

# 控制与决策

Control and Decision

## 基于跨域知识动态筛选与非负子空间对齐的多任务进化算法

殷涛, 姚立忠, 董浩铭, 罗海军

引用本文:

殷涛, 姚立忠, 董浩铭, 等. 基于跨域知识动态筛选与非负子空间对齐的多任务进化算法[J]. 控制与决策, 2026, 41(4): 1055-1064.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0529>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于弱关联的自适应高维多目标进化算法

A weak association-based adaptive evolutionary algorithm for manyobjective optimization

控制与决策. 2021, 36(8): 1804-1814 <https://doi.org/10.13195/j.kzyjc.2019.1723>

#### 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>

#### 基于复杂昂贵仿真的体系效能多目标优化

Complex and expensive simulation based multi-objective optimization to system-of-system effectiveness

控制与决策. 2021, 36(3): 589-598 <https://doi.org/10.13195/j.kzyjc.2019.0844>

#### 求解约束优化问题的改进果蝇优化算法及其工程应用

Improved fruit fly optimization algorithm for solving constrained optimization problems and engineering applications

控制与决策. 2021, 36(2): 314-324 <https://doi.org/10.13195/j.kzyjc.2019.0557>

#### 基于动态资源权重的多技能项目调度启发式算法

Dynamic resource priority-based heuristics for multi-skill resource constrained project scheduling problem

控制与决策. 2021, 36(10): 2553-2561 <https://doi.org/10.13195/j.kzyjc.2020.0070>

# 基于跨域知识动态筛选与非负子空间对齐的 多任务进化算法

殷涛, 姚立忠<sup>†</sup>, 董浩铭, 罗海军

(重庆师范大学 物理与电子工程学院, 重庆 401331)

**摘要:** 多任务进化通过跨域知识正迁移可实现比传统进化算法更佳的收敛性能. 然而, 如何筛选有益知识以及设计高效的迁移方式仍然是多任务知识迁移亟需攻关的难题. 鉴于此, 提出一种基于跨域知识动态筛选与非负子空间对齐的多任务优化算法. 首先, 设计跨域知识动态筛选机制, 计算源任务解到目标任务种群分布、目标任务解到自身种群分布的马氏距离求取动态筛选阈值以实现有益解直接迁移; 然后, 针对剩余跨域知识差异较大的未迁移解, 提出非负子空间对齐映射策略, 利用非负矩阵分解提取多任务种群高维特征的低维表示, 并最小化子空间差异以减少知识负迁移; 接着, 基于跨域知识动态筛选与非负子空间对齐的互补机制, 给出所提出多任务优化算法的完整框架; 最后, 为验证所提出算法的有效性, 在多任务基准测试套件和真实铝电解能耗优化问题上进行消融、对比以及验证实验. 实验结果表明, 与其他 5 种先进多任务优化算法相比, 所提出框架具有显著的竞争性优势.

**关键词:** 多任务优化; 进化算法; 知识迁移; 马氏距离; 铝电解; 能耗优化

中图分类号: TP306.1

文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0529

引用格式: 殷涛, 姚立忠, 董浩铭, 等. 基于跨域知识动态筛选与非负子空间对齐的多任务进化算法 [J]. 控制与决策, 2026, 41(4): 1055-1064.

## Evolutionary multitasking algorithm based on dynamic cross-domain knowledge screening and non-negative subspace alignment

YIN Tao, YAO Li-zhong<sup>†</sup>, DONG Hao-ming, LUO Hai-jun

(College of Physics and Electronic Engineering, Chongqing Normal University, Chongqing 401331, China)

**Abstract:** Evolutionary multitasking (EMT) utilizes positive cross-domain knowledge transfer to achieve better convergence performance compared to traditional evolutionary algorithms. However, identifying beneficial knowledge and designing efficient transfer mechanisms remain key challenges. Therefore, this paper proposes an evolutionary multitasking algorithm that integrates dynamic cross-domain knowledge screening and non-negative subspace alignment (EMT-DNSA). First, a dynamic cross-domain knowledge selection mechanism is designed, where the Mahalanobis distance between the source and target task distributions is used to calculate the threshold for direct migration of beneficial solutions. Second, for untransferred solutions with large cross-domain knowledge differences, a non-negative subspace alignment strategy is proposed, using non-negative matrix factorization to extract low-dimensional representations of high-dimensional features and minimize subspace differences to reduce negative transfer. Third, the complete framework of the proposed multi-task optimization algorithm is presented, based on the complementary mechanisms of knowledge selection and subspace alignment. Finally, ablation, comparison, and verification experiments on a multi-task benchmark suite and a real-world aluminium electrolytic energy consumption problem validate the algorithm's effectiveness. The results demonstrate significant competitive advantages over five other advanced algorithms.

**Keywords:** multitasking optimization; evolutionary algorithm; knowledge transfer; Mahalanobis distance; aluminum electrolysis; energy consumption optimization

收稿日期: 2025-05-21; 录用日期: 2025-07-07.

基金项目: 重庆市教委科学技术研究重点项目 (KJZD-K202400513); 重庆市自然科学基金项目 (CSTB2023NSCQ-MSX0537).

责任编辑: 王凌.

<sup>†</sup>通信作者. E-mail: lizhong\_yao@cqnu.edu.cn.

## 0 引言

进化算法 (EAs) 通过模拟生物进化机制已成为解决复杂非线性优化问题的核心范式之一<sup>[1-2]</sup>。然而, 现实工程场景中普遍存在多任务协同优化需求 (如并行设计、参数联合调优等), 传统单任务 EAs<sup>[3-4]</sup> 因其独立优化范式存在经验复用障碍, 难以挖掘潜在跨任务关联知识。近年来, 多任务进化算法 (EMT) 通过跨任务知识迁移机制, 在进化计算领域展现出了显著优势<sup>[5]</sup>。其机理在于通过隐性并行搜索和互补信息融合, 能够突破单任务优化的局限, 从而在收敛速度和全局搜索能力上实现双向提升。目前, EMT 在车辆路径规划<sup>[6-7]</sup>、光伏模型参数提取<sup>[8]</sup>、铝电解工艺优化<sup>[9-10]</sup> 等工程领域取得了显著成效, 验证了其解决复杂工业问题的可行性。

EMT 通过跨任务知识迁移实现多任务协同优化, 其关键挑战聚焦于如何在动态优化过程中有选择性且高效地传递有益信息<sup>[11]</sup>。Gupta 等<sup>[12]</sup> 首次提出了多因子进化算法 (MFEA), 通过引入随机交配概率 (RMP) 来调控不同任务间的知识迁移程度; 此后, Bali 等<sup>[13]</sup> 提出了一种具有在线转移参数估计的算法 MFEA-II, 通过将对称 RMP 矩阵代替单一 RMP 来控制不同任务间知识迁移的程度; 为找到更具有迁移价值的解, Lin 等<sup>[14]</sup> 通过寻找实现正迁移的解, 随后选取了其邻近解作为下一代的迁移解; 在文献<sup>[15]</sup> 中, 使用了增量朴素贝叶斯分类器识别转移个体; Chen 等<sup>[16]</sup> 引入了迁移秩来量化转移解的优先级, 优先选择高迁移秩的解, 而对于具有相同秩的解, 利用 KNN 分类器进行选择; Gao 等<sup>[17]</sup> 提出了一种基于二部图的 EMT 转移解选择策略, 并通过历史知识修正策略来处理二部图识别知识时的异常情况; 为解决昂贵优化问题, Liu 等<sup>[18]</sup> 使用了高斯分布来描述种群的分布特征, 并在进化过程中通过自适应识别目标函数的分布形态来引导种群的进化方向。

通过选择合适的迁移解, 可有效减少负迁移。然而, 随着任务间相似性的降低或搜索空间维度不一致时<sup>[19]</sup>, 需要额外考虑迁移解能否适应目标任务的搜索空间。Bali 等<sup>[20]</sup> 提出了一种将 MFEA 与线性域适应相结合的 LDA-MFEA 框架, 该方法通过在原始解空间中构建任务间的线性映射关系, 采用直接线性变换策略, 将简单任务的搜索空间转换到与复杂任务更为相似的搜索空间中; Feng 等<sup>[21]</sup> 利用去噪自编码器来构造任务间的映射模式, 并根据不同任务的特性, 配置了不同搜索偏差的进化机制求解优化问题; Gao 等<sup>[22]</sup> 通过测地线流核的域自适应方法来建立任务间的映射; Wu 等<sup>[23]</sup> 提出了一种正交传输

的知识转移方法, 利用跨任务映射策略实现了异构任务间的高质量知识迁移; Ding 等<sup>[24]</sup> 提出了 G-MFEA (generalized multifactorial evolutionary algorithm), 通过将当前最优个体转换到均匀搜索空间的中心位置, 并结合洗牌策略, 以提高每个维度值的使用效率, 从而弥补了不同问题域间的种群分布差异; 区别于现有算法关注任务间种群分布的相似性, 文献<sup>[25]</sup> 重点考虑了种群搜索方向的特征, 通过动态评估种群搜索方向的变化来识别具有相似搜索行为的任务; 针对“应该转移什么知识”和“应该转移多少知识”这两个关键问题, Li 等<sup>[26]</sup> 提出了一种 MKTA (multiple knowledge types and transfer adaptation) 框架, 通过融合进化路径模型和最优域信息, 并结合参数自适应机制来调控任务间知识迁移的强度; Wu 等<sup>[27]</sup> 则提出了一种学习迁移框架, 使用强化学习方法将知识迁移过程建模为马尔可夫决策过程以同时优化迁移质量和搜索性能。

尽管现有研究取得了显著进展, 但是, 以下重要问题仍然未得到有效解决: 1) 迁移解的筛选缺乏针对性。MFEA 及其变体大多采用固定 RMP 调控任务间的知识迁移规模, 种群中的所有个体以相同的概率作为潜在的转移解。实际上, 并非所有个体均能够为目标任务带来积极贡献, 特别是当大量无助于目标任务的个体被选为迁移解时, 这种随机的知识交互反而会增加计算负担。2) 任务间知识结构差异易导致负迁移。在 EMT 的知识迁移中, 若将选出的个体直接迁移至目标任务而不考虑其与目标任务知识结构间的差异, 迁移解往往难以适应目标任务的进化趋势。当处理低相关的任务时, 这种盲目的迁移方式可能会导致迁移解偏离目标任务的搜索方向, 从而对优化过程产生负面影响。

综上所述, 为了从源任务中选取更具转移价值的个体, 并减少源任务与目标任务搜索空间差异带来的负迁移危害, 本文提出一种融合跨域知识动态筛选与非负子空间对齐的多任务进化算法。本文内容主要包括: 1) 提出一种跨域知识动态筛选机制。针对跨域任务有效迁移解的筛选问题, 通过计算源任务个体与目标任务空间的马氏距离, 动态筛选更适配目标任务特征的解, 剔除分布差异显著的解, 从概率层面保证迁移解与目标域的相似性。2) 考虑到低相似任务间存在的知识结构差异, 设计一种非负子空间对齐映射策略, 通过构建使得任务间非负子空间差异最小化的对齐映射矩阵, 实现高质量的跨任务知识迁移。3) 融合上述两种策略, 给出基于跨域知识动态筛选与非负子空间对齐的多任务算法 (EMT-

DNSA) 完整框架. EMT-DNSA 通过构建从筛选到映射的双阶段知识迁移通道, 能够突破传统 EMT 中迁移策略单一的局限性. 在多任务优化 (MTO) 基准测试问题和电解铝工艺决策优化场景进行了性能测试, 实验结果表明, EMT-DNSA 相比于其他先进的 EMT 算法具有更好的性能.

## 1 本文算法

本节介绍所提出 EMT-DNSA 算法框架以及两种知识迁移方式的实现过程. 首先描述跨域知识动态筛选机制的原理, 然后给出非负子空间对齐映射策略的流程, 最后给出 EMT-DNSA 的完整算法框架.

### 1.1 多任务优化问题

MTO 是一种基于种群搜索的并行优化方法, 通过跨任务知识迁移同时处理多个独立任务. 一般地, 假设同时处理  $K$  个最小化任务  $\{T_1, T_2, \dots, T_K\}$ , MTO 可表述为

$$x_i^* = \arg \min_{x \in S_i} f_i(x), \quad i = 1, 2, \dots, K. \quad (1)$$

其中:  $x_i^*$  为在任务  $T_i$  上找到的最优解,  $S_i$  和  $f_i$  分别为任务  $T_i$  的搜索空间和目标函数.

### 1.2 跨域知识动态筛选机制

在 MTO 中, 由于种群分布特征会随着迭代过程动态变化, 采用固定 RMP 随机选择迁移解会为跨任务知识迁移带来较大的不确定性. 同时, 在大多数优化任务中, 各特征间存在复杂的相关性. 若在度量个体间相似性时直接采用欧氏距离, 则会导致距离度量偏离种群真实特征分布<sup>[28]</sup>. 马氏距离 (MD)<sup>[29]</sup> 是一种基于协方差结构的二阶统计量方法, 能够有效衡量个体样本与多维分布中心间的偏离程度. 与信息论度量 (如 KL 散度) 相比, MD 不依赖对数据分布的先验假设, 对样本规模要求更低, 且更适用于个体层面的筛选. 相比之下, KL 散度主要用于衡量两个概率分布间的差异, 若用于个体筛选, 则需要进行概率建模, 易引入额外的建模误差和计算成本. 综合上述分析, 为有效筛选具有迁移价值的解, 本文设计一种跨域知识动态筛选机制, 以 MD 作为核心度量手段, 并引入动态阈值以调控迁移规模.

如图 1(a) 和图 1(b) 所示: 假设  $T_1$ 、 $T_2$  分别为两个任务种群,  $O$  为任务种群  $T_1$  的分布中心,  $O_1$ 、 $O_2$  分别为任务种群  $T_2$  的两个解, 在初始种群分布状态下,  $O_1$  更符合种群  $T_1$  的分布特性 (即  $O_1$  与  $O$  的马氏距离更小), 因此优先被选为迁移解. 但是随着  $T_1$  迭代进化, 其分布特性发生了动态变化, 若使用固定阈值进

行筛选迁移解, 则会导致选择的迁移解不符合目标任务种群当前分布特征. 如图 1(c) 和图 1(d) 所示: 当种群  $T_1$  进化后, 相同的解  $O_1$ 、 $O_2$  已不适合作为迁移解, 而  $O_3$  处于任务种群  $T_1$  分布方差更大的方向上, 更能真实反映解与目标种群的结构一致性. 因此, 本文根据每个任务种群的动态分布特性, 采用动态阈值结合马氏距离进行筛选迁移解, 使得跨任务知识迁移在不同演化阶段均能够保持高效且稳健. 具体而言, 首先, 计算源任务个体与目标任务种群分布中心间的马氏距离作为迁移候选解的初筛标准; 然后, 结合目标任务种群内部的分布特征, 计算动态阈值来确定迁移的个体集合.

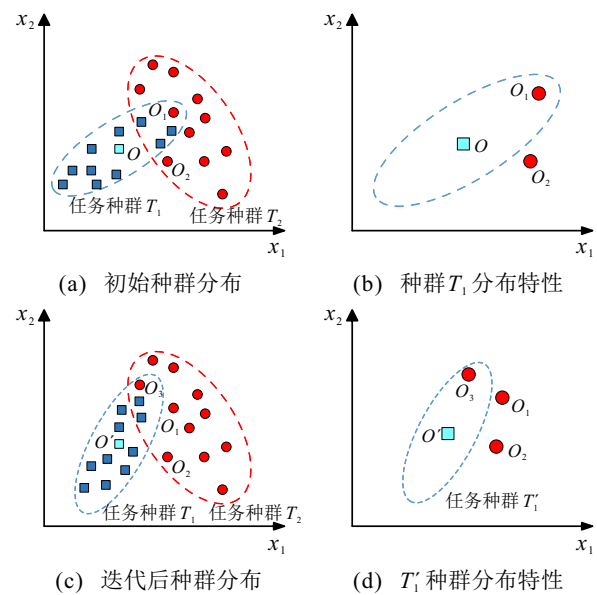


图1 任务种群动态分布状况

跨域知识动态筛选机制的实现过程如下: 首先, 计算源任务中解到目标任务分布中心的马氏距离. 假设  $X_i$  为源任务中的一个解, 其到目标任务样本分布中心的马氏距离为

$$D_{M_1}(i) = \sqrt{(X_i - \mu)^T S^{-1} (X_i - \mu)}. \quad (2)$$

其中:  $\mu$  为目标任务解集分布的均值向量,  $S$  为目标任务解集的协方差矩阵. 同时, 计算目标任务解  $X'_i$  相对自身分布的马氏距离  $D_{M_2}$  作为参考分布距离, 即

$$D_{M_2}(i) = \sqrt{(X'_i - \mu)^T S^{-1} (X'_i - \mu)}, \quad (3)$$

这里  $X'_i$  为目标任务解. 根据覆盖率  $r$  计算动态筛选阈值  $\tau$ , 最后筛选出  $D_{M_1}(i)$  中小于  $\tau$  的解作为优先迁移解. 动态筛选阈值  $\tau$  的具体计算方式如下所示:

$$\tau = \tilde{D}_2(\lfloor N \cdot r \rfloor). \quad (4)$$

其中:  $\tilde{D}_2$  为对  $D_{M_2}$  进行升序排列后的距离向量,  $N$  为目标任务的种群规模,  $\lfloor \cdot \rfloor$  表示向下取整. 为避免

种群中分布异常解的干扰, 本文设定覆盖率  $r = 0.8$ , 此时,  $\tau$  将覆盖 80% 目标任务种群的核心分布区域. 算法 1 为迁移解动态筛选机制的伪代码.

---

**算法 1** 迁移解动态筛选机制.
 

---

输入: 任务种群  $P_1$ 、 $P_2$ , 覆盖率  $r$ ;

输出: 迁移解的索引集合  $I = \{I_1, I_2, \dots, I_n\}$ .

1. 计算  $P_1$  中个体到  $P_2$  的马氏距离  $D_{M_1}(P_1, P_2)$
  2. 计算  $P_2$  中个体到自身分布的距离  $D_{M_2}(P_2, P_2)$
  3. 对距离向量  $D_{M_2}$  进行升序排列, 得到  $\tilde{D}_2$
  4.  $\tau \leftarrow$  由式 (4), 计算距离阈值
  5.  $I \leftarrow \{i \mid D_{M_1}(i) < \tau\}$
  6. 输出迁移解索引  $I$
- 

### 1.3 非负子空间对齐映射策略

EMT 在优化相似性较大的任务上, 通过统一搜索空间直接迁移的方式实现知识迁移在 MFEA 及其变体上已得到了证实. 然而, 在 EMT 的知识转移过程中, 当转移解携带的知识与目标任务知识结构相差较大时, 直接转移迁移解往往无益于目标任务, 甚至会扰乱目标任务当前的搜索方向. 同时, 考虑到多任务优化在大多数工程优化场景中各参数本质上均为非负值, 本文提出了基于非负矩阵分解的非负子空间对齐映射策略来解决前述问题. 首先, 使用非负矩阵分解将不同任务的解集映射为既符合物理约束又具有良好可解释性的低维表示; 然后, 获取非负子空间的对齐映射矩阵; 最后, 利用此矩阵实现多任务低维特征的空间映射, 从而提升知识转移效果.

基于非负子空间对齐知识转移策略的具体过程如下: 假设有源任务解集  $S$  和目标任务解集  $P$  ( $S, P \in R^{N \times D}$ ,  $N$  为样本个数,  $D$  为数据维度), 使用非负矩阵分解得到两个任务对应的非负子空间基矩阵分别为  $X_S$  和  $X_P$  ( $X_S, X_P \in R^{N \times h}$ ,  $N$  为样本个数,  $h$  为子空间维度), 希望找到一个对齐映射矩阵  $M$ , 使得  $X_S^* M$  与  $X_P$  尽可能接近. 因此, 可用如下线性变化函数  $L$  进行表示:

$$L(M) = \|X_P - X_S \cdot M\|_F^2. \quad (5)$$

其中:  $\|\cdot\|_F^2$  为 Frobenius 范数,  $M$  为使得  $X_S$  与  $X_P$  间差异最小的对齐映射矩阵.  $L(M)$  的最优解  $M^*$  表示为

$$M^* = \arg \min_M (L(M)). \quad (6)$$

利用矩阵迹运算性质,  $L(M)$  可展开为

$$L(M) = \text{trace}((X_P - X_S M)^T (X_P - X_S M)). \quad (7)$$

为求解最优对齐映射矩阵  $M$ , 对式 (7) 关于  $M$  求导,

并令其为 0, 可得到

$$\frac{\partial L(M)}{\partial M} = 2X_S^T X_S M - 2X_S^T X_P = 0. \quad (8)$$

由式 (8), 求最优解  $M^*$ , 有

$$M^* = (X_S^T X_S)^{-1} X_S^T X_P. \quad (9)$$

进而, 得到源任务非负子空间在目标任务坐标系下的重构表示为

$$X_S^* = X_S \cdot M^*. \quad (10)$$

因此,  $X_S$  可通过对齐映射矩阵  $M$  对齐到  $X_P$ . 这样, 任务种群  $S$  与  $P$  的跨域知识迁移关系可由式 (10) 建立.

### 1.4 EMT-DNSA 算法框架

EMT-DNSA 为每个任务分配一个独立的种群并使用差分进化 (DE) 作为基本进化器, 算法的完整优化流程如图 2 所示. 以双任务优化问题为例, 首先, 为每个任务随机生成规模为  $N$  的初始种群  $P_1$  和  $P_2$ ; 然后, 根据跨域知识动态筛选机制 (算法 1) 来获取每个任务中的迁移解; 假设在任务 1 中获取的迁移解集合为  $T_1$ , 接下来将  $T_1$  中的个体与  $P_2$  合并, 使用差分进化产生子代; 接着, 构建各自任务的非负子空间并通过对齐映射矩阵  $M$  来迁移未被选中的个体; 最后, 合并子代与父代种群, 并根据适应度来选择下一代任务种群进行迭代, 直至满足算法终止条件. 具体算法流程如算法 2 所示.

---

**算法 2** EMT-DNSA 算法框架.
 

---

1. 初始化任务种群  $P_1$  和  $P_2$ .
  2. while  $g < G_{\max}$
  3. for  $j = 1$  to 2
  4.  $I_j \leftarrow$  根据算法 1 获取迁移解索引
  5.  $M \leftarrow$  由式 (5) ~ (10), 计算任务间对齐矩阵
  6. 通过  $M$  实现个体映射
  7. 根据  $I_j$  构建迁移集合  $T_j$
  8.  $Q_j \leftarrow$  合并  $P_j$  与  $T_j$ , 使用 DE 产生子代
  9.  $P'_j \leftarrow$  合并  $P_j$ 、 $Q_j$ , 根据适应度选择  $N$  个解
  10. end for
  11. end while
  12. 输出每个任务的最优解
- 

## 2 实验与结果分析

### 2.1 基准测试套件与参数设置

本研究选取 CEC17-MTSO<sup>[30]</sup> 和复杂度较高的 WCCI2020-MTSO 两个基准套件进行性能测试. 其中: CEC17-MTSO 基准套件包含 9 个特征各异的多任务优化问题, 每个问题由两个任务构成. 基于 Spearman 等级相关性和任务搜索空间交集程度, 该

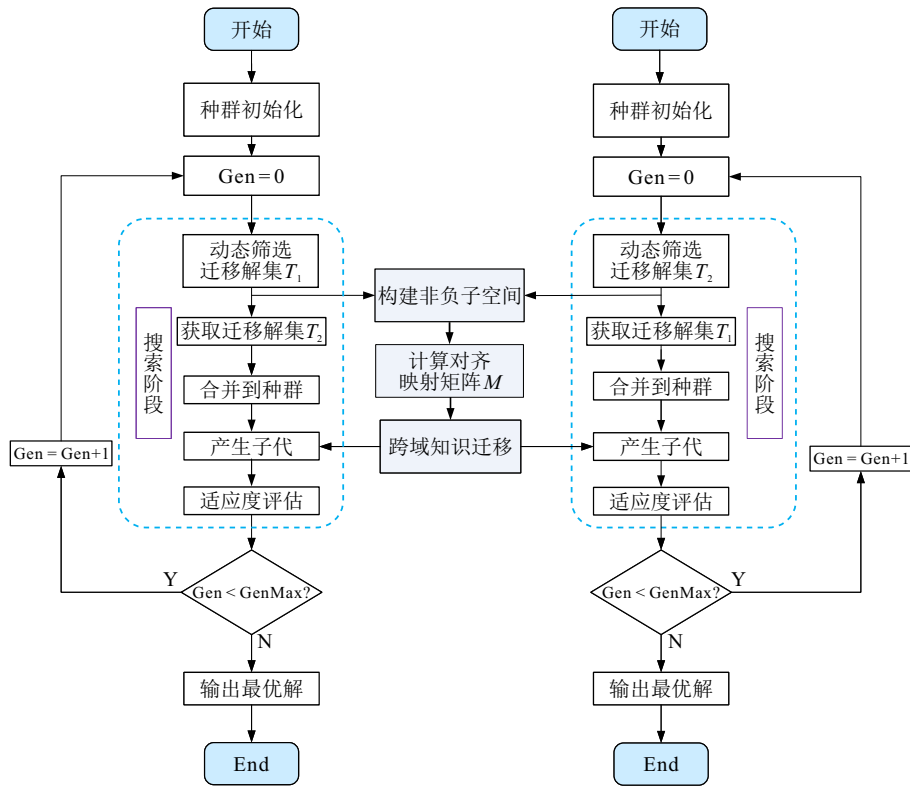


图2 EMT-DNSA 流程

套件将问题划分为 3 类相似度 (高相似度 HS、中等相似度 MS、低相似度 LS) 和 3 类交集状态 (完全相交 CI、部分相交 PI、无相交 NI)。另一方面, WCCI2020-MTSO 作为双任务优化领域的复杂测试集, 包含 10 个具有挑战性的多任务问题。

为验证 EMT-DNSA 算法的有效性, 本文将其与 5 种先进的多任务优化算法进行对比分析, 包括 ASCMFDE<sup>[31]</sup>、BLKT-DE<sup>[32]</sup>、MFEA-II<sup>[13]</sup>、EMEA<sup>[21]</sup> 和 SREMTO<sup>[33]</sup>。在实验设置方面, 采用 MTO-Platform<sup>[34]</sup> 测试环境。EMT-DNSA 采用差分进化作为基本求解器。其中缩放因子以及交叉概率分别设置为常用基准值:  $f = 0.5$ ,  $CR = 0.5$ 。各对比算法的参数均遵循其在原始论文中的参数设置。为确保比较的公平性, 其他实验参数设置如下:

- 1) 种群规模: 多任务算法的每个任务种群大小设置为 100;
- 2) 设置  $RMP = 0.3$ , SBX 以及多项式变异中  $\eta_c = 2$ ,  $\eta_m = 5$ ;
- 3) 最大评估次数: 单个任务的最大评估次数为  $5 \times 10^4$ ;
- 4) 独立运行次数: 每个算法独立运行 20 次。

## 2.2 实验结果与分析

表 1 和表 2 分别为 EMT-DNSA 算法与对比算法在 CEC17 和 WCCI20 基准问题上独立运行 20 次后的实验结果。在表 1 和表 2 中: 使用黑色字体标记

较优结果, 并基于 95% 置信水平的 Wilcoxon 秩和检验对实验结果进行统计显著性分析, 其中“+”“-”“=”分别表示对比算法显著优于、显著劣于或与 EMT-DNSA 表现相当。

由表 1 可见: EMT-DNSA 在高相似性和低相似性任务组上均表现出色, 在 CI-HS、PI-MS、PI-LS、NI-HS 和 NI-MS 五组问题上均取得了最优结果。这一优势得益于算法采用的动态迁移机制: 在高相似性任务中, 基于马氏距离的跨域知识动态筛选策略能够准确选取合适的知识进行迁移; 而在低相似性任务中, 非负子空间对齐映射策略有效减少了任务间搜索空间差异带来的负迁移影响。表 2 的 WCCI20 实验结果进一步验证了 EMT-DNSA 的优越性, 该算法在 20 个基准问题中的 9 个上表现最佳。具体而言, 与 ASCMFDE 相比, EMT-DNSA 在 18 个问题上显著更优, 在 2 个问题上表现相当 (评估结果为 0/18/2); 与 EMEA 相比, EMT-DNSA 在 14 个问题上更优, 在 5 个问题上表现相当。这一优势主要归因于以下设计: 1) 动态迁移筛选机制有效剔除了潜在的低质量迁移解, 降低了负迁移概率; 2) 非负子空间对齐通过映射矩阵缩小任务间搜索空间差异, 提升了算法在复杂问题上的鲁棒性。

针对 CEC17 测试问题, EMT-DNSA 展现了具有解决不同相似性任务的能力。在 3 个相似度较低的任务组中, EMT-DNSA 在 PI-LS 上实现了最优的

表1 EMT-DNSA 和对比算法在 CEC17 上的实验结果

problems		EMT-DNSA	ASCMFDE	BLKT-DE	MFEA-II	EMEA	SREMTO
CI + HS	$T_1$	<b>3.941 6e-03</b> <b>(1.12e-02)</b>	2.594 8e-01 (5.16e-02) -	5.005 5e-02 (5.43e-02) -	5.455 5e-02 (3.48e-02) -	3.499 6e-02 (1.16e-02) -	1.058 5e+00 (1.41e-02) -
	$T_2$	<b>3.971 9e+00</b> <b>(1.32e+01)</b>	3.322 3e+02 (2.29e+01) -	1.089 5e+02 (3.41e+01) -	7.959 6e+01 (4.06e+01) -	4.418 1e+02 (1.82e+01) -	7.905 5e+02 (1.40e+02) -
CI + MS	$T_1$	<b>2.458 4e-02</b> <b>(1.50e-02)</b>	8.794 0e-01 (2.39e-01) -	3.249 5e-01 (2.32e-01) -	8.589 8e-02 (2.74e-02) -	4.490 0e-01 (3.60e-01) -	2.030 0e+01 (7.13e-02) -
	$T_2$	1.020 5e+01 (3.13e+01)	1.002 1e+02 (3.88e+01) -	1.199 7e+02 (6.94e+01) -	<b>3.257 3e+00</b> <b>(1.71e+00) +</b>	4.480 5e+02 (1.51e+01) -	7.673 3e+02 (1.13e+02) -
CI + LS	$T_1$	2.121 6e+01 (3.63e-02)	2.121 7e+01 (3.85e-02) =	2.119 9e+01 (4.68e-02) =	2.121 2e+01 (4.40e-02) =	2.115 7e+01 (2.20e-01) =	<b>2.040 8e+01</b> <b>(6.48e-02) +</b>
	$T_2$	8.123 4e+03 (8.67e+02)	1.358 2e+04 (3.12e+02) -	6.455 6e+03 (2.22e+03) +	<b>1.279 7e+03</b> <b>(3.98e+02) +</b>	1.164 3e+04 (5.07e+02) -	2.569 6e+03 (3.39e+02) +
PI + HS	$T_1$	4.015 3e+02 (1.67e+01)	4.272 3e+02 (1.54e+01) -	<b>1.554 5e+02</b> <b>(8.75e+01) +</b>	3.820 1e+02 (3.08e+01) +	1.967 4e+02 (6.38e+01) +	7.481 6e+02 (1.26e+02) -
	$T_2$	4.840 9e-02 (1.61e-01)	3.451 4e+00 (8.79e-01) -	2.832 1e-01 (2.34e-01) -	<b>3.831 4e-03</b> <b>(1.03e-03) +</b>	4.476 1e-01 (8.91e-02) -	2.358 8e+02 (5.40e+01) -
PI + MS	$T_1$	<b>9.073 5e-02</b> <b>(3.43e-02)</b>	1.021 6e+00 (1.69e-01) -	2.902 5e-01 (1.93e-01) -	1.730 9e-01 (6.45e-02) -	5.754 6e-01 (4.46e-01) -	2.030 5e+01 (7.85e-02) -
	$T_2$	<b>5.205 2e+01</b> <b>(1.32e+01)</b>	1.829 6e+02 (5.39e+01) -	6.065 0e+01 (1.45e+01) -	1.159 2e+02 (5.21e+01) -	1.227 5e+03 (5.13e+02) -	6.954 8e+04 (2.07e+04) -
PI + LS	$T_1$	<b>1.478 4e-02</b> <b>(4.00e-03)</b>	5.488 6e+00 (1.37e+00) -	2.073 6e+00 (1.78e+00) -	3.500 8e-01 (2.83e-01) -	4.953 4e-01 (4.10e-01) -	2.031 1e+01 (7.24e-02) -
	$T_2$	<b>5.790 7e-02</b> <b>(1.45e-02)</b>	9.414 3e-01 (2.73e-01) -	3.464 1e+00 (2.86e+00) -	1.474 8e+00 (1.17e+00) -	3.320 1e-01 (7.52e-01) -	2.185 4e+01 (3.33e+00) -
NI + HS	$T_1$	<b>5.410 5e+01</b> <b>(1.47e+01)</b>	3.285 0e+02 (5.01e+01) -	1.105 7e+02 (9.96e+01) -	2.180 9e+02 (6.30e+01) -	8.988 9e+02 (1.23e+03) -	6.278 9e+04 (2.65e+04) -
	$T_2$	<b>3.705 8e+01</b> <b>(7.91e+01)</b>	3.406 8e+02 (1.09e+01) -	1.558 9e+02 (7.43e+01) -	2.605 4e+02 (7.55e+01) -	4.424 7e+02 (1.40e+01) -	7.508 5e+02 (1.39e+02) -
NI + MS	$T_1$	<b>1.749 0e-03</b> <b>(7.23e-04)</b>	3.549 5e-01 (5.47e-02) -	9.790 4e-02 (8.83e-02) -	1.294 2e-02 (6.33e-03) -	3.658 4e-02 (1.16e-02) -	1.057 4e+00 (1.41e-02) -
	$T_2$	<b>3.223 3e+00</b> <b>(8.19e-01)</b>	6.153 0e+00 (5.99e-01) -	3.781 5e+00 (2.86e+00) =	5.726 3e+00 (1.82e+00) -	3.127 2e+01 (1.15e+01) -	5.152 9e+01 (5.60e+00) -
NI + LS	$T_1$	4.089 8e+02 (1.67e+01)	4.656 6e+02 (2.01e+01) -	3.563 6e+02 (9.11e+01) =	3.782 9e+02 (1.83e+01) +	<b>2.118 8e+02</b> <b>(5.37e+01) +</b>	7.610 1e+02 (1.22e+02) -
	$T_2$	7.555 2e+03 (8.73e+02)	7.515 1e+03 (5.70e+02) =	2.058 5e+03 (1.02e+03) +	<b>1.131 2e+03</b> <b>(4.07e+02) +</b>	1.166 6e+04 (6.45e+02) -	2.450 3e+03 (3.03e+02) +
+ / - / =	Base	0/16/2	3/12/3	6/11/1	2/15/1	3/ 15 / 0	

表2 6 种算法在 WCCI20 上的实验结果

algorithms	+ / - / =
ASCMFDE	0/18/2
BLKT-DE	2/13/5
MFEA-II	4/11/5
EMEA	1/14/5
SREMTO	4/13/3
EMT-DNSA	Base

收敛表现;然而,在 CI-LS 和 NI-LS 问题中,其性能有所下降.这一现象表明,尽管所提出非负子空间对齐策略在一定程度上能够缓解任务间搜索空间差异所带来的负迁移效应,但是,在任务间结构差异过大或潜在特征难以对齐的情况下,该策略的调节能力仍然有提升空间.

图 3 为 EMT-DNSA 与其他 5 种对比算法在 CEC17 和 WCCI20 部分基准问题上的收敛轨迹对比.图 3 中:横轴(x轴)为函数评估次数,纵轴(y轴)

为当前评估次数下平均目标函数值的对数(log 尺度).实验结果表明,EMT-DNSA 在大多数测试问题上均表现出显著的收敛速度优势:1)快速初始收敛:在 CI-HS、NI-HS、WCCI20-P3 以及 WCCI20-P6 等问题中,EMT-DNSA 在优化初期即展现出更快的收敛趋势.这一现象归因于算法设计的动态迁移解筛选机制,该机制通过马氏距离度量个体与目标任务种群分布的相似性,在迭代早期即可从源任务种群中高效筛选出有价值的个体,从而实现快速知识迁移.2)持续优化能力:在后续优化阶段,EMT-DNSA 通过非负子空间对齐策略将不同任务搜索空间映射至统一子空间,有效促进了跨任务知识融合,从而避免了收敛停滞问题,保证了优化过程的可持续性.

### 2.3 EMT-DNSA 成分有效性分析

为验证 EMT-DNSA 中双策略的协同效应,本文在 WCCI20 基准集上设计了消融实验.实验对比了

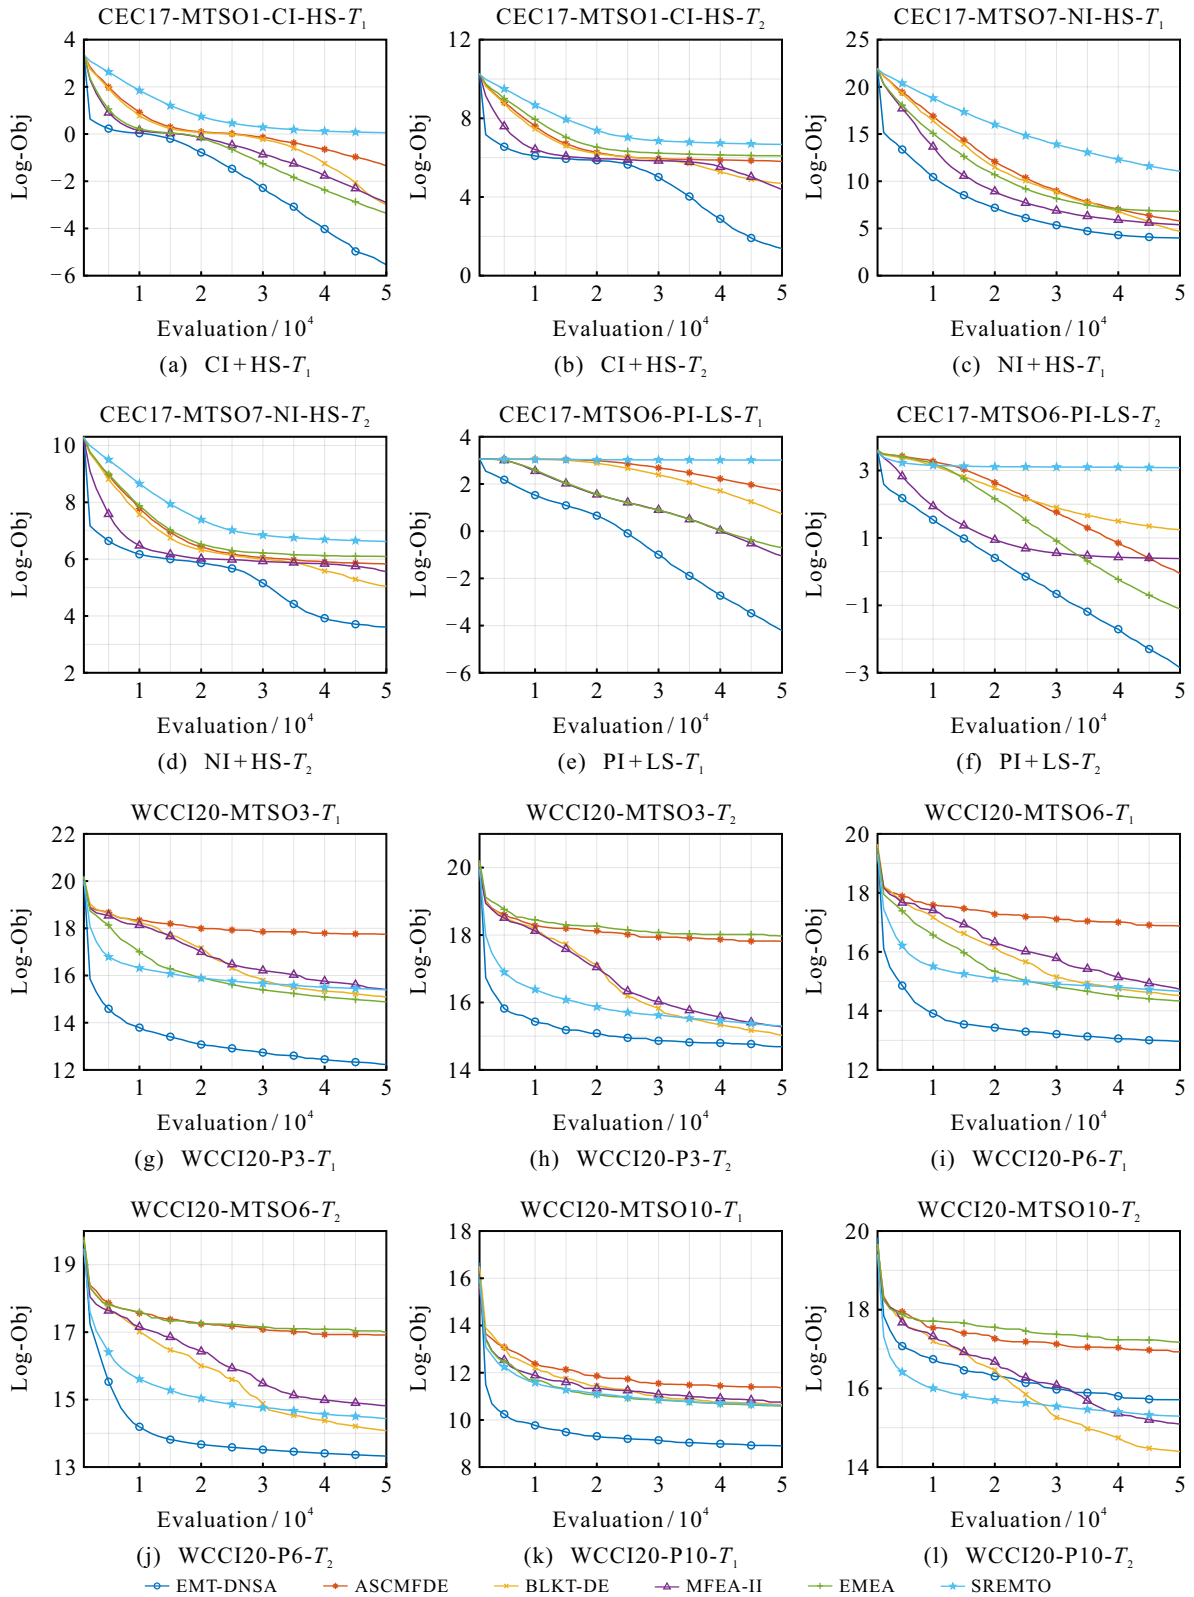


图3 6种算法的平均收敛曲线

完整 EMT-DNSA 算法与其两个变体: 1) EMT-DS (仅使用跨域知识动态筛选机制); 2) EMT-NSA (仅使用非负子空间对齐映射策略). 3 种算法在 10 个基准问题上独立运行 20 次, 结果如表 3 所示. 实验数据表明: 1) 相比于 EMT-NSA, EMT-DNSA 在 11 个问题上更具优势 (8 个问题表现相当). 这表明动态筛选能够有效识别跨任务潜力解并提升局部搜索效率.

2) EMT-DNSA 在 11 个任务上显著优于 EMT-DS (4 个任务表现相似). 这表明即使是差异较大的迁移解, 在经过适当的映射后, 仍然能够在进化中产生正向影响; 也验证了该对齐策略能够确保稳定的知识迁移和收敛性. 3) 两种策略的融合使得 EMT-DNSA 在多数问题上表现最优, 验证了所提出混合策略的有效性.

表3 3种算法在 WCCI20 上的实验结果

algorithms	+/-/=
EMT-DS	5/11/4
EMT-NSA	1/11/8
EMT-DNSA	Base

2.4 铝电解能耗工艺决策优化案例分析

为评估 EMT-DNSA 的实际应用价值, 本研究选取铝电解过程 (AEP) 多槽协同能耗优化作为验证案例<sup>[10]</sup>. 铝电解过程工艺复杂能耗较大且存在多参数耦合、强非线性等特征, 电解槽结构如图 4 所示. 现有单任务优化算法虽然在单槽优化中取得了成效, 但是难以实现多槽间经验迁移; 多槽协同优化工艺决策已成为实现 AEP 系统级节能的关键研究方向<sup>[35]</sup>.




图4 铝电解槽结构

本案例将 3 台电解槽建模为多任务优化问题, 以验证 EMT-DNSA 在复杂工业场景中的迁移优化

能力. 其通过同时优化 3 台铝电解槽的工艺决策参数, 以实现吨铝直流电耗 ( $C_{DC}$ ) 最低.  $C_{DC}$  指标综合反映了电解槽结构参数 (如槽电压) 与操作参数 (如槽温度、铝水平) 的交互影响, 其数学表达式为

$$\min C_{DC} = f_{C_{DC}}(\Omega_x), \quad (11)$$

其中决策变量  $\Omega_x$  表示为

$$\Omega_x = [I, V, t, R, A, E_C, T_b, Q, F_d]^T. \quad (12)$$

这里:  $I$  为系列电流 (kA),  $V$  为工作电压 (mV),  $N$  为下料量 (kg),  $R$  为分子比,  $A$  为铝水平 (cm),  $E_C$  为电解质水平 (cm),  $T$  为槽温 ( $^{\circ}C$ ),  $Q$  为实际出铝量 (kg),  $F_d$  为氟化盐用量 (kg).

本实验采集重庆某铝厂电解车间生产日报数据, 并使用长短期记忆网络 (LSTM) 构建铝电解三槽能耗预测模型. 其中: 铝电解槽 1 和铝电解槽 2 的样本集分别包含 640 个样本 (训练集 590/测试集 50); 铝电解槽 3 的样本集包含 594 个样本 (训练集 544/测试集 50). LSTM 内部门控函数均为 Sigmoid, 候选记忆和最终输出为 Tanh 函数, 决策变量的约束条件如表 4 所示. 铝电解槽能耗模型预测误差如图 5 所示, 三槽  $C_{DC}$  的最大预测误差分别为 1.298%、0.207% 和 1.529%, 满足 AEP 工业设计的精度要求. 进而, 将铝电解多槽能耗模型转化为所需要的优化目标函数  $f_{C_{DC}}$ .

表4 决策变量的边界条件

电解槽	边界	$I/kA$	$V/mV$	$N/kg$	$R$	$A/cm$	$E_C/cm$	$T/^{\circ}C$	$Q/kg$	$F_d/kg$
AEP <sub>1</sub>	上界	310	4008	4953	2.75	28	21	954	2653	56
	下界	302	3910	3421	2.20	24	14	936	1880	17
AEP <sub>2</sub>	上界	310	4023	5100	2.70	29	20	955	2480	56
	下界	305	3911	3828	2.31	26	11	933	2033	0
AEP <sub>3</sub>	上界	311	4276	4997	3.33	32	23	969	2543	48
	下界	305	3851	3372	2.37	24	10	931	1553	0




图5 AEP 三槽能耗模型预测误差

继续采用上述 5 种 EMT 算法与 EMT-DNSA 进行对比分析, 每个算法独立运行 20 次, 每个任务最大评估次数设置为 3000. 算法在 AEP 三任务能耗优化的结果如表 5 和表 6 所示, 优化收敛如图 6 所示.

可以看出, EMT-DNSA 最终在电解槽 1 和电解槽 3 上得到两个电解槽的最低直流能耗, 分别为 10724 kW·h/t-Al 和 10792 kW·h/t-Al. 相较于 MFEA-II、ASCMFDE 与 SREMT0, EMT-DNSA 在所有 3 个电解槽上均展现出了优势; 与 BLKT-DE、EMEA 相比, EMT-DNSA 在 2 个电解槽上表现更优, 在剩余 1 个电解槽上性能相当. 综上所述, 所提出 EMT-DNSA 在解决铝电解多槽系统节能降耗方面具有实用价值.

3 结论

本文提出了一种基于跨域知识动态筛选与非负子空间对齐的多任务进化算法 (EMT-DNSA). 该算法通过计算源任务解到目标任务种群分布中心的马

表5 电解槽最优运行参数

任务槽	$I/kA$	$V/mV$	$N/kg$	$R$	$A/cm$	$E_c/cm$	$T/^{\circ}C$	$Q/kg$	$F_d/kg$
AEP <sub>1</sub>	305.3	3.910	3421	2.202	25.23	14	944	2653	17.2
AEP <sub>2</sub>	305.3	3.911	3828	2.311	26.95	11	942	2480	0.3
AEP <sub>3</sub>	305.3	3851	3372	2.366	24.62	23	963	2543	25.9

表6 AEP 三槽能耗优化实验结果

problem	EMT-DNSA	ASCMFDE	BLKT-DE	MFEA-II	EMEA	SREMT0
AEP-T <sub>1</sub>	<b>1.072 4e+04</b> ( <b>1.74e-01</b> )	1.072 6e+04 (1.30e+00) -	1.072 4e+04 (6.29e-01) -	1.072 5e+04 (9.73e-01) -	1.072 4e+04 (4.48e-01) -	1.080 4e+04 (3.11e+01) -
AEP-T <sub>2</sub>	1.157 8e+04 (1.78e-01)	1.157 9e+04 (3.91e-01) -	1.157 9e+04 (2.98e-01) =	1.157 9e+04 (3.89e-01) -	<b>1.157 8e+04</b> ( <b>2.09e-01</b> ) =	1.160 5e+04 (8.81e+00) -
AEP-T <sub>3</sub>	<b>1.079 2e+04</b> ( <b>7.17e-01</b> )	1.079 4e+04 (1.30e+00) -	1.079 3e+04 (1.24e+00) -	1.079 3e+04 (6.92e-01) -	1.079 3e+04 (1.02e+00) -	1.086 5e+04 (1.93e+01) -
+ / - / =	Base	0/3/0	0/2/1	0/3/0	0/2/1	0/3/0




图6 AEP 任务收敛曲线

氏距离结合动态阈值来筛选符合目标任务种群分布特性的迁移解. 对于不适应直接迁移的解, 设计了非负子空间对齐映射策略来提升迁移解对目标任务的适应性, 以确保算法在后期收敛的可持续性. 在 MTO 基准测试问题以及多槽铝电解能耗优化问题上验证了所提出算法的性能. 未来的研究工作将侧重于探索 EMT-DNSA 在昂贵优化问题、多模态优化问题以及超多任务场景上的性能表现.

参考文献 (References)

[1] 王凌, 郑洁, 王晶晶. 求解区间数分布式流水线调度的混合离散果蝇优化算法[J]. 控制与决策, 2020, 35(4): 930-936.  
(Wang L, Zheng J, Wang J J. A hybrid discrete fruit fly optimization algorithm for distributed permutation flowshop scheduling with interval data[J]. Control and Decision, 2020, 35(4): 930-936.)

[2] 王凌, 王晶晶. 带峰值能耗约束流水线调度的协同群智能优化[J]. 控制与决策, 2021, 36(10): 2350-2358.  
(Wang L, Wang J J. Cooperative memetic optimization for flowshop scheduling with peak power consumption constraint[J]. Control and Decision, 2021, 36(10): 2350-2358.)

[3] 赵世杰, 赵秋丽, 陈淼, 等. 基于邻域交叉的双变异差分进化算法求解非线性方程组[J]. 控制与决策, 2025, 40(2): 546-552.

(Zhao S J, Zhao Q L, Chen M, et al. Solving nonlinear equation systems with neighborhood crossover-based dual-mutation differential evolution algorithm[J]. Control and Decision, 2025, 40(2): 546-552.)

[4] 王博, 刘建昌, 张伟, 等. 基于角分解辅助的多阶段高维多目标进化算法[J]. 控制与决策, 2025, 40(5): 1619-1630.  
(Wang B, Liu J C, Zhang W, et al. Many-objective evolutionary algorithm based on angle decomposition assist in multi-stage[J]. Control and Decision, 2025, 40(5): 1619-1630.)

[5] 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.

[6] Hou Y, Shen Y J, Han H G, et al. Multi-task differential evolution algorithm with dynamic resource allocation: A study on e-waste recycling vehicle routing problem[J]. Swarm and Evolutionary Computation, 2025, 92: 101806.

[7] Liu X F, Dai Y T, Fang Y C, et al. Fragment-based knowledge transfer for multi-task capacitated vehicle routing[J]. IEEE Transactions on Intelligent Transportation Systems, 2025, PP(99): 1-15.

[8] 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.

[9] Yao L Z, Chen J, Wang L, et al. Multi-objective

- optimization driven by preponderant individuals and symmetric sampling for operational parameter design in aluminum electrolysis process[J]. *Swarm and Evolutionary Computation*, 2024, 87: 101574.
- [10] Yao L Z, Zong X, Wang L, et al. Explicit evolutionary framework with multitasking feature fusion for optimizing operational parameters in aluminum electrolysis process[J]. *IEEE Transactions on Cybernetics*, 2024, 54(12): 7527-7540.
- [11] 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.
- [12] Gupta A, Ong Y S, Feng L. Multifactorial evolution: Toward evolutionary multitasking[J]. *IEEE Transactions on Evolutionary Computation*, 2016, 20(3): 343-357.
- [13] 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.
- [14] 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.
- [15] Lin J B, Liu H L, Xue B, et al. Multiobjective multitasking optimization based on incremental learning[J]. *IEEE Transactions on Evolutionary Computation*, 2020, 24(5): 824-838.
- [16] Chen H Y, Liu H L, Gu F Q, et al. A multiobjective multitask optimization algorithm using transfer rank[J]. *IEEE Transactions on Evolutionary Computation*, 2023, 27(2): 237-250.
- [17] Gao F H, Gao W F, Huang L L, et al. Effective transferred knowledge identified by bipartite graph for multiobjective multitasking optimization[J]. *Knowledge-Based Systems*, 2024, 290: 111530.
- [18] Liu J, Wang Y, Sun G Y, et al. Solving highly expensive optimization problems via evolutionary expected improvement[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023, 53(8): 4843-4855.
- [19] 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.  
(Cheng M Y, Qian Q, Ni Z W. Review of multi-task optimization algorithm[J]. *Control and Decision*, 2023, 38(7): 1802-1815.)
- [20] Bali K K, Gupta A, Feng L, et al. Linearized domain adaptation in evolutionary multitasking[C]. *IEEE Congress on Evolutionary Computation*. Donostia, 2017: 1295-1302.
- [21] Feng L, Zhou L, Zhong J H, et al. Evolutionary multitasking via explicit autoencoding[J]. *IEEE Transactions on Cybernetics*, 2018, 49(9): 3457-3470.
- [22] Gao F H, Gao W F, Huang L L, et al. Evolutionary multitasking optimization enhanced by geodesic flow kernel[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2024, 8(2): 1540-1549.
- [23] Wu S H, Zhan Z H, Tan K C, et al. Orthogonal transfer for multitask optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2023, 27(1): 185-200.
- [24] Ding J L, Yang C E, Jin Y C, et al. Generalized multitasking for evolutionary optimization of expensive problems[J]. *IEEE Transactions on Evolutionