)。首先,由于源任务和目标任务通常具有不同的维度,OTMTO 提出了一种跨任务映射策略,以满足知识在异构空间中的迁移需求。其次,针对相似维度配对问题,OTMTO 设计了正交迁移策略,对跨任务映射后的源任务个体维度和目标任务中的维度进行配对优化,寻找出两者之间的最佳维度配对。实验结果表明,OTMTO 在求解具有异构任务的多任务优化问题上表现出色。Ma 等^[61]提出了一种双层迁移学习算法,其中顶层迁移学习通过个体间的交叉和精英个体学习来实现,而底层迁移学习通过跨维度优化策略实现知识在不同维度间的高效迁移。

4.4 分析与总结

EMTO 中的知识迁移旨在将源任务空间的有效知识映射至目标任务空间以提升优化效率。种群层面的知识迁移策略通过映射和平移技术,实现了

不同任务间的知识迁移。在这种策略中,每个种群独立解决不同任务,并通过映射和平移技术,在不同任务空间之间灵活进行知识映射,从而促进知识迁移。然而,通过显式映射/平移实现跨任务全局优化,但依赖任务间线性关系假设,对于复杂任务之间的非线性关系,映射操作可能较为复杂,增加了计算负担。同时,平移策略依赖于正确计算种群中心,对种群中心的有偏估计可能影响迁移效果。

在个体层面的知识迁移策略中,通常采用单一种群来解决多个任务,通过交叉变异等进化操作,实现不同任务个体间知识迁移。这种方法通过单种群解决多个任务,并为每个个体根据技能因子分配任务,从而实现对不同任务需求的灵活适应。然而,由于所有个体统一置于单一种群中,需采用最大维度统一编码,这将导致低维任务个体出现冗余维度,从而增加计算负担。

维度层面的知识迁移策略通过对任务或个体的维度进行重新排序或切分,使得知识在更相关维度间进行迁移。相对于种群或个体层面的知识迁移,维度层面的知识迁移策略具有更高的迁移效率。在现有研究中,该策略可以根据不同任务的特点,自适应地选择合适的维度进行知识迁移。因此,针对种群层面和个体层面的知识迁移策略,BLKT-DE^[58]和 OTMTO^[60]在维度层面进行知识迁移是更为有效的解决方案。

5 知识运用

EMTO 中的知识运用是指在目标任务内运用知识的过程。现有的知识运用策略包含基于交叉变异的知识运用策略、基于信息融合的知识运用策略以及基于行为模仿的知识运用策略。知识运用策略直接影响运用知识的有效性和生成子代的质量,因此知识运用是 EMTO 的重点研究方面之一。

5.1 基于交叉变异的知识运用

基于交叉变异的知识运用策略是一种较为初级的知识运用方式,通过在源任务个体和目标任务个体之间直接进行交叉和变异等进化操作,生成新的目标任务个体,以实现知识运用。基于交叉变异的知识运用策略框架如图 10 所示,该策略通过源任务个体与目标任务个体的交叉与变异操作,生成目标任务的新一代个体,从而实现知识的有效运用。

现有研究主要通过源任务个体和目标任务个体之间的交叉、变异等操作生成目标任务新一代子个




图 10 基于交叉变异的知识运用框架

体。例如, Lin 等^[62]提出了一种基于高效迁移的进化多任务优化算法,通过判断源任务个体位置与以往世代中优质个体之间的距离,选择优质的个体位置知识,并运用源任务的个体和目标任务个体之间的交叉变异生成子代个体。Tang 等^[63]提出了一种基于测地流的多因子差分进化算法(Geodesic Flow-based MultiFactorial Differential Evolution, GFMFDE)。在基于交叉变异的知识运用方面, GFMFDE 设计了多种不同的变异操作,实现从中间坐标系和原始坐标系等不同空间中的知识运用,以运用源任务中的解知识生成新个体。Chen 等^[64]提出了使用迁移排名和 KNN 模型的多目标多任务优化算法(Multiobjective Multitask Optimization algorithm using Transfer rank and a KNN model, MMOTK)。在基于交叉变异的知识运用方面, MMOTK 首先利用历史迁移解集合计算迁移排名,通过 KNN 模型对解进行分类,从而选择正迁移区域内的解进行交叉变异操作,生成下一代种群,有效提高了子代质量和种群多样性。Han 等^[65]提出了自适应多任务粒子群优化算法,在知识运用方面实现了对粒子更新模式的自适应控制,根据源任务中的粒子位置知识来辅助更新目标任务中粒子的速度和位置。Liang 等^[66]提出了基于自适应差分进化的多目标多因子进化算法(Multi-Objective MFEA based on Self-Adaptive Differential Evolution, MOMFEA-SADE)。在知识运用方面, MOMFEA-SADE 通过从多种不同的变异操作中自适应选择最合适的算子,实现对源任务个体和目标任务个体的自适应高效配对,以结合和运用源任务和目标任务中的解知识,生成更为优秀的子代个体。实验结果表明, MOMFEA-SADE 在求解多目标 MTOP 上性能显著,并取得了 2019 年 CEC 进化多任务优化竞赛的冠军。

5.2 基于信息融合的知识运用

基于信息融合的知识运用通过将源任务种群与

目标任务种群进行融合,并利用融合后的种群分布、个体位置等信息辅助目标任务生成新种群。基于信息融合的知识运用策略框架如图 11 所示,在目标任务新种群中,部分个体通过融合源任务和目标任务知识而生成。




图 11 基于信息融合的知识运用框架

在运用融合后的源任务和目标任务种群分布信息辅助目标任务方面,研究者们探索了多种策略和技术。例如,Liang 等^[67]提出了一种基于多源知识迁移的超多任务优化框架(Evolutionary Many-Task Optimization based on Multi-source Knowledge Transfer, EMaTO-MKT)。在知识选择方面,EMaTO-MKT 采用了最大平均差作为任务间相似性度量策略,以从众多任务中挑选出最为相似的任务作为知识源。在知识运用方面,EMaTO-MKT 引入了局部分布估计技术,通过融合源任务与目标任务当前种群的分布情况,结合源任务和目标任务分布知识,生成高斯分布模型,并运用分布知识生成新一代个体。通过从多个源任务学习分布信息,EMaTO 在求解 MaTOP 方面性能出众。

Lai 等^[68]提出了一种基于精英个体迁移的多任务优化算法(MultiTask Optimization algorithm based on Elite individual Transfer, MTOET),其中通过融合当前种群和源任务种群的优秀个体分布情况,构建高斯分布模型,以根据该分布模型生成子代个体,实现对于分布信息的高效运用。通过实验结果的分析,MTOET 相较于现有的十种 EMTO 算法具有更好的收敛效果,展现出卓越的性能。Liang 等^[69]提出了一种基于种群分布的进化多任务算法(Evolutionary MultiTasking algorithm based on Population Distribution, EMT-PD),在求解多目标 MTOP 上表现出色。通过引入基于种群分布的知识提取和运用技术,EMT-PD 能够从种群的概率模型中提取分布知识,通过最大化概率模型的乘

积来指导种群搜索,从而提高了知识运用的有效性。

一些研究运用融合后的源任务和目标任务个体位置信息辅助求解目标任务。例如,Li 等^[17]提出的 MKTDE 通过平移实现对源任务和目标任务中种群的融合,并利用融合种群中的个体位置信息生成子代个体。针对信息融合中存在的源任务和目标任务空间不统一的问题,Tang 等^[19]通过主成分分析技术,将源任务个体映射到子空间,再投影到目标任务空间,以实现在目标空间对源任务空间个体位置的知识运用。

5.3 基于行为模仿的知识运用

基于行为模仿的知识运用通过在目标任务求解过程中,模仿和借鉴求解源任务过程中的成功行为,如参数设置、进化方向等知识,以实现对目标任务的高效辅助求解。基于行为模仿的知识运用策略框架如图 12 所示。




图 12 基于行为模仿的知识运用框架

一些基于行为模仿的知识运用策略通过模仿源任务中的成功参数,并运用在求解目标任务过程中。相关算法展现出非常优秀的性能,具有较大发展潜力。例如,Wu 等^[18]提出了两阶段可迁移的自适应差分进化算法(Two-stage Transferable Adaptive Differential Evolution, TRADE),以通过模仿源任务中优质参数设置,实现高效求解 MaTOP。TRADE 分为两个阶段。在第一阶段,TRADE 提出了任务表示策略和任务分组策略,使用初期演化信息来实现基于移位不变性的相似性度量,以完成对众多优化任务的表示和分组。在 TRADE 的第二阶段引入了成功演化经验迁移策略,通过在相似任务之间迁移成功的参数设定作为参数知识,并应用于求解不同任务的差分进化算法的参数能够自适应调整,显著提高了子代生成的质量和优化效率。实验结果表明,TRADE 中成功演化经验迁移策略能够有效运用参数信息,增强了算法在求解基准测试集和实际应用中 MaTOP 的有效性和适应性。Thang 等^[70]提出自适应多因子进化算法,其中通过

引入基于历史信息的动态参数调整策略,能够在不同任务之间有效迁移参数信息,减少了传统方法中的参数调整困难和负迁移问题。

一些其他知识运用策略通过模仿源任务中的进化方向,并利用这些进化方向指引目标任务进化。例如,Yin 等^[71]提出了跨任务搜索方向增强的多因子进化算法,其中引入了基于搜索方向的知识运用策略,用源任务的差分向量替换目标任务中的差分向量,并将差分向量运用在目标任务精英个体的变异操作中生成子代,加速种群的收敛并增强搜索多样性。Li 等^[72]引入了一种用于多任务的三角合作技术,在利用目标任务中的进化方向的同时也引入了源任务中的进化方向,运用进化方向知识辅助生成子代个体。Li 等^[73]提出了一种包含多种知识类型和迁移自适应策略的 EMTO 框架,面向高效求解多目标 MTOPs。该框架结合并高效运用了基于进化路径模型的知识与基于统一搜索空间的知识。其中,基于进化路径模型的知识运用策略适用于当目标任务和源任务间相似度较低且复杂度较高的情况,而基于统一搜索空间的知识运用适用于当目标任务和源任务间全局最优域较为接近的情况。在实验验证中,包含多种知识类型和迁移自适应策略的 EMTO 算法与六种不同类型的 EMTO 算法进行了比较。实验结果表明,该框架在大多数多目标 MTOP 上取得了更为优秀的性能。

5.4 分析与总结

在 EMTO 算法中,知识运用是在目标任务中运用知识生成子代个体的过程,直接影响到目标任务的子代质量和优化效率。基于交叉变异的知识运用策略通过直接的交叉和变异操作,能够快速实现对源任务知识的运用,适用于多种场景。然而,基于交叉变异的知识运用策略对个体位置的依赖较强,如果源任务个体质量不高,可能会影响目标任务的优化效果。

基于信息融合的知识运用策略通过融合多源任务信息,能够更高效地实现知识迁移。通过融合源任务和目标任务分布信息和个体位置信息,可以增加种群的多样性,从而更高效地实现知识迁移,提高子代生成的质量。然而,其有效性高度依赖源任务与目标任务之间的相似性,若相似性较低,可能导致知识运用效率低下。

基于行为模仿的知识运用策略通过模仿成功行为,自适应调整参数和进化方向,具有较高的适应性和稳定性。通过模仿源任务中的参数设置和进化方

向信息,算法能够自适应调整目标任务的参数和进化方向。因此,Wu 等^[18]运用成功参数设置进行知识运用的策略是未来的研究方向之一,具有较大的发展潜力。

6 应用分析和研究展望

6.1 相关应用分析

EMTO 算法在求解众多实际应用中的复杂优化问题方面已经取得了长足的发展。本节通过对 EMTO 算法在三种具有代表性的应用场景中的研究进行分析,分别为无人系统与集群优化、神经网络架构搜索以及智慧城市应用,以提供对未来研究展望的讨论支撑。




图 13 一个具有两个任务的机械臂控制优化问题示意图

在无人系统与集群优化中,通过利用 EMTO 算法,可以有效地提升无人系统的任务分配和集群控制性能和智能水平。本节通过集群控制中的机械臂控制优化问题为例^[74],直观展示实际应用中的 MTOP 模型,以便后续分析与展望。图 13 展示了一个具有两个任务的机械臂控制优化问题示意图,其中 P_D 代表每条机械臂的顶端构件, T 代表目标位置, $[\alpha_1, \alpha_2, \dots, \alpha_d]$ 代表机械臂上每个关节的可转动范围。该问题的目标是为每条机械臂找到一组最优的关节角度,使得机械臂尽可能准确地到达目标位置 T 并完成特定操作,即最小化所有机械臂顶端构件 P_D 到目标位置 T 之间的距离。由于不同机械臂在执行类似抓取任务时,其关节运动模式和轨迹可能存在相似之处,因此 EMTO 算法可以通过共享不同机械臂控制优化过程中的通用知识,实现对于多机械臂的精确协同控制。例如,在知识选择层面,通过计算任务间的相似性度量,选择与当前任务最相似的源任务知识,如关节角度变化或末端构件位置等;在知识迁移层面,可将源任务中优质个体信息迁移到其他目标任务中,以提高目标任务的机械臂控制效率;而在知识运用层面,目标任务可通过模仿源任务中的成功接近目标点的角度参数设

置,以指导目标任务对应的机械臂运动。经过现有文献的实验验证^[38,42,46],与传统优化算法相比,EMTO 算法在解决此类机械臂控制优化问题时具有显著性能优势。

在神经网络架构搜索中,不同任务可能具有相似的神经网络架构需求,而 EMTO 算法可以利用架构间的相似性,并通过共享架构优化中的通用知识来提高神经网络架构搜索效率。在多任务神经网络架构搜索方面已有一些先驱性的工作,例如,Zhou 等^[75]提出了多任务卷积神经网络架构搜索(MultiTask Neural Architecture Search,MTNAS)框架,其通过知识共享机制在不同搜索过程中迁移和复用有效知识,从而协同、高效地优化多个神经网络架构。MTNAS 设计了低保真知识复用策略,用于在不进行大量训练的情况下评估架构性能,并通过自适应策略动态调整知识转移的频率。在实验验证中,MTNAS 在三种不同搜索空间的测试集上进行了验证。实验结果表明,MTNAS 能够在消耗比单任务神经网络架构搜索算法少约两倍的计算成本下,搜索到对比比算法更优的神经网络架构。因此,EMTO 算法在神经网络架构搜索中具有良好的应用前景。

智慧城市应用中往往涉及大量复杂系统和协同性任务,例如交通管理、物流调度等。这些系统通常包含众多相似的子任务,通过 EMTO 算法协同优化能够提高多任务求解效率和精度^[15]。以交通管理为例,城市中的不同区域、不同时段交通流量模式可能存在相似之处,基于不同模式之间的相似性,EMTO 算法可以在不同的交通管理场景之间共享知识。Feng 等^[15]率先探索 EMTO 在车辆路由问题上的应用前景,采用显式 EMTO 框架,构建路径之间映射,以实现任务间的知识迁移。在实验中,该研究构建了分别具有高、中、低任务间相似度的测试问题实例,并将提出的显式 EMTO 框架与多种单任务优化算法进行比较。实验结果表明,在求解车辆路由问题中,EMTO 算法无论是在求解精度还是在收敛速度方面都具有显著优势,尤其是当任务之间相似度较高的情况下。

6.2 未来研究展望

随着应用场景的不断拓展和 MTOP 的日益复杂,EMTO 仍面临许多问题和挑战,需要进一步探索与创新。本节从算法设计的知识选择、知识迁移、知识运用和应用拓展等方面对未来研究方向进行展望。

在知识选择方面,主要研究问题是如何从源任

务中选择出更高质量、能更好地辅助求解目标任务的知識。未来研究应关注从两方面提高知识选择的质量:首先,在知识选择上,EMTO 算法应设计更为细粒度的知识选择策略,以更精确地从相关个体或维度中选择知识。其次,算法可以尝试融合基于相似性的知识选择和基于性能反馈的知识选择的优势。基于相似性的知识选择策略能够快速选择相关知识,但对不相似却潜在有效的知识不敏感。而基于性能反馈的知识选择策略能够逐步发现潜在知识,但存在反馈延迟问题。因此,设计两者结合的知识选择策略是值得研究的方向。

在知识迁移方面,当前种群层面的知识迁移主要依赖映射和平移技术,难以应对复杂任务之间更复杂的非线性关系。因此,如何研究和设计能够满足复杂非线性映射需求的技术或模型,例如基于神经网络的映射方法,是值得探索的方向。此外,个体层面的知识迁移策略面临维度统一的问题,可能导致冗余维度和额外计算复杂度。未来研究应关注探索维度自适应性技术,使个体能够灵活调整其维度结构,以适应不同任务的需求,从而提高优化效率。

在知识运用方面,如何确保知识对当前任务进化过程的有效性是需要考虑的关键问题。现有研究大量基于交叉变异操作以实现知识迁移,但这种知识运用的前提是源任务知识和目标任务处于相似的空间中,因而需要对任务相似性进行精确评估以及设计合理的知识迁移策略。未来研究应深入探索将基于交叉变异、信息融合和行为模仿的知识运用策略相结合的方法,以发挥各自优势,提高整体优化性能。

在应用拓展方面,将 EMTO 算法应用于无人系统与集群优化^[76]、神经网络架构搜索^[77]以及智慧城市应用^[78]是值得探索的研究领域。同时,进一步探索 EMTO 在其他领域如生物信息学、金融优化以及大模型^[79]中的应用潜力。首先,在生物信息学方面,未来研究中,EMTO 算法可用于基因序列比对、蛋白质结构预测以及药物设计等复杂任务。例如,蛋白质结构预测需要处理大量复杂的结构和功能数据^[80],EMTO 算法可以通过多任务学习,共享不同蛋白质结构预测任务中的有用信息,从而提升预测模型的性能。其次,在金融优化方面,可以研究用于投资组合优化、风险管理以及高频交易策略制定的 EMTO 算法^[81]。例如,投资组合优化需要考虑多种资产的风险和收益,EMTO 算法能够同时优化多个投资组合,实现高效的资产管理。最后,在应用于大模型方面,在当前的科技发展趋势下,大模

型技术已经在多个领域展现出了巨大的潜力和影响力。大模型在处理复杂任务时表现出色,但其训练和优化过程往往需要大量的计算资源和时间。EMTO 技术可以通过共享知识和优化策略,帮助大模型在不同的任务之间进行有效的知识迁移和优化。一方面,可以通过 EMTO 和大模型技术的联合优化,研究如何将 EMTO 与大模型的训练过程相结合,通过共享中间结果和知识,加速大模型的训练过程。另一方面,可探索如何利用 EMTO 在大模型和小模型之间进行知识蒸馏的优化设计,使得小模型能够继承大模型的部分知识,从而在资源受限的环境中实现高效推理。

7 结 语

本文对现有 EMTO 领域的研究进行了全面梳理和分析,重点关注了知识选择、知识迁移和知识运用这三个主要研究方向。在知识选择方面,本文分基于相似性的和基于性能反馈的知识选择两类综述了现有研究。在知识迁移方面,本文从种群层面、个体层面和维度层面的知识迁移进行介绍。在知识运用方面,本文分析了基于交叉变异、基于信息融合和基于行为模仿的知识运用策略。通过对这些策略的系统阐述和分析,揭示了现有 EMTO 研究的贡献和局限。

尽管当前的研究已经取得了显著进展,但仍存在一些亟待解决的问题。在未来研究展望方面,本文针对知识选择、知识迁移和知识运用等 EMTO 的三个主要过程提出了一些研究设想。总之,EMTO 作为一种新兴的优化范式,具有广阔的应用前景和研究潜力,值得进行更为深入的研究。希望本综述能够为后续研究提供有益的参考和启示,推动 EMTO 领域不断向前发展。

参 考 文 献

- [1] Zhan Z H, Shi L, Tan K C, et al. A survey on evolutionary computation for complex continuous optimization. *Artificial Intelligence Review*, 2022, 55(1): 59-110
- [2] Zhan Z H, Li J Y, Kwong S, et al. Learning-aided evolution for optimization. *IEEE Transactions on Evolutionary Computation*, 2023, 27(6): 1794-1808
- [3] Jiang Y, Zhan Z H, Tan K C, et al. Knowledge learning for evolutionary computation. *IEEE Transactions on Evolutionary Computation*, doi:10.1109/TEVC.2023.3278132
- [4] Wang R, Ji F, Jiang Y, et al. An adaptive ant colony system based on variable range receding horizon control for berth allocation problem. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(11): 21675-21686
- [5] Wang C, Zhu R, Jiang Y, et al. A scheme library-based ant colony optimization with 2-opt local search for dynamic traveling salesman problem. *Computer Modeling in Engineering & Sciences*, 2023, 135(2): 1209-1228
- [6] Shi L, Zhan Z H, Liang D, et al. Memory-based ant colony system approach for multi-source data associated dynamic electric vehicle dispatch optimization. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(10): 17491-17505
- [7] Jin C, Tsai P W, Qin A K. A study on knowledge reuse strategies in multitasking differential evolution//*Proceedings of IEEE Congress on Evolutionary Computation*. Wellington, New Zealand, 2019: 1564-1571
- [8] Bi Y, Xue B, Zhang M. Multitask feature learning as multiobjective optimization: A new genetic programming approach to image classification. *IEEE Transactions on Cybernetics*, 2023, 53(5), 3007-3020
- [9] Zhou L, Feng L, Gupta A, et al. Learnable evolutionary search across heterogeneous problems via kernelized autoencoding. *IEEE Transactions on Evolutionary Computation*, 2021, 25(3): 567-581
- [10] Wang C, Ma H, Chen G, et al. Using an estimation of distribution algorithm to achieve multitasking semantic web service composition. *IEEE Transactions on Evolutionary Computation*, 2023, 27(3): 490-504
- [11] Huang Z, Mei Y, Zhang F, et al. Multitask linear genetic programming with shared individuals and its application to dynamic job shop scheduling. *IEEE Transactions on Evolutionary Computation*, 2024, 28(6), 1546-1560
- [12] Zhang F, Mei Y, Nguyen S, et al. Task relatedness-based multitask genetic programming for dynamic flexible job shop scheduling. *IEEE Transactions on Evolutionary Computation*, 2023, 27(6): 1705-1719
- [13] Jiang Y, Zhan Z H, Zhang J. A new and more challenging compositive multi-task optimization problem test suite//*Proceedings of the 12th International Conference on Information Science and Technology*. Kaifeng, China, 2022: 132-138
- [14] Lyu C, Shi Y, Sun L, et al. Community detection in multiplex networks based on evolutionary multitask optimization and evolutionary clustering ensemble. *IEEE Transactions on Evolutionary Computation*. 2023, 27(3), 728-742
- [15] Feng L, Huang Y, Zhou L, et al. Explicit evolutionary multitasking for combinatorial optimization: A case study on capacitated vehicle routing problem. *IEEE Transactions on Cybernetics*, 2021, 51(6): 3143-3156
- [16] Gupta A, Ong Y S, Feng L. Multifactorial evolution: Toward evolutionary multitasking. *IEEE Transactions on Evolutionary Computation*, 2016, 20(3): 343-357
- [17] Li J Y, Zhan Z H, Tan K C, et al. A meta-knowledge trans-

- fer-based differential evolution for multitask optimization. *IEEE Transactions on Evolutionary Computation*, 2022, 26(4): 719-734
- [18] Wu S H, Zhan Z H, Tan K C, et al. Transferable adaptive differential evolution for many-task optimization. *IEEE Transactions on Cybernetics*, 2023, 53(11): 7295-7308
- [19] Tang Z, Gong M, Wu Y, et al. Regularized evolutionary multitask optimization: learning to intertask transfer in a aligned subspace. *IEEE Transactions on Evolutionary Computation*, 2021, 25(2): 262-276
- [20] Zhao Jiawei, Chen Xuefeng, Feng Liang, et al. Review of evolutionary multitasking from the perspective of optimization scenarios. *Journal of Computer Applications*, 2024, 44(05): 1325-1337 (in Chinese)
(赵佳伟, 陈雪峰, 冯亮, 等. 优化场景视角下的进化多任务优化综述. *计算机应用*, 2024, 44(05): 1325-1337)
- [21] Wei T, Wang S, Zhong J, et al. A review on evolutionary multitask optimization: trends and challenges. *IEEE Transactions on Evolutionary Computation*, 2022, 26(5): 941-960
- [22] Tan K C, Feng L, Jiang M. Evolutionary transfer optimization—A new frontier in evolutionary computation research. *IEEE Computational Intelligence Magazine*, 2021, 16(1): 22-33
- [23] Lin Q, Wu Z, Ma L, et al. Multiobjective multitasking optimization with decomposition-based transfer selection. *IEEE Transactions on Cybernetics*, 2024, 54(5): 3146-3159
- [24] Gao K, Yang C, Ding J, et al. Distributed knowledge transfer for evolutionary multitask multimodal optimization. *IEEE Transactions on Evolutionary Computation*, 2024, 28(4): 1141-1155
- [25] Huang Y, Feng L, Qin A K, et al. Toward large-scale evolutionary multitasking: A GPU-based paradigm. *IEEE Transactions on Evolutionary Computation*, 2022, 26(3): 585-598
- [26] Han H, Bai X, Hou Y, et al. Multitask particle swarm optimization with heterogeneous domain adaptation. *IEEE Transactions on Evolutionary Computation*, 2024, 28(1): 178-192
- [27] Lin W, Lin Q, Feng L, et al. Ensemble of domain adaptation-based knowledge transfer for evolutionary multitasking. *IEEE Transactions on Evolutionary Computation*, 2024, 28(2): 388-402
- [28] Feng L, Zhou L, Zhong J, et al. Evolutionary multitasking via explicit autoencoding. *IEEE Transactions on Cybernetics*, 2019, 49(9): 3457-3470
- [29] Huang S, Zhong J, Yu W J. Surrogate-assisted evolutionary framework with adaptive knowledge transfer for multi-task optimization. *IEEE Transactions on Emerging Topics in Computing*, 2021, 9(4): 1930-1944
- [30] Liu P, Guo Z, Yu H, et al. A preliminary study of multi-task map-elites with knowledge transfer for robotic arm design// *Proceedings of IEEE Congress on Evolutionary Computation*. Padua, Italy, 2022: 1-8
- [31] Geng S, Li W, Tu J, et al. MOEMT-RPA: Reference point-assisted explicit multi-objective evolutionary multi-task algorithm// *Proceedings of the 5th International Conference on Data-driven Optimization of Complex Systems*. Tianjin, China, 2023: 1-8
- [32] Chen Y, Zhong J, Feng L, et al. An adaptive archive-based evolutionary framework for many-task optimization. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2020, 4(3): 369-384
- [33] Hou Y, Shen Y, Han H, et al. Many-task differential evolutionary algorithm based on bi-space similarity. *IEEE Transactions on Evolutionary Computation*, doi: 10.1109/TEVC.2024.3398436
- [34] Qiu Honghui, Liu Hailin, Chen Lei. Multi-objective multitasking optimization algorithm based on adjustment of covariance matrix. *Computer Engineering*, 2022, 48(8): 306-312 (in Chinese)
(邱鸿辉, 刘海林, 陈磊. 基于协方差矩阵调整的多目标多任务优化算法. *计算机工程*, 2022, 48(08): 306-312)
- [35] Xu Y, Pi D, Yang S, et al. Knowledge transfer-based multi-factorial evolutionary algorithm for selective maintenance optimization of multistate complex systems. *IEEE Transactions on Reliability*, 2024, 73(2): 1341-1352
- [36] Wang C, Liu J, Wu K, et al. Solving multitask optimization problems with adaptive knowledge transfer via anomaly detection. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 304-318
- [37] Wang Z, Cao L, Feng L, et al. Evolutionary multitask optimization with lower confidence bound-based solution selection strategy. *IEEE Transactions on Evolutionary Computation*, 2025, 29(1): 132-144
- [38] Jiang Y, Zhan Z H, Tan K C, et al. A bi-objective knowledge transfer framework for evolutionary many-task optimization. *IEEE Transactions on Evolutionary Computation*, 2023, 27(5): 1514-1528
- [39] Wu X, Wang W, Yang H, et al. Multitasking feedback optimization algorithm based on an evolutionary state estimator. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, 8(3): 2554-2569
- [40] Han H, Bai X, Hou Y, et al. Multitask particle swarm optimization with dynamic on-demand allocation. *IEEE Transactions on Evolutionary Computation*, 2023, 27(4): 1015-1026
- [41] Liaw R T, Ting C K. Evolutionary many-tasking based on biocoenosis through symbiosis: A framework and benchmark problems//*Proceedings of IEEE Congress on Evolutionary Computation*. Donostia, Spain, 2017: 2266-2273
- [42] Xu H, Qin A K, Xia S. Evolutionary multitask optimization with adaptive knowledge transfer. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 290-303
- [43] Bai L, Lin W, Gupta A, et al. From multitask gradient descent to gradient-free evolutionary multitasking: A proof of

- faster convergence. *IEEE Transactions on Cybernetics*, 2022, 52(8): 8561-8573
- [44] Li G, Lin Q, Gao W. Multifactorial optimization via explicit multipopulation evolutionary framework. *Information Sciences*, 2020, 512: 1555-1570
- [45] Da B, Gupta A, Ong Y S. Curbing negative influences online for seamless transfer evolutionary optimization. *IEEE Transactions on Cybernetics*, 2019, 49(12): 4365-4378
- [46] Jiang Y, Zhan Z H, Tan K C, et al. Knowledge structure preserving-based evolutionary many-task optimization. *IEEE Transactions on Evolutionary Computation*, 2024, early access, doi:10.1109/TEVC.2024.3355781
- [47] Wu D, Tan X. Multitasking genetic algorithm (MTGA) for fuzzy system optimization. *IEEE Transactions on Fuzzy Systems*, 2020, 28(6): 1050-1061
- [48] Xie T, Gong M, Tang Z, et al. Enhancing evolutionary multifactorial optimization based on particle swarm optimization//*Proceedings of IEEE Congress on Evolutionary Computation*. Vancouver, Canada, 2016: 1658-1665
- [49] Osaba E, Del Ser J, Martinez A D, et al. AT-MFCGA: An adaptive transfer-guided multifactorial cellular genetic algorithm for evolutionary multitasking. *Information Science*, 2021, 570: 577-598
- [50] Yi J, Bai J, He H, et al. A multifactorial evolutionary algorithm for multitasking under interval uncertainties. *IEEE Transactions on Evolutionary Computation*, 2020, 24(5): 908-922
- [51] Zhou L, Feng L, Tan K C, et al. Toward adaptive knowledge transfer in multifactorial evolutionary computation. *IEEE Transactions on Cybernetics*, 2021, 51(5): 2563-2576
- [52] Mai Wei-Jie, Liu Wei-Li, Zhong Jing-Hui. Evolutionary many-task optimization framework based on machine learning. *Chinese Journal of Computers*, 2024, 47(01): 29-51 (in Chinese)
(麦伟杰, 刘伟莉, 钟竞辉. 基于机器学习的演化多任务优化框架. *计算机学报*, 2024, 47(01): 29-51)
- [53] Bali K K, Ong Y S, Gupta A, et al. Multifactorial evolutionary algorithm with online transfer parameter estimation; MFEA-II. *IEEE Transactions on Evolutionary Computation*, 2020, 24(1): 69-83
- [54] Gupta A, Ong Y S, Feng L, et al. Multiobjective multifactorial optimization in evolutionary multitasking. *IEEE Transactions on Cybernetics*, 2017, 47(7): 1652-1665
- [55] Yang C, Ding J, Tan K C, et al. Two-stage assortative mating for multi-objective multifactorial evolutionary optimization//*Proceedings of IEEE 56th Annual Conference on Decision and Control*. Melbourne, Australia, 2017: 76-81
- [56] Bali K K, Gupta A, ONG Y S, et al. Cognizant multitasking in multiobjective multifactorial evolution; MO-MFEA-II. *IEEE Transactions on Cybernetics*, 2021, 51(4): 1784-1796
- [57] Ji X, Zhang Y, Gong D, et al. Multisurrogate-assisted multitasking particle swarm optimization for expensive multimodal problems. *IEEE Transactions on Cybernetics*, 2023, 53(4): 2516-2530
- [58] Jiang Y, Zhan Z H, Tan K C, et al. Block-level knowledge transfer for evolutionary multitask optimization. *IEEE Transactions on Cybernetics*, 2024, 54(1): 558-571
- [59] Xue Z F, Wang Z J, Jiang Y, et al. Multi-level and multi-segment learning multitask optimization via a niching method. *IEEE Transactions on Evolutionary Computation*, doi: 10.1109/TEVC.2024.3511941
- [60] Wu S H, Zhan Z H, Tan K C, et al. Orthogonal transfer for multitask optimization. *IEEE Transactions on Evolutionary Computation*, 2023, 27(1): 185-200
- [61] Ma X, Chen Q, Yu Y, et al. A two-level transfer learning algorithm for evolutionary multitasking. *Frontiers in Neuroscience*, 2020, 13: 1408
- [62] Lin J, Liu H L, Tan K C, et al. An effective knowledge transfer approach for multiobjective multitasking optimization. *IEEE Transactions on Cybernetics*, 2021, 51(6): 3238-3248
- [63] Tang Z, Gong M, Wu Y, et al. A multifactorial optimization framework based on adaptive intertask coordinate system. *IEEE Transactions on Cybernetics*, 2022, 52(7): 6745-6758
- [64] H. Chen, H. Liu, F. Gu, et al. A multiobjective multitask optimization algorithm using transfer rank. *IEEE Transactions on Evolutionary Computation*, 2023, 27(2): 237-250
- [65] Han H, Bai X, Han H, et al. Self-adjusting multi-task particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 2022, 26(1): 145-158
- [66] Liang Z, Dong H, Liu C, et al. Evolutionary multitasking for multiobjective optimization with subspace alignment and adaptive differential evolution. *IEEE Transactions on Cybernetics*, 2022, 52(4): 2096-2109
- [67] Liang Z, Xu X, Liu L, et al. Evolutionary many-task optimization based on multisource knowledge transfer. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 319-333
- [68] Lai Y, Chen H, Gu F. A multitask optimization algorithm based on elite individual transfer. *Mathematical Biosciences and Engineering*, 2023, 20(5): 8261-8278
- [69] Liang Z, Liang W, WANG Z, et al. Multiobjective evolutionary multitasking with two-stage adaptive knowledge transfer based on population distribution. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2022, 52(7): 4457-4469
- [70] Thang T B, Dao T C, Long N H, et al. Parameter adaptation in multifactorial evolutionary algorithm for many-task optimization. *Memetic Computing*, 2021, 13(4): 433-446
- [71] Yin J, Zhu A, Zhu Z, et al. Multifactorial evolutionary algorithm enhanced with cross-task search direction//*Proceedings of IEEE Congress on Evolutionary Computation*. Wellington, New Zealand, 2019: 2244-2251
- [72] Li W, Fan Y, Wang L, et al. Multifactorial teaching-learning

- ing-based optimization with the diversity and triangle cooperation mechanism. *Applied Intelligence*, 2022, 52 (14): 16512-16531
- [73] Li Y, Gong W. Multiobjective multitask optimization with multiple knowledge types and transfer adaptation. *IEEE Transactions on Evolutionary Computation*, 2025, 29(1), 205-216
- [74] Mouret J B, Maguire G. Quality diversity for multi-task optimization// *Proceedings of the Genetic and Evolutionary Computation Conference*. New York, USA, 2020: 121-129
- [75] Zhou X, Wang Z, Feng L, et al. Toward evolutionary multitask convolutional neural architecture search. *IEEE Transactions on Evolutionary Computation*, 2024, 28(3): 682-695
- [76] Jiang Y, Xu X X, Zheng M Y, et al. Evolutionary computation for unmanned aerial vehicle path planning: A survey. *Artificial Intelligence Review*, 2024, 57(10): 267
- [77] Zhan Z H, Li J Y, Zhang J. Evolutionary deep learning: A survey. *Neurocomputing*, 2022, 483: 42-58
- [78] Chen Z G, Zhan Z H, Kwong S, et al. Evolutionary computation for intelligent transportation in smart cities: A survey. *IEEE Computational Intelligence Magazine*, 2022, 17(2): 83-102
- [79] Wu X, Wu S H, Wu J et al. Evolutionary computation in the era of large language model: Survey and roadmap. *IEEE Transactions on Evolutionary Computation*, 2025, 29(2): 534-554
- [80] Hong J, Zhan Z H, He L et al. Protein structure prediction using a new optimization-based evolutionary and explainable artificial intelligence approach. *IEEE Transactions on Evolutionary Computation*, 2024, early access, doi: 10.1109/TEVC.2024.3365814
- [81] Chou J S, Chen K E. Optimizing investment portfolios with a sequential ensemble of decision tree-based models and the FBI algorithm for efficient financial analysis. *Applied Soft Computing*, 2024, 158, 111550



JIANG Yi, Ph. D.. His main research interests include artificial intelligence, evolutionary computation, and multitask optimization.

ZHAN Zhi-Hui, Ph. D., professor.

His main research interests include artificial intelligence, evolutionary computation, and swarm intelligence.

ZHANG Jun, Ph. D., professor. His main research interests include artificial intelligence and evolutionary computation.

Background

Evolutionary multitask optimization is an emerging research topic in the evolutionary computation community. Traditionally, evolutionary computation algorithms have been designed to solve single, independent optimization problems. However, in many practical applications, optimization problems are often interrelated or share common characteristics. This interconnectedness can be leveraged to enhance the optimization process across multiple tasks. Addressing this, the main objective of evolutionary multitask optimization is to solve multiple optimization tasks simultaneously and effectively by utilizing knowledge gained from the optimization process for one task to aid in solving other related ones. By sharing knowledge across tasks, evolutionary multitask optimization algorithms are generally more effective and efficient compared to traditional single-task optimization methods. At present, evolutionary multitask optimization has demonstrated significant success across various application domains. Since its introduction, the studies of evolutionary multitask optimization have developed rapidly. However, current reviews of evolutionary multitask optimization often focus on specific applications or general descriptions of evolutionary multitask optimization algo-

gorithms without delving deeply into the underlying mechanisms and processes that affect algorithms' performance. To fulfill this urgent need, this paper presents a comprehensive and systematic review of evolutionary multitask optimization research from three important aspects of algorithm design: knowledge selection, knowledge transfer, and knowledge utilization. (1) In the aspect of knowledge selection, this paper surveys the studies on similarity-based and performance-feedback-based knowledge selection strategies, assessing their efficacy in extracting knowledge from source tasks. (2) In the aspect of knowledge transfer, this paper introduces the studies on population-level, individual-level, and dimension-level knowledge transfer strategies, highlighting their respective strengths. (3) In the aspect of knowledge utilization, this paper introduces the research for knowledge utilization based on crossover and mutation, information fusion, and behavioral imitation, analyzing their impact on enhancing target task optimization. By categorizing the existing studies, this paper summarizes the research lineage of evolutionary multitasking optimization and proposes insights for future exploration, intending to promote the continuous development of the field.