

控制与决策

Control and Decision

多任务优化算法综述

程美英, 钱乾, 倪志伟

引用本文:

程美英, 钱乾, 倪志伟. 多任务优化算法综述[J]. 控制与决策, 2023, 38(7): 1802–1815.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1754>

您可能感兴趣的其他文章

Articles you may be interested in

天空地一体化网络环境下多运动体系统跨域协同控制与智能决策综述

Cross-domain cooperative control and intelligent decision-making of multi-dynamic agents in space-air-ground integrated network environment: A review

控制与决策. 2023, 38(5): 1176–1199 <https://doi.org/10.13195/j.kzyjc.2022.1774>

基于博弈论的多车智能驾驶交互决策综述

A review on interactive decision-making of multi-vehicle autonomous driving with a game theoretical perspective

控制与决策. 2023, 38(5): 1159–1175 <https://doi.org/10.13195/j.kzyjc.2022.1512>

移动群智感知中基于任务质量的多任务分发参与者选择

Multitask-oriented participant selection based on task quality in mobile crowd sensing

控制与决策. 2022, 37(10): 2667–2676 <https://doi.org/10.13195/j.kzyjc.2021.0049>

基于分解的多目标多因子进化算法

A multiobjective multifactorial evolutionary algorithm based on decomposition

控制与决策. 2021, 36(3): 637–644 <https://doi.org/10.13195/j.kzyjc.2019.0525>

阴影条件下基于迁移强化学习的光伏系统最大功率跟踪

Transfer reinforcement learning based maximum power point tracker of PV systems under partial shading condition

控制与决策. 2020, 35(12): 2939–2949 <https://doi.org/10.13195/j.kzyjc.2019.0412>

多任务优化算法综述

程美英^{1†}, 钱乾², 倪志伟³

(1. 湖州师范学院 经济管理学院, 浙江 湖州 313000; 2. 湖州师范学院 教师教育学院, 浙江 湖州 313000;
3. 合肥工业大学 管理学院, 合肥 230009)

摘要: 基于计算智能“隐并行性”实现多任务优化 (multi-task optimization, MTO), 是当前研究的热点和前沿技术. 与传统单任务优化算法相比, 通过挖掘群体智能内在并行和内涵并行同时优化多个任务, 可显著提高问题求解质量以及缩短任务求解时间. 首先, 对 MTO 相关英文/中文文献进行梳理, 总结 MTO 研究进展和趋势; 然后, 基于多因子优化 (multifactorial optimization, MFO) 和多种群演化 (multi-population evolution, MPE) 两种不同信息共享框架, 从多任务搜索空间设计、种群数量、种群规模、依托算法、信息迁移节点、交互信息、时间和空间复杂度以及复杂系统等角度对比二者异同; 接着, 从信息迁移节点、方式和类型 3 方面重点阐述 MTO 核心理论; 最后, 从探究 MTO 复杂系统层级智能涌现行为、多任务种群多样性控制以及应用领域拓展 3 方面展望未来研究方向.

关键词: 多任务优化; 信息共享框架; 信息迁移节点; 信息迁移方式; 信息迁移类型; 典型应用领域

中图分类号: TP18 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2021.1754

引用格式: 程美英, 钱乾, 倪志伟. 多任务优化算法综述[J]. 控制与决策, 2023, 38(7): 1802-1815.

Review of multi-task optimization algorithm

CHENG Mei-ying^{1†}, QIAN Qian², NI Zhi-wei³

(1. School of Economics & Management, Huzhou University, Huzhou 313000, China; 2. School of Teacher Education, Huzhou University, Huzhou 313000, China; 3. School of Management, Hefei University of Technology, Hefei 230009, China)

Abstract: Multi-task optimization (MTO) based on implicit parallelism of computational intelligence is a research hot-spot and cutting-edge technology nowadays. Compared with the traditional single-task optimization algorithm, optimizing multiple tasks concurrently by mining the internal parallelism and connotation of swarm intelligence can significantly improve the problem solving quality and shorten the task solving time. Firstly, the research trend and progress of the MTO is outlined by combing the English and Chinese related literature. Then, based on the multifactorial optimization (MFO) and multi-population evolution (MPE) information sharing frameworks, the differences and similarities between the MFO and the MPE are summarized from the aspects of multi-task search space design, population number, population size, relying algorithms, information migration nodes, transferred knowledge, time and spatial complexity, complex systems. Moreover, the core theory of MTO is expounded from the angel of information transfer nodes, modes and types. Finally, the future research direction from the aspects of exploring the hierarchical intelligent emergence of the MTO complex system, multi-task population diversity control and expanding application fields are discussed.

Keywords: multi-task optimization; information sharing framework; information transfer node; information transfer mode; information transfer type; typical application area

0 引言

随着经济全球化、网络化、数字化发展, 计算机应用所需的数据量和计算量不断增加, 使得人们对高性能计算(即问题求解的时间性能、处理效率、资源利用率等)提出更高的要求. 高性能计算通常指并行计算, 即在同一时刻快速响应或处理来自多个用户服务请

求(多任务处理^[1]). 目前并行计算即高性能计算正在进入体系架构大变革时代, 而这大变革是“硬件、软件和算法的同时演进”. 计算机发展史表明, 为了达到高效而快速的计算目的, 除了提高计算机 CPU 等元器件速度外, 计算机体系结构(如并行计算)成为人们解决高速计算的新方案, 然而在谈论并行计算时,

收稿日期: 2021-10-12; 录用日期: 2022-05-24.

基金项目: 国家自然科学基金青年基金项目(62102148); 湖州市科技计划项目(2018YZ11).

责任编辑: 巩敦卫.

[†]通讯作者. E-mail: 02550@zjhu.edu.cn.

往往会忽略对算法的研究,通常算法效率提高所带来计算速度的提高才是最为有效的方法^[2]。

计算智能(computational intelligence, CI)是一组受自然启发的计算方法和途径,用于解决复杂现实世界问题,主要包括进化计算(evolutionary computation, EC)和群体智能(swarm intelligence, SI)等分支。其中,EC主要基于达尔文生物进化原理,而SI侧重于模仿社会性动物各种群体行为,利用群体中个体间信息交互和协作实现寻优目的,但二者均拥有“隐含并行性”这一共同特征,均具备多任务处理能力。区别于基于云平台的多任务处理算法,基于EC和SI实现多任务处理命名为“多任务优化(multi-task optimization, MTO)”^[3]。开发高性能多任务优化算法反过来能够更大程度地提高云平台计算效率,进一步提高云计算发展和应用^[4]。

作为一个全新研究领域,近些年,国内外学者就MTO进行了广泛而深入的研究,涌现出一系列研究成果。文献[5-9]对MTO相关成果进行了分类和总结,其中文献[6]为文献[5]进一步地完善和延伸,从MTO概念、编码解码策略、多任务信息选择及评价机制、超多任务优化存在问题等方面阐述了近5年MTO研究进展;文献[7]主要从信息迁移模式以及遏制信息负迁移两个角度综述现有成果;文献[8]从进化迁移优化角度探讨了多任务间的信息传递;文献[9]致力于将MTO算法与传统进化算法进行对比。文献[5-9]对了解MTO进展具有重要的参考价值。

自2016年Gupta等^[3]首次提出MTO概念以来,相关研究成果逐年递增,如何将现有文献进行分类,是本研究综述需要着重解决的问题。现有MTO算法主要基于两种信息共享框架:1)多因子优化(multifactorial optimization, MFO^[3]);2)多种群演化(multi-population evolution, MPE)^[10]。MFO和MPE本质在于通过任务间知识共享达到共同进化目的,但仍有细微差别。本文以MFO和MPE为主线,分类讨论现有MTO的核心理论。

区别于文献[5-9],本文主要内容如下:1)在挖掘MFO与MPE本质特征和相似性基础上,从复杂系统视角构建基于MFO和MPE的层次涌现模型,探讨多任务间基因重组或多种群重构复杂智能涌现。2)对MTO现有成果进行梳理,从信息迁移节点、方式和类型3方面详细讨论MTO核心理论。其中,信息迁移节点设置在文献[5-9]基础上增加了优、缺点对比;信息迁移方式在文献[5-9]基础上增加了“构建虚拟多任务环境(包括辅助任务、辅助种群、辅助代理、辅助信息)”“基于任务复杂性度量的信息迁移”“基于多

任务间学习优化的信息共享”3个分支;而信息迁移类型则按是否需对迁移知识进行转换映射分为“直接信息迁移”和“基于源域求解经验的间接信息迁移”两类,并将MFO和MPE贯穿于整个核心理论中进行讨论。3)从复杂系统视角完善MTO理论、多任务种群多样性控制以及求解多任务动态复杂优化问题等视角展望未来研究方向。

本文组织结构安排如下:第1节通过收集英文/中文权威期刊上发表MTO的相关论文,探讨MTO近6年研究进展;第2节从MTO起源引申出MTO信息共享机制与搜索空间设置关联,并基于演化算法(evolutionary algorithm, EA)和粒子群算法(particle swarm optimization, PSO)详述MFO和MPE基本机理,从理论上分析二者异同;第3节系统阐述MTO算法核心理论及典型应用领域;第4节展望MTO未来研究方向。

1 MTO研究现状总括

本文文献收集截止时间为2022年4月。首先选取计算机领域具有较高国际影响力期刊作为英文文献主要来源,具体操作如下:参照汤森路透集团(Thomson Reuters)发布的年度《期刊引用报告》(journal citation reports, JCR),对本课题研究领域重要期刊进行分析:1)以“Multitasking”或“Multi-Task”为关键词进行论文宽泛检索,然后根据论文摘要剔除无关文献;2)将全部检索论文目录导入文献管理软件Zotero,通过ScienceDirect、Springer-Link、Web of Science(SCIE)等数据库下载论文全文。

近6年已于高级别英文期刊上发表了一系列关于MTO的论文,论文发表数量呈逐年递增趋势。表1对英文权威期刊(JCR二区以上)发表的MTO相关论文进行分类统计,罗列出10种5年平均影响因子在4.0以上的期刊。发表于计算机领域顶级期刊IEEE Transactions on Evolutionary Computation和IEEE Transactions on Cybernetics上的论文数量分别为16篇和17篇。继续对表1分析可知,目前MTO依托算法主要集中于EC中的遗传算法(evolutionary algorithm, EA)和遗传规划(genetic programming, GP),采用MFO实现任务间信息共享,而基于SI的多任务优化研究成果则不多见,主要集中于PSO领域,且采用MPE实现任务间协作。对中文文献主要依托我国知网、维普数据库、万方数据库,以“多任务优化”或“进化多任务优化”为关键字进行检索,统计国家自然科学基金委员会认定一级期刊上发表的相关论文(如表2所示)。由表2可见,目前发表在中文一级期刊上的MTO

表1 英文权威期刊发表MTO相关论文统计

英文权威期刊全称(JCR二区以上)	5年影响因子	发表论文数量	依托算法	依托框架
IEEE Transactions on Evolutionary Computation	14.033	16	EC	MFO
IEEE Transactions on Cybernetics	10.090	17	EC/SI(PSO)	MFO
IEEE Transactions on Fuzzy Systems	9.376	1	EC	MFO
IEEE Transactions on Neural Networks and Learning Systems	8.823	3	EC	MFO
IEEE Transactions on Systems Man Cybernetics-System	7.715	2	EC/GP	MFO
IEEE Transactions on Intelligent Transportation Systems	6.709	3	EC	MFO
Energy Conversion and Management	6.431	2	EC	MFO
IEEE Transactions on Emerging Topics in Computational Intelligence	5.539	3	EC	MFO
Expert Systems with Applications	4.084	2	EC	MFO
Engineering Applications of Artificial Intelligence	4.02	1	SI(PSO)	MPE

表2 中文一级期刊发表MTO论文统计

论文期刊	发表论文数量	依托算法	依托框架
模式识别与人工智能	2	SI(PSO)	MPE/MFO
系统科学与数学	1	SI(PSO)	MPE

论文仅有3篇,均以PSO为依托算法,其中2篇以MPE为信息共享依托框架.通过对MTO近些年发表高级别英文、中文论文分析可知,现有MTO算法大多基于MFO实现多任务信息共享,以SI为依托算法的研究成果并不多见,表明关于SI多任务优化理论和应用尚处于一个新兴研究领域.

2 MFO与MPE对比

大脑是生物体内结构和功能最复杂的器官,同时也是高超、精巧和完善的信息处理系统.大脑同时管理和执行多项任务,并总结经验迁移至其他任务,在现实生活中非常常见,如边打电话边记录,边跑步边听歌等,具有高效率、防止拖延等优点.虽然有部分神经类科学家指出频繁地在多个任务间来回切换会产生一定时间开销,且集中力、组织能力和细节把控力上会遭遇麻烦,但是采用计算机实现多个任务处理,完全可以忽略这些问题.

受人类大脑多任务处理思想启发,假设采用计算机同时处理2个极小函数优化问题 T_1 和 T_2 , T_1 对应的目标函数和搜索空间为 f_1, X_1 , T_2 对应的目标函数和搜索空间为 f_2, X_2 ,若将 T_1 和 T_2 同时求解,则多任务搜索空间设为 $Y = X_1 \cup X_2$,如图1所示.

假设对于 Y 中任意两点 y_1 和 y_2 满足 $f_1(y_1) < f_1(y_2) \Leftrightarrow f_2(y_1) < f_2(y_2)$.将注意力集中于图1搜索区域 AB , f_1 和 f_2 均单调递减,若将 f_1 和 f_2 同时求解,任何作用于 f_1 的操作在一定程度上也会协助 f_2 跳出局部最优陷阱,即信息正迁移;而对于 BC 区域,单调趋势相反,任何作用于 f_1 的操作在一定程度上会使




图1 多任务优化信息共享示意图

得 f_2 逐步偏离全局极小值,即信息负迁移.若能够有效利用 AB 区域这种信息正迁移,必能够加速多个任务共同进化.

2.1 MFO与MPE搜索空间设置对比

推广至一般情况,假设需要同时处理 K 个不同任务 T_1, T_2, \dots, T_K ,任务 T_k 对应的搜索空间和维数分别设为 X_k 和 D_k ,假设 $X_1 < X_2 < \dots < X_K, D_1 < D_2 < \dots < D_K$,则基于MFO多任务优化搜索空间设为 $Y = (X_1 \cup X_2 \cup \dots \cup X_K)$,搜索空间 Y 维数设为 $D_Y = \max\{D_k\}$,如图2所示.假设同时优化任务 T_k (维数 D_k)和 T_t (维数 D_t),且 $D_k > D_t$,多任务搜索空间维数设为 $D_Y = \max\{D_t, D_k\}$,解码任务 T_t 时取前 t 位.




图2 基于MFO多任务搜索空间设置

因MPE种群与任务一一对应,各种群搜索空间

各自独立,只有在信息交互节点迁移信息,若考虑后期信息迁移时能够给信息需求方提供完整信息,则可效仿MFO将搜索空间维数取所有任务维度最大值,如图3所示,解码方式与MFO相同,这里不再赘述。




图3 基于MPE多任务搜索空间设置

2.2 MFO和MPE主要思想

在同一搜索空间,通过基因交互(MFO)或任务间协作演化(MPE)可提高多任务优化性能.对MTO文献进行梳理发现,现有MTO算法大多基于MFO和MPE或对其实施改进,如文献[11]基于小组头脑风暴思想设计MTO算法便是MPE的变种.因此本节简要介绍MFO与MPE的基本思想,并对比分析两者异同.假设需要同时优化K个极小优化问题,任务Ts.目标函数为fs: Xs,且fs受相应约束限制.设种群规模为N,当个体i(i∈N)用于处理任务Ts时,其目标函数设为fi.

2.2.1 MFO基本思想

MFO主要受多因子遗传思想启发,生物个体遗传性状除受基因作用外,还受环境因素影响,是遗传(基因选型交配)与环境(文化传播)两种因素的综合作用[12].MFO信息共享框架如图4所示。




图4 MFO多任务信息共享框架

定义1(等级因子rsⁱ) 指种群中个体i求解任务Ts时适应值排序。

定义2(标量因子φi) 将任意个体i在不同任务上的等级因子{r₁ⁱ, r₂ⁱ, ..., r_Kⁱ}化简为该个体最适合求解的任务标量φi,如φi = 1/min{r_sⁱ}, s = 1, 2, ..., K。

定义3(技能因子τi) 指在所有任务中个体i最适宜求解的任务。

MFO通过计算种群中每个个体i的rsⁱ、φi、τi,并根据τi将整个种群分割为适于求解K个任务的K个不重叠任务组(或称临时子种群),临时子种群间个体通过选择性交配或选择性模仿,实现任务间垂直基因传递,达到知识在不同任务组间迁移和共享目的.算法1给出了将MFO引入EA的多任务多因子进化算法(multifactorial EA, MFEA)[3]伪代码。

算法1 MFEA[3]

step 1: 随机初始化N个个体,并存放于当前种群current-pop(P)。

step 2: 分别将N个个体求解K个任务,并评估N个个体在K个任务上的适应值。

step 3: 计算个体i技能因子。

step 4: 在current-pop(P)中按概率随机选择具有相同技能因子的父代个体实施交叉操作,新产生的个体存放于子代种群offspring-pop(C)。

step 5: 将offspring-pop(C)中个体求解特定任务,并进行适应值评价。

step 6: 合并current-pop(P)和offspring-pop(C)形成临时种群intermediate-pop。

step 7: 从intermediate-pop中选择适应值最优的N个个体形成下一代新种群current-pop(P)。

step 8: 循环step 2~step 7,若满足循环结束条件,则输出K个任务最优适应值;否则,转至step 2。

2.2.2 MPE基本思想

自然生态系统中,物种在长期进化过程中从单方依赖性发展为双方相互调节而相互依存,协同演化已成为种群间不可缺少的生存条件。

在EC和SI中引入多种群思想已诞生一系列研究成果,但往往集中于求解一些复杂单任务优化问题,如在难度系数较高的高维函数优化问题中,将每个子种群对应1个(或1组)函数变量[13],或在多目标函数优化问题中,每个子种群对应1个(或多个)目标[14],然后将各子种群并行搜索结果合并为1个完整解.而MPE主要根据任务个数设置相应子种群,各子种群内个体间相互竞争,在信息交互节点子种群间协作,达到同时优化多个任务的目的,如图5所示。




图5 MPE多任务信息共享框架

算法2为在PSO算法中引入MPE的多任务协同进化PSO算法(coevolutionary PSO for multitasking,

CPSOM)^[10].

算法2 CPSOM^[10]

step 1: 随机产生 K 个种群 s_1, s_2, \dots, s_K 用于优化 K 个任务. 种群 $s_k (k=1, 2, \dots, K)$ 规模为 N .

step 2: 分别评价 s_1, s_2, \dots, s_K 中个体适应值, 比较得出各任务最优适应值 $f_{s_k}^{best}(t=0)$ 和个体 $i (i \in s_k)$ 自身最优适应值 $f_{s_k, i}^{best}(t=0)$.

step 3: 设置种群计数器 $count_{s_k}$ 和个体计数器 $count_{s_k}^i$.

step 4: 更新种群 $s_k (k=1, 2, \dots, K)$ 中个体速度和位置.

step 5: 评价个体适应值, 并与个体最优适应值对比, 若 $f_{s_k, i}^{best}(t+1) > f_{s_k, i}^{best}(t)$, 则 $count_{s_k}^i = count_{s_k}^i + 1$, 一旦 $count_{s_k}^i == \gamma_1$, 种群 s_k 内个体实施竞争操作, 若新产生个体优于父代个体, 则取代父代个体.

step 6: 比较得出种群 $s_k (k=1, 2, \dots, K)$ 全局最优解, 若 $f_{s_k}^{best}(t+1) > f_{s_k}^{best}(t)$, 则 $count_{s_k} = count_{s_k} + 1$, 一旦 $count_{s_k} == \gamma_2$, 其他 $(K-1)$ 个种群协助种群 s_k .

step 7: 循环 step 4 ~ step 6, 若满足循环结束条件, 则输出 K 个任务最优适应值; 否则, 转至 step 4.

其中 γ_1 和 γ_2 分别为种群内部/种群间信息迁移节点.

2.2.3 MFO与MPE信息共享框架对比

MFO 和 MPE 均为实现多任务间信息迁移和共享的有效策略, 但二者存在细微区别, 这里仅以 MFEA 与 CPSOM 为例对比二者异同, 如表 3 所示.

表3 MFO与MPE对比

	MFO	MPE
种群数量	1	K
种群规模	N	$K \cdot N$
依托算法	EC	SI
信息迁移节点	按概率迁移信息	自适应调整信息交互间隔
迁移的信息	垂直基因传递	最优位置信息传递
时间复杂度	多项式	多项式
空间复杂度	多项式	多项式

由表3可见, MFO与MPE不同点主要体现于以下3方面.

1) 依托算法不同. MFO 主要依托算法为 EC, 而 MPE 主要依托于 SI, 也有部分学者将 MFO 引入 PSO 中, 最典型代表可参考文献[15].

2) 种群规模不同. MFO 仅用 1 个种群完成 K 个任务求解, 即种群数量为 1, 而 MPE 种群数量为 K , K 个任务对应 K 个种群. 在整个问题求解过程中, MFO 中父代虽然通过交叉变异产生新个体, 但通过精英选择操作使得整个种群规模始终保持 $1 \cdot N$; 而 MPE 种群规模始终为 $K \cdot N$, 是 MFO 的 K 倍.

3) 信息迁移机制不同. MFO 通过技能因子始终将最合适个体分配给最合适任务, 并采用垂直因子传递实现任务间信息共享; 而 MPE 通过协作和竞争在信息迁移节点 γ_1 和 γ_2 交互信息, 达到协助其他任务的目的.

MFO 与 MPE 虽然存在细微区别, 但 MFO 模型子代形成的复杂特征受遗传与文化因素协同影响, 这与 MPE 的协同演化机制在本质上一致. 同时, 在保持相同种群规模、相同搜索空间维度以及相同最大迭代次数时, MFO 与 MPE 的时间复杂度和空间复杂度相当, 均为多项式.

2.2.4 基于复杂系统视角的MFO与MPE层次涌现行为对比

基于 MFO/MPE 的多任务优化系统实质是一个复杂自适应系统, 个体/基因相互作用形成群体, 群体间通过协作迁移信息形成群落, 个体交互、群体间合并融合均会导致基因重组或种群重构, 如图 6 所示.

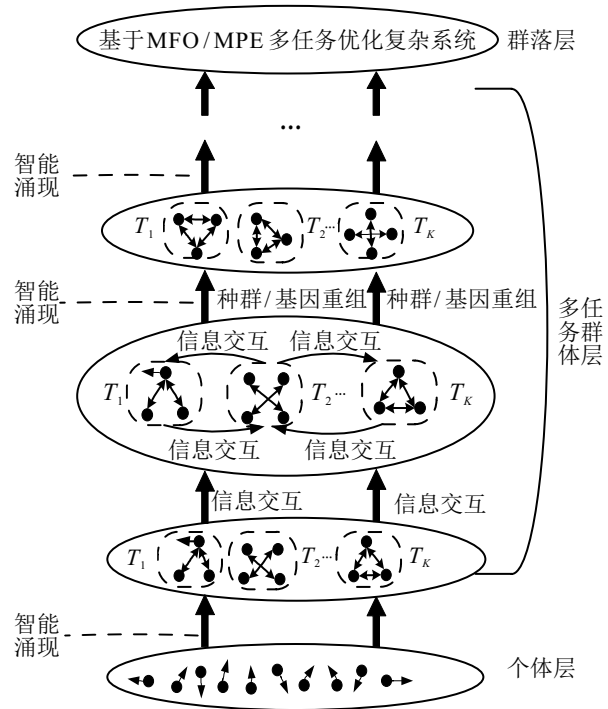


图6 基于MFO/MPE多任务复杂系统智能涌现层次

基因重组或种群重构是任务间知识共享的典型途径, 因此, 从复杂系统视角可发现, MFO 与 MPE 在本质上也是一致的.

3 MTO核心理论和应用

MTO 算法是基于种群模拟的计算智能, 具有内在并行和内涵并行智能特征. MTO 与多任务学习 (multi-task learning, MTL^[16]) 在形式上相似, 但却有本质区别, MTL 同时对多个任务进行学习, 从而使得单个任务中信息能够被其他任务利用, 而 MTO 专注于

挖掘任务间共享信息以改善单任务优化性能,即借助种群进化和多因素遗传机制,达到加速各任务收敛速度和提高各任务求解质量的目的(“正迁移”效应)。然而,现有多任务优化方法往往基于任务之间是紧密相关的假设,由于不可能每个任务均与所有任务紧密关联,负向任务间交互的易感性会阻碍整体收敛行为,即出现信息“负迁移”^[3,17],主要归结为以下3方面原因。

1) 各优化问题搜索域重合度低^[18-19]。现有多任务优化算法将各任务限定于统一搜索空间,当搜索域完全重合、部分重合情况下效果较好,且随着搜索域重合部分增加,信息传递导致各任务优化效果也随之递增。然而,当搜索域完全不重合时,不相关共享信息有可能对多任务处理性能造成伤害,这种现象在多任务组合优化问题中尤为明显。

2) 各优化问题相似程度低^[20-22]。当任务处于中等或低相似性时,鲜有可供利用的有效信息。

3) 与任务间信息迁移导致种群多样性过度增加有关。文献[23]通过实验表明MTO本质在于有效信息传递,但任务间频繁信息迁移或无关共享信息将导致种群多样性过度增加。

在MFO或MPE信息共享框架中,何时迁移信息(信息迁移节点)、如何迁移信息(信息迁移方式)、迁移什么信息(信息迁移类型)均会对MTO的性能产生影响^[8,10]。MFO与MPE虽然在本质上一致,但由于进化机制或依托算法的不同使其在信息迁移节点、方式、类型上有稍许差异,本文以上述3方面为基石,对MTO核心理论分类讨论和对比。

3.1 信息迁移节点设置

迁移节点设置会直接影响MTO信息迁移频率,当信息迁移频率过高时,种群过度多样性导致当前任务不能快速收敛,而当信息迁移频率过低时,达不到任务间信息共享目的。现有MTO信息迁移节点设置方法主要有:设置随机交互参数 rmp 、自适应调整 rmp 、基于数据驱动估计 rmp 、固定信息交互间隔、自适应调整信息交互间隔,具体如表4所示。文献[6]已详细罗列出上述各种信息交互的数学描述,这里不再重复,本文在文献[6]基础上总结了不同信息迁移节点设置的优劣势,相关文献统计如表4所示,其中英文论文引用次数来源于谷歌学术,中文文献引用次数来源于中国知网。由表4可见,MFO与MPE信息迁移节点设置上并没有明显区别,二者相互借鉴。

表4 MTO不同信息迁移节点设置方式

信息迁移节点设置方法	依托框架	代表文献/引用次数	优点	缺点
随机交互参数 rmp	MFO MPE	[10]/322,[24]/67,[25]/181 [26]/67,[27]/3,[28]/0	操作简单,易于实现	随机性较强, 各不同任务采用 同一 rmp 值具有其局限性
自适应调整 rmp	MFO MPE	[29]/45,[30]/25,[31]/29,[32]/26,[33]/0 [34]/25,[35]/24	根据MFO动态过程 自适应调整 rmp 值, 可降低负向迁移概率	并不总能够准确预估多任务 优化过程中种群进化方向
数据驱动估计 rmp	MPE	[36]/103,[37]/34 [38]/1,[39]/1	在线参数能够捕获 不一致任务间协同, 从而抑制负迁移	当待求解任务个数递增时, 在线参数学习机制时间复杂度较高; 子种群数据集数据较少时, 易产生过拟合现象
固定信息交互间隔	MPE	[40]/110,[41]/37	操作简单,能够显著 改善多任务优化性能	信息迁移过程具有盲目性
自适应调整信息交互间隔	MPE MFO	[11]/40,[42]/11,[43]/5 [44]/28,[45]/64	根据种群进化趋势 动态调整时间间隔, 可平衡探索与开发冲突	对具体问题需要反复 调整信息交互间隔参数

3.2 MTO信息迁移方式

MTO目标是借助任务间信息共享同时优化多个任务,而这些任务有可能来自完全不同的领域,或拥有完全不同的特征。因此,在信息迁移节点探究合适的信息融合方式显得尤为重要。本文基于现有文献,从以下4个方面进行分类综述,如表5所示。

3.2.1 基于任务特征相似性度量

相似性或互补性指在同一搜索空间2个任务适应度曲面的异同,通常表现为多个优化问题描述、搜索空间、全局最优解紧密相关。文献[18]和文献[22]基于数据驱动计算任务间Spearman相关系数,或基于高斯贝叶斯优化模型有效度量任务间的相似性,

表5 MTO信息融合方式

分类	信息迁移方式	依托框架	代表文献/引用次数
基于任务特征相似性度量	计算任务间 Spearman 相关系数	MFO	[18]/14
	高斯贝叶斯优化模型	MFO	[22]/163
	聚类技术	MFO	[46]/[45]
	基于种群分布动态获取任务相关性等级	MPE	[47]/1
构建虚拟多任务环境	辅助任务	MFO	[20]/109, [48]/6, [49]/2, [50]/6, [51]/4, [52]/1
	辅助种群	MFO	[43]/5
	辅助代理	MFO/MPE	[53]/14, [54]/14, [55]/2
	辅助信息	MPE	[56]/1
基于任务复杂度动态分配资源	广义资源分配框架	MFO	[57]/0
	动态资源分配策略	MPE	[58]/72
	在线资源分配机制	MPE	[59]/60
基于多任务学习优化	层次学习机制	MPE/MFO	[60]/3, [61]/0, [62]/1
	多子种群间学习优化	MFO/MPE	[63]/12, [64]/0, [65]/25, [66]/32, [67]/4
	基于任务关系学习	MFO	[68]/8, [69]/8

将相关性高的任务同时求解,效果明显优于单任务优化;文献[19]从搜索域完全重叠、部分重叠以及完全不重叠3方面分析MFEA性能与搜索域重合度的关系,随着搜索域重叠部分不断地减少,MFEA多任务优化能力也不断地下降;文献[46]基于聚类技术将相似的任务分为一组,并规定信息迁移只能发生在同一簇中;文献[47]基于进化过程中种群分布特征,动态获取任务间相关性等级以决定信息迁移类型.使用一些先验知识以度量任务相关性或相似性,并将相关性高的任务同时求解,可提高知识交融概率.然而,逐个计算任务间 Spearman 相关系数的时间复杂度高,基于高斯模型的贝叶斯优化以概率逼近目标函数,因而不能直接应用于组合优化问题.

3.2.2 构建虚拟多任务环境

受同时处理相似任务能够显著加速多任务收敛启发,文献[20, 43, 48-49]构造了虚拟多任务环境,基于先验知识或相似度给主任务配备强相关性辅助任务或辅助种群,促进主任务进化;文献[50]提出了一种基于异常检测的多任务进化算法,为每个任务分配1个种群和1个异常检测模型,异常检测模型用以学习当前任务与其他在线任务之间的个体关系,可能携带负面知识的个体被认定为离群值,通过异常检测模型识别出的候选迁移个体用以辅助当前任务;文献[51]引入了分类学习系统XOF,通过比较主/辅任务间模式行为,动态指导学习分类器系统间特征传递;当多任务环境中资源受限时,文献[52]采用轮盘赌方法随机选择1个任务作为主任务,剩余任务作为辅助任务协作主任务进化;文献[53-55]基于MPE信息共

享机制,为每个子种群配备了1个或多个代理,该代理协助主种群筛选精英子代,能够显著降低主任务计算成本;文献[56]基于EA染色体上具有代表性点,产生多个预测性方向信息,并将这些信息作为迁移知识协作任务搜索.

辅助任务的引入可显著降低主任务优化难度,但现有寻找辅助任务主要基于一种假设,仍然不知道何种辅助模式在实际应用中是最有效的.

3.2.3 基于任务复杂度量度的信息迁移

MFEA初衷是令低复杂度任务协助难度系数较高的优化问题,即将互补性任务同时求解.如构造Sphere和Ackley函数、Sphere和Rastrigin函数任务组.随着MTO发展,现有MTO算法对所有任务几乎一视同仁,无论任务难易,均享受同等计算资源.然而,当资源受限时,一些任务很难收敛至可接受解.为解决上述问题,文献[57]引入了标准化达成函数衡量任务收敛状态,并基于多步非线性回归方法评估任务复杂性能,在传统资源分配过程基础上灵活调整资源分配强度并包含知识转移信息,该框架虽然改进了MFEA,但资源分配模式单一,不够灵活;文献[58]基于MPE信息共享框架,在MFEA中加入了轮询策略以确定各任务是否可在每个资源分配周期中完成搜索,对复杂性较高的任务,通过交叉/变异方式将更多计算资源注入种群内或种群间演化过程中,以保证该任务持续进化.

在多任务环境中对不同任务合理分配资源,可保证资源利用率,但必须基于任务难度系数已知情况,在实际问题求解中往往较难获取这些信息.

3.2.4 基于多任务间学习优化的信息共享

受机器学习领域多任务学习^[59]思想启发,基于多任务间学习优化的信息迁移是指关联任务在进化过程中互相学习,并将学习所得知识指导任务搜索和进化,任务间共享信息、相互补充,提升彼此的表现。

文献[60]基于MPE在PSO中引入层次任务间学习策略,在跨任务邻域之间共享信息,并将学习所获得知识指导具有不同搜索偏好的粒子,即将最合适的粒子分配给最合适的任务;文献[61]基于MFO在MFEA搜索区域内基于小波基函数设置多个搜索边界,引入动态反向学习策略从统一搜索空间和该任务所在子空间学习产生相反解,达到限定各任务子代个体搜索领域的目的;文献[62]在MFEA中引入了任务间多层次文化学习,基于3种不同锦标赛选择算子从不同文化层次背景种群中挑选父代,并经过交叉操作产生新个体分配给不同任务,但该方法并不能在所有多目标优化问题中展示最优性能;文献[63]在MPE基础上针对各任务所在子种群分布信息建立了任务特征低维子空间,构建最小化子空间差异矩阵学习任务间关系,并将所学信息用于指导各任务子代个体繁殖;文献[64]基于MPE为各子种群建立了独立学习字典以最小化单层分类器中相关约束,并将学习优化后的参数最优值迁移至各任务中;文献[65]以同时优化任务 T_1 和 T_2 为例,将原始种群根据任务个数划分为 P_1 和 P_2 ,构建 T_1 到 T_2 位置映射向量 M_{12} 、 T_2 到 T_1 位置映射向量 M_{21} ,然后将 M_{12} 和 M_{21} 分别纳入 P_1 和 P_2 子代进化过程中,提高子代种群知识共享效率;文献[66]和文献[67]通过互相学习对方任务所在种群进化信息,为自身种群演化或信息迁移节点设置提供启发式信息;文献[68]基于任务关系学习,将每个任务决策空间视为一个流形,不同任务所有决策空间联合建模为一个联合流形投影至潜在空间,同时保留所有任务所需特征和每个流形拓扑结构,然后将学习所得的任务关系表示为联合映射矩阵,用于进化过程中不同任务决策空间之间的信息传递;文献[69]引入梯度下降算法将多任务学习视为多个学习任务,并构建独立成本函数模型学习不同任务模型参数,通过隐式改变成本函数传递模型参数实现任务间信息共享。

多任务学习优化通过在进化过程中实时学习并利用相关任务信息减轻负迁移,在任务数量较大时可受益于这种并行学习或计算模式。然而,如何确定不同来源信息权重复杂度较高,且对任务特征进行学习的成果并不多见。

MTO信息融合过程中,度量任务间特征相似性、

分析任务复杂性以及对任务关系进行学习是实施MTO先前步骤,而这些先前操作对基于MFO和MPE的信息共享框架均适用,具体如表5所示。

3.3 MFO信息迁移类型

多任务环境中,在合适时间传送最需要的知识,可达到“雪中送碳”的目的,文献[70]已从理论上予以证明。在生物种群中,适应性个体要想生存离不开彼此的信息交流。信息交流是指信息的所有者和需求者间彼此互通有无,以达到共享信息资源的目的。在MTO中,信息从所有者传递至需求者的方式可分为不同类型,按照信息是否从信息发出方直接传递给信宿,可分为直接信息交流和间接信息交流。直接信息交流是指迁移信息无需处理直接为对方所接收,在MTO中表现为种群内/种群间不同个体位置/基因、当前种群或邻域最优个体位置迁移给信息需求任务;而间接信息交流是指迁移信息经过映射或转换后传递给信息接收者,如策略借鉴、神经信息或种群进化/分布信息迁移等。

3.3.1 基于位置/基因共享的直接信息迁移

由图1多任务优化信息共享示意图可知,具有相同单调趋势的多个任务共享信息,在提高种群多样性的同时,还可加速任务进化过程。基于MFO和MPE的MTO算法大多通过种群内个体位置迭代或基因交互趋近全局最有解,而将邻域种群个体位置或基因纳入当前任务进化过程中^[71-72]是最为直接的信息共享类型。因文献[7]已对该种直接信息迁移作出较为详细的综述,这里不再赘述。

直接信息迁移模式大多模仿遗传算法交叉操作,将邻居种群个体或全局最优位置直接纳入当前粒子进化过程中,这在扩大种群搜索范围和增强物种多样性等方面存在优势,但对从源域迁移过来的信息是否适配于目标域的研究尚不深刻。

3.3.2 基于源域求解经验的间接信息迁移

在现实生活中,人类善于利用经验处理类似问题,甚至能够挖掘表面上毫不相关的任务的内在联系。传统优化算法一般基于先验知识为0的假设,且求解问题能力并不会随着历史经验的增长而提高^[73]。若目标任务(目标域)与历史任务(源域)含有一些共同交叉特征,将存储多源任务中的优良模型、求解经验映射/转换至目标任务优化过程中或作为目标任务启发式信息,不仅能够降低目标任务求解过程中大量时间和费用消耗,还可在一定程度上改善目标任务的求解性能^[74-76]。

为了避免将源域无关信息迁移至目标任务中造

成负迁移,文献[77]提出了两阶段信息迁移框架,首先将源域任务按照分类性能进行分组,给予目标预测能力强的源域任务较高权重,然后利用所有不同分类性能源域任务训练目标域数据,提高了目标任务分类准确率;文献[78]将源域强化学习过程中存储的有用信息作为任务启发式信息,迭代映射至目标任务搜索过程中,指导目标种群搜索;为了使得历史经验能够在具有独特属性的问题间重用,文献[79]提出了一种单层去噪自编码进化搜索范式,构建历史任务种群与目标任务种群映射矩阵,将过去搜索经验中获得的问题解决方案迭代映射至当前种群中;文献[80]在解决多任务多目标优化问题时,若源域任务的知识迁移解决方案在目标任务中是非支配的,则为正转移,该正转移解决方案的邻域将被选为子代个体搜索区域。

文献[81]引入了受限 Boltzmann 机从源域每层网络决策空间中提取低效特征构造非线性映射矩阵,然后每隔固定迭代次数将这些特征迁移至目标任务进化过程中;文献[82]通过获取多源历史任务求解过程中精英解种群分布,按一定概率以堆积密度估计混合模型形式,传递给与其相关性高的新任务求解过程中;文献[83]引入了6种信息反馈模型,并将历史种群个体中存储的有价值信息反馈给目标任务;文献[84]提出了一种基于种群分布的两阶段自适应知识转移多目标进化多任务优化算法,该算法基于概率模型提取反映总体搜索趋势的知识,提高了目标优化任务收敛性能;文献[85]基于文化传播理论,提出了两种信息策略,即精英解传播(将处于 Pareto 前沿个体位置传播给种群其他个体)和水平文化传播(实现源任务求解经验映射至目标任务),减少信息负迁移的消极

影响;文献[86]基于多种群模式,存储成功迁移的概率参数 rmp ,以指导目标任务信息交互;为解决因源域与目标域特征或优秀解分布不匹配而导致的信息负迁移问题,文献[87]构建了基于源域和目标域非线性映射函数,将源任务和目标任务映射至一个公共空间,以适应目标域不同类型搜索空间等。

通过策略模仿或将历史任务中有效数据和知识迭代映射至目标任务求解过程中,显著加快了目标任务收敛和提高解质量^[88]。然而,存储多源任务历史经验需要花费大量存储空间,且随着历史任务的增加,从历史经验堆中逐个为新任务配对以找到相关性高的最优经验知识,需要耗费大量时间。同时,MTO 信息迁移类型可变化多样^[89],对具体优化问题具有较强依赖性,但针对不同信息迁移类型,MFO 和 MPE 均适用。

3.4 MTO 典型应用领域

MTO 算法在理论上不断完善或提高的同时,在具体应用领域也得到了进一步扩充。文献[90]回顾了关于 MTO 几个面向应用的探索,根据其各自应用领域将其归纳为6个大类,每一类均阐述了 MTO 基本动机,并包含代表性实验研究。本文则根据优化问题的类型将 MTO 应用领域分为4大类:多任务多目标优化问题;多任务多约束优化问题;多任务二元离散优化问题(以 MTO 算法为搜索策略,分形技术(常用分形维数或多重分形技术)作为子集评估度量准则);多任务序列型优化问题。具体如表6所示。在 MTO 典型应用领域均涉及了 MFO/MPE 依托框架,且在序列型和二元离散型优化问题中应用较多,而在多目标和多约束优化问题中则较少应用。

表6 MTO 典型应用领域

分类	依托框架	典型应用领域	代表文献/引用次数
多任务多目标优化问题	MFO/MPE	电力系统调度, 太阳能可再生能源系统优化, 污染路径问题	[91]/17,[92]/32,[93]/3
多任务多约束优化问题	MFO/MPE	树脂成型固化工艺优化	[11]/40,[42]/12
多任务二元离散优化问题	MFO/MPE	医学图像关键特征提取, 关键指标体系构建	[94]/2,[95]/2,[96]/4,[97]/2,[98]/2
多任务序列型优化问题	MFO/MPE	虚拟机布局问题,车辆路径调度, 随机团队定向问题,多任务分配 模糊系统优化	[99]/81,[100]/28,[101]/31,[102]/1 [103]/6,[104]/4,[105]/2,[106]/16 [107]/19,[108]/8,[109]/2

4 总结和展望

EC 与 SI 虽然有着不同计算模型,但均具有潜在并行智能特征。MTO 通过挖掘 EC 和 SI 隐并行性,借

助 MFO 和 MPE 信息共享框架,在不同优化问题上有着卓越的表现。但作为进化算法领域一个新研究方向,MTO 研究仍然处于初级阶段,故未来研究可从以

下3方面展开.

1) 理论研究需进一步深化. 现有MTO算法着重围绕信息迁移节点、信息迁移方式、信息迁移类型以及应用等方面展开研究, 本文第2.2.4节虽然从复杂系统视角对比分析了MFO与MPE的异同, 但MTO种群内部信息交互细节以及MTO作为整体群落所拥有的独有新特征如群落空间格局、群落种群密度则未见研究. 复杂系统建模能够对不同系统机理的复杂程度进行深入刻画, 因而, 构造基于个体、群体和群落数学模型描述MTO复杂系统动力学行为, 并引入细胞自动机仿真模拟长时间尺度内多任务MTO复杂系统层级智能涌现特征, 对拓宽MTO理论和方法体系具有重要价值.

2) 从控制种群多样性角度遏制负迁移的消极影响. 信息负迁移会抑制干扰多任务优化性能, 这是目前尚未完全解决的难题之一. 现有文献针对搜索域重合度、任务相似性进行了广泛而深入的研究, 提出了一系列有效改进措施, 但从种群多样性角度遏制信息负迁移却鲜有报道. 文献[23]虽然通过数独实验证实了MTO本质在于知识共享, 但任务间频繁信息迁移会导致种群基因型过度增加, 从而降低MTO的收敛速度和性能. 因而如何在多任务进化过程中实时测算种群多样性指数^[110], 并设置相关阈值进行控制, 也是一个有趣的研究方向.

3) 将MTO算法应用于多任务动态复杂优化问题^[111-112]. 随着全球经济竞争日趋激烈, 资源能源日益紧张, 在环保和节能意识越发强烈的背景下, 工业制造、农业生产以及国防、交通、金融等众多行业追求高产出、高收益、高效益、低排放、保安全, 从而面临着需要解决多峰分布、非凸约束、局部极值环境等更为复杂的优化难题. 动态复杂优化问题在不同时期往往涉及不同状态, 具有较强不确定性. 如何改进现有MTO算法, 在较低时间复杂度下使得多任务信息共享机制也适用于复杂动态优化问题, 也是一个有价值的研究方向.

参考文献(References)

- [1] Rich C. Multitask learning[J]. *Journal of Machine Learning-Special Issue on Inductive Transfer*, 1997, 28(1): 41-75.
- [2] Kim H. Parallel genetic algorithm with a knowledge base for a redundancy allocation problem considering the sequence of heterogeneous components[J]. *Expert Systems With Applications*, 2018, 113: 328-338.
- [3] Gupta A, Ong Y S, Feng L. Multifactorial evolution: Toward evolutionary multitasking[J]. *IEEE Transactions on Evolutionary Computation*, 2016, 20(3): 343-357.
- [4] Zhou L, Feng L, Gupta A, et al. Learnable evolutionary search across heterogeneous problems via kernelized autoencoding[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(3): 567-581.
- [5] 徐庆征, 杨恒, 王娜, 等. 多因子进化算法研究进展[J]. *计算机工程与应用*, 2018, 54(11): 15-20. (Xu Q Z, Yang H, Wang N, et al. Recent advances in multifactorial evolutionary algorithm[J]. *Computer Engineering and Applications*, 2018, 54(11): 15-20.)
- [6] Xu Q Z, Wang N, Wang L, et al. Multi-Task optimization and multi-task evolutionary computation in the past five years: A brief review[J]. *Mathematics*, 2021, 9(8): 1-44.
- [7] Osaba E, del Ser J, Martinez A D, et al. Evolutionary multitask optimization: A methodological overview, challenges, and future research directions[J]. *Cognitive Computation*, 2022, 14(3): 927-954.
- [8] Tan K C, Feng L, Jiang M. Evolutionary transfer optimization—A new frontier in evolutionary computation research[J]. *IEEE Computational Intelligence Magazine*, 2021, 16(1): 22-33.
- [9] Wei T Y, Wang S B, Zhong J H, et al. A review on evolutionary multi-task optimization: Trends and challenges[J]. *IEEE Transactions on Evolutionary Computation*, 2021: 1.
- [10] Cheng M Y, Gupta A, Ong Y S, et al. Coevolutionary multitasking for concurrent global optimization: With case studies in complex engineering design[J]. *Engineering Applications of Artificial Intelligence*, 2017, 64: 13-24.
- [11] Lyu C, Shi Y H, Sun L J. A novel multi-task optimization algorithm based on the brainstorming process[J]. *IEEE Access*, 2020, 8: 217134-217149.
- [12] Rice J, Cloninger C R, Reich T. Multifactorial inheritance with culture transmission and assortative mating. I. description and basic properties of the unitary MTOdel[J]. *The American Journal of Human Genetics*, 1978, 30(6): 618-643.
- [13] Li M X, Yang G L, Li X Q, et al. Variable universe fuzzy control of adjustable hydraulic torque converter based on multi-population genetic algorithm[J]. *IEEE Access*, 2019, 7: 29236-29244.
- [14] Zhao Z B, Liu B, Zhang C R, et al. An improved adaptive NSGA-II with multi-population algorithm[J]. *Applied Intelligence*, 2019, 49(2): 569-580.
- [15] 程美英, 钱乾, 倪志伟, 等. 信息交互多任务粒子群算法[J]. *模式识别与人工智能*, 2019, 32(5): 385-397. (Cheng M Y, Qian Q, Ni Z W, et al. Information exchange particle swarm optimization for multitasking[J]. *Pattern Recognition and Artificial Intelligence*, 2019, 32(5): 385-397.)

- [16] Caruana R A. Multitask learning: A knowledge-based source of inductive bias[J]. *Machine Learning Proceedings*, 1993, 10(1): 41-48.
- [17] Da B S, Gupta A, Ong Y S, et al. The boon of gene-culture interaction for effective evolutionary multitasking[C]. *Artificial Life and Computational Intelligence*, 2016, 9592: 54-65.
- [18] Gupta A, Ong Y S, Da B S, et al. Measuring complementarity between function landscapes in evolutionary multitasking[C]. *IEEE Congress on Evolutionary Computation*. Vancouver, 2016: 1-8.
- [19] Gupta A, Ong Y S, Da B, et al. Landscape synergy in evolutionary multitasking[C]. *IEEE Congress on Evolutionary Computation*. Vancouver, 2016: 3076-3083.
- [20] Da B S, Ong Y S, Feng L, et al. Evolutionary multitasking for single-objective continuous optimization: Benchmark problems, performance metric and baseline results[C]. *IEEE Congress on Evolutionary Computation*. San Sebastian, 2017: 1706-1710.
- [21] Zhou L, Feng L, Zhong J H, et al. A study of similarity measure between tasks for multifactorial evolutionary algorithm[C]. *Genetic and Evolutionary Computation Conference*. Kyoto, 2018: 229-230.
- [22] Yogatama D, Mann G. Efficient transfer learning method for automatic hyper parameter tuning[J]. *Journal of Machine Learning Research*, 2014, 33: 1077-1085.
- [23] Gupta A, Ong Y S. Genetic transfer or population diversification? Deciphering the secret ingredients of evolutionary multitask optimization[C]. *IEEE Symposium Series on Computational Intelligence*. Athens, 2016: 1-7.
- [24] Gupta A, Mańdziuk J, Ong Y S. Evolutionary multitasking in bi-level optimization[J]. *Complex & Intelligent Systems*, 2015, 1(1/2/3/4): 83-95.
- [25] 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.
- [26] Feng L, Zhou W, Zhou L, et al. An empirical study of multifactorial PSO and multifactorial DE[C]. *IEEE Congress on Evolutionary Computation*. Donostia, 2017: 921-928.
- [27] 程美英. 基于二元蚁群优化算法和分形维数的属性选择方法[D]. 合肥: 合肥工业大学, 2017: 50-70. (Cheng M Y. Attribute selection method based on binary ant colony optimization and fractal dimension[D]. Hefei: Hefei University of Technology, 2017: 50-70.)
- [28] 程美英, 钱乾, 倪志伟, 等. 信息筛选多任务优化自组织迁移算法[J]. *计算机应用*, 2021, 41(6): 1748-1755. (Cheng M Y, Qian Q, Ni Z W, et al. Self-organized migrating algorithm for multi-task optimization with information filtering[J]. *Journal of Computer Applications*, 2021, 41(6): 1748-1755.)
- [29] Yang C E, Ding J L, Jin Y C, et al. Multitasking multiobjective evolutionary operational indices optimization of beneficiation processes[J]. *IEEE Transactions on Automation Science and Engineering*, 2019, 16(3): 1046-1057.
- [30] Yang C E, Ding J L, Tan K C, et al. Two-stage assortative mating for multi-objective multifactorial evolutionary optimization[C]. *IEEE 56th Annual Conference on Decision and Control*. Melbourne, 2017: 76-81.
- [31] Tang Z D, Gong M G. Adaptive multifactorial particle swarm optimization[J]. *CAAI Transactions on Intelligence Technology*, 2019, 4: 37-46.
- [32] Thanh Binh H T, Quoc Tuan N, Thanh Long D C. A multi-objective multi-factorial evolutionary algorithm with reference-point-based approach[C]. *IEEE Congress on Evolutionary Computation*. Wellington, 2019: 2824-2831.
- [33] Thang T B, Dao T C, Long N H, et al. Parameter adaptation in multifactorial evolutionary algorithm for many-task optimization[J]. *Memetic Computing*, 2021, 13(4): 433-446.
- [34] Li G H, Zhang Q F, Gao W F. Multipopulation evolution framework for multifactorial optimization[C]. *GECCO'18: Proceedings of the Genetic and Evolutionary Computation Conference Companion*. Kyoto, 2018: 215-216.
- [35] Li G H, Lin Q Z, Gao W F. Multifactorial optimization via explicit multipopulation evolutionary framework[J]. *Information Sciences*, 2020, 512: 1555-1570.
- [36] 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.
- [37] Bali K K, Gupta A, Ong Y S, et al. Cognizant multitasking in multiobjective multifactorial evolution: MO-MFEA-II[J]. *IEEE Transactions on Cybernetics*, 2021, 51(4): 1784-1796.
- [38] Shen F, Liu J, Wu K. Evolutionary multitasking network reconstruction from time series with online parameter estimation[J]. *Knowledge-Based Systems*, 2021, 222: 107019.
- [39] Yao J, Nie Y D, Zhao Z H, et al. Self-adaptive multifactorial evolutionary algorithm for multitasking production optimization[J]. *Journal of Petroleum Science and Engineering*, 2021, 205: 108900.
- [40] Feng L, Zhou L, Zhong J H, et al. Evolutionary multitasking via explicit autoencoding[J]. *IEEE Transactions on Cybernetics*, 2019, 49(9): 3457-3470.

- [41] Liang J, Qiao K J, Yuan M H, et al. Evolutionary multi-task optimization for parameters extraction of photovoltaic models[J]. *Energy Conversion and Management*, 2020, 207: 112509.
- [42] 程美英, 钱乾, 倪志伟, 等. 多任务处理协同进化粒子群算法[J]. *模式识别与人工智能*, 2018, 31(4): 322-334.
(Cheng M Y, Qian Q, Ni Z W, et al. Co-evolutionary particle swarm optimization for multitasking[J]. *Pattern Recognition and Artificial Intelligence*, 2018, 31(4): 322-334.)
- [43] 程美英, 钱乾, 倪志伟, 等. 基于虚拟多任务二元粒子群算法和分形维数的雾霾天气预测方法[J]. *系统科学与数学*, 2018, 38(5): 105-119.
(Cheng M Y, Qian Q, Ni Z W, et al. Virtual multitasking binary particle swarm optimization and fractal dimension for haze forecast[J]. *Journal of Systems Science and Mathematical Science*, 2018, 38(5): 105-119.)
- [44] Hashimoto R, Ishibuchi H, Masuyama N, et al. Analysis of evolutionary multi-tasking as an island model[C]. *Proceedings of the genetic and evolutionary computation conference*. Kyoto, 2018: 1894-1897.
- [45] Wen Y W, Ting C K. Parting ways and reallocating resources in evolutionary multitasking[C]. *Proceedings of the IEEE Congress on Evolutionary Computation*. Wellington, 2019: 2404-2411.
- [46] Tang J, Chen Y, Deng Z, et al. A group-based approach to improve multifactorial evolutionary algorithm[C]. *Proceedings of International Joint Conferences on Artificial Intelligence*. Stockholm, 2018: 3870-3876.
- [47] Cai Y Q, Peng D M, Liu P Z, et al. Evolutionary multi-task optimization with hybrid knowledge transfer strategy[J]. *Information Sciences*, 2021, 580: 874-896.
- [48] Feng Y L, Feng L, Hou Y Q, et al. Large-scale optimization via evolutionary multitasking assisted random embedding[C]. *IEEE Congress on Evolutionary Computation*. Glasgow, 2020: 1-8.
- [49] Ma X L, Yin J, Zhu A M, et al. Enhanced multifactorial evolutionary algorithm with meme helper-tasks[J]. *IEEE Transactions on Cybernetics*, 2022, 52(8): 7837-7851.
- [50] Wang C, Liu J, Wu K, et al. Solving multitask optimization problems with adaptive knowledge transfer via anomaly detection[J]. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 304-318.
- [51] Nguyen T B, Browne W N, Zhang M J. Relatedness measures to aid the transfer of building blocks among multiple tasks[C]. *Proceedings of the Genetic and Evolutionary Computation Conference*. Cancun, 2020: 377-385.
- [52] Li G H, Zhang Q F, Wang Z K. Evolutionary competitive multitasking optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 278-289.
- [53] Zhang F F, Mei Y, Nguyen S, et al. Surrogate-assisted evolutionary multitask genetic programming for dynamic flexible job shop scheduling[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(4): 651-665.
- [54] Wang H D, Feng L, Jin Y C, et al. Surrogate-assisted evolutionary multitasking for expensive minimax optimization in multiple scenarios[J]. *IEEE Computational Intelligence Magazine*, 2021, 16(1): 34-48.
- [55] Ji X F, Zhang Y, Gong D W, et al. Multisurrogate-assisted multitasking particle swarm optimization for expensive multimodal problems[J]. *IEEE Transactions on Cybernetics*, 2021: 1-15.
- [56] Dang Q L, Gao W F, Gong M G. Multiobjective multitasking optimization assisted by multidirectional prediction method[J]. *Complex & Intelligent Systems*, 2022, 8(2): 1663-1679.
- [57] Wei T Y, Zhong J H. Towards generalized resource allocation on evolutionary multitasking for multi-objective optimization[J]. *IEEE Computational Intelligence Magazine*, 2021, 16(4): 20-37.
- [58] Gong M G, Tang Z D, Li H, et al. Evolutionary multitasking with dynamic resource allocating strategy[J]. *IEEE Transactions on Evolutionary Computation*, 2019, 23(5): 858-869.
- [59] Caruana R. Multitask learning[J]. *Autonomous Agents and Multi-Agent Systems*, 1998, 27(1): 95-133.
- [60] Tang Z D, Gong M G, Xie Y, et al. Multi-task particle swarm optimization with dynamic neighbor and level-based inter-task learning[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2022, 6(2): 300-314.
- [61] Li N, Wang L, Jiang Q Y, et al. An improved genetic transmission and dynamic-opposite learning strategy for multitasking optimization[J]. *IEEE Access*, 2021, 9: 131789-131805.
- [62] Yao L Z, Long W, Yi J, et al. A novel tournament selection based on multilayer cultural characteristics in gene-culture coevolutionary multitasking[J]. *Soft Computing*, 2021, 25(14): 9529-9543.
- [63] 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.
- [64] Liu B, Xie H X, Xiao Y S. Multi-task analysis discriminative dictionary learning for one-class learning[J]. *Knowledge-Based Systems*, 2021, 227: 107195.
- [65] Liang Z P, Zhang J, Feng L, et al. A hybrid of

- genetic transform and hyper-rectangle search strategies for evolutionary multi-tasking[J]. *Expert Systems With Applications*, 2019, 138: 112798.
- [66] Zhou L, Feng L, Tan K C, et al. Toward adaptive knowledge transfer in multifactorial evolutionary computation[J]. *IEEE Transactions on Cybernetics*, 2021, 51(5): 2563-2576.
- [67] Gupta A, Ong Y S. Multitask knowledge transfer across problems, in *Memetic[M]*. Springer, 2019, 21: 83-92.
- [68] Chen Z F, Zhou Y R, He X Y, et al. Learning task relationships in evolutionary multitasking for multi-objective continuous optimization[J]. *IEEE Transactions on Cybernetics*, 2020, 18: 1-12.
- [69] Bai L, Ong Y S, He T T, et al. Multi-task gradient descent for multi-task learning[J]. *Memetic Computing*, 2020, 12(4): 355-369.
- [70] Bai L, Lin W, Gupta A, et al. From multitask gradient descent to gradient-free evolutionary multitasking: A proof of faster convergence[J]. *IEEE Transactions on Cybernetics*, 2022, 52(8): 8561-8573.
- [71] Song H, Qin A K, Tsai P W, et al. Multitasking multi-swarm optimization[C]. *Proceedings of the IEEE Congress on Evolutionary Computation*. Wellington, 2019: 1937-1944.
- [72] Yin J, Zhu A M, Zhu Z X, et al. Multifactorial evolutionary algorithm enhanced with cross-task search direction[C]. *Proceedings of the IEEE Congress on Evolutionary Computation*. Wellington, 2019: 2244-2251.
- [73] Gupta A, Ong Y S. Back to the roots: Multi-X evolutionary computation[J]. *Cognitive Computation*, 2019, 11(1): 1-17.
- [74] Louis S J, McDonnell J. Learning with case-injected genetic algorithms[J]. *IEEE Transactions on Evolutionary Computation*, 2004, 8(4): 316-328.
- [75] Feng L, Ong Y S, Lim M H, et al. Memetic search with interdomain learning: A realization between CVRP and CARP[J]. *IEEE Transactions on Evolutionary Computation*, 2015, 19(5): 644-658.
- [76] Gupta A, Ong Y S, Feng L. Insights on transfer optimization: Because experience is the best teacher[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2018, 2(1): 51-64.
- [77] Ge L, Gao J, Ngo H, et al. On handling negative transfer and imbalanced distributions in multiple source transfer learning[J]. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, 2014, 7(4): 254-271.
- [78] Bianchi R A C, Santos P E, Silva I J, et al. Heuristically accelerated reinforcement learning by means of case-based reasoning and transfer learning[J]. *Journal of Intelligent & Robotic Systems*, 2018, 91(2): 301-312.
- [79] Feng L, Ong Y S, Jiang S W, et al. Autoencoding evolutionary search with learning across heterogeneous problems[J]. *IEEE Transactions on Evolutionary Computation*, 2017, 21(5): 760-772.
- [80] Lin J B, Liu H L, Tan K C, et al. An effective knowledge transfer approach for multiobjective multitasking optimization[J]. *IEEE Transactions on Cybernetics*, 2021, 51(6): 3238-3248.
- [81] Wu K, Wang C, Liu J. Evolutionary multitasking multilayer network reconstruction[J]. *IEEE Transactions on Cybernetics*, DOI: 10.1109/TCYB.2021.3090769.
- [82] Da B S, Gupta A, Ong Y S. Curbing negative influences online for seamless transfer evolutionary optimization[J]. *IEEE Transactions on Cybernetics*, 2019, 49(12): 4365-4378.
- [83] Wang G G, Tan Y. Improving metaheuristic algorithms with information feedback models[J]. *IEEE Transactions on Cybernetics*, 2019, 49(2): 542-555.
- [84] Liang Z P, Liang W Q, Wang Z Q, et al. Multiobjective evolutionary multitasking with two-stage adaptive knowledge transfer based on population distribution[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2022, 52(7): 4457-4469.
- [85] Xu Z W, Liu X M, Zhang K, et al. Cultural transmission based multi-objective evolution strategy for evolutionary multitasking[J]. *Information Sciences*, 2022, 582: 215-242.
- [86] Li G H, Lin Q Z, Gao W F. Multifactorial optimization via explicit multipopulation evolutionary framework[J]. *Information Sciences*, 2020, 512: 1555-1570.
- [87] Lim R, Gupta A, Ong Y S, et al. Non-linear domain adaptation in transfer evolutionary optimization[J]. *Cognitive Computation*, 2021, 13(2): 290-307.
- [88] Tan K C, Feng L, Jiang M. Evolutionary transfer optimization—A new frontier in evolutionary computation research[J]. *IEEE Computational Intelligence Magazine*, 2021, 16(1): 22-33.
- [89] Shao L, Zhu F, Li X L. Transfer learning for visual categorization: A survey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(5): 1019-1034.
- [90] 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.
- [91] Wu T, Bu S Q, Wei X, et al. Multitasking multi-objective operation optimization of integrated energy system considering biogas-solar-wind renewables[J]. *Energy Conversion and Management*, 2021, 229: 113736.
- [92] Rauniyar A, Nath R, Muhuri P K. Multi-factorial

- evolutionary algorithm based novel solution approach for multi-objective pollution-routing problem[J]. *Computers & Industrial Engineering*, 2019, 130: 757-771.
- [93] Qiao K J, Yu K J, Qu B Y, et al. An evolutionary multitasking optimization framework for constrained multiobjective optimization problems[J]. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 263-277.
- [94] Shi J, Shao T, Liu X D, et al. Evolutionary multitask ensemble learning model for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 936-950.
- [95] Chen K, Xue B, Zhang M J, et al. Evolutionary multitasking for feature selection in high-dimensional classification via particle swarm optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2022, 26(3): 446-460.
- [96] Bi Y, Xue B, Zhang M J. Learning and sharing: A multitask genetic programming approach to image feature learning[J]. *IEEE Transactions on Evolutionary Computation*, 2022, 26(2): 218-232.
- [97] Zhang N, Gupta A, Chen Z F, et al. Evolutionary machine learning with minions: A case study in feature selection[J]. *IEEE Transactions on Evolutionary Computation*, 2022, 26(1): 130-144.
- [98] Shi J, Zhang X, Liu X D, et al. Multicriteria semi-supervised hyperspectral band selection based on evolutionary multitask optimization[J]. *Knowledge-Based Systems*, 2022, 240: 107934.
- [99] Yuan Y, Ong Y S, Gupta A, et al. Evolutionary multitasking in permutation-based combinatorial optimization problems: Realization with TSP, QAP, LOP, and JSP[C]. *IEEE Region 10 Conference. Singapore*, 2016: 3157-3164.
- [100] Feng L, Zhou L, 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.
- [101] 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.
- [102] Ji J J, Guo Y N, Gong D W, et al. Evolutionary multi-task allocation for mobile crowdsensing with limited resource[J]. *Swarm and Evolutionary Computation*, 2021, 63: 100872.
- [103] Zhou Y, Wang T, Peng X. MFEA-IG: A multi-task algorithm for mobile agents path planning[C]. *Proceedings of IEEE Congress on Evolutionary Computation. Glasgow*, 2020: 1-7.
- [104] Binh H T T, Thang T B, Thai N D, et al. A bi-level encoding scheme for the clustered shortest-path tree problem in multifactorial optimization[J]. *Engineering Applications of Artificial Intelligence*, 2021, 100: 104187.
- [105] Zheng X, Chen Y, Alam M, et al. Multi-task scheduling based on classification in mobile edge computing[J]. *Electronics*, DOI: 10.3390/electronics.8090938.
- [106] Wang C, Ma H, Chen G, et al. Evolutionary multitasking for semantic web service composition[C]. *Proceedings of IEEE Congress on Evolutionary Computation. Wellington*, 2019: 10-13.
- [107] Wu D R, Tan X F. Multitasking genetic algorithm (MTGA) for fuzzy system optimization[J]. *IEEE Transactions on Fuzzy Systems*, 2020, 28(6): 1050-1061.
- [108] Zhang K, Hao W N, Yu X H, et al. A multitasking genetic algorithm for mamdani fuzzy system with fully overlapping triangle membership functions[J]. *International Journal of Fuzzy Systems*, 2020, 22(8): 2449-2465.
- [109] Shang Q X, Huang Y X, Wang Y, et al. Solving vehicle routing problem by memetic search with evolutionary multitasking[J]. *Memetic Computing*, 2022, 14(1): 31-44.
- [110] Yu S H, Su S B, Huang L. A simple diversity guided firefly algorithm[J]. *Kybernetes*, 2015, 44(1): 43-56.
- [111] Fu H, Lewis P R, Sendhoff B, et al. What are dynamic optimization problems?[C]. *Proceedings of the IEEE Congress on Evolutionary Computation. Beijing*, 2014: 1550-1557.
- [112] Ruan G, Minku L L, Menzel S, et al. When and how to transfer knowledge in dynamic multi-objective optimization[C]. *Proceedings of IEEE Symposium Series on Computational Intelligence. Xiamen*, 2019: 2034-2041.

作者简介

程美英(1983—),女,讲师,博士,从事群体智能优化、多任务优化等研究, E-mail: 02550@zjhu.edu.cn;

钱乾(1983—),男,讲师,硕士,从事进化计算的研究, E-mail: 02595@zjhu.edu.cn;

倪志伟(1965—),男,教授,博士,从事智能优化等研究, E-mail: zhwnelson@163.com.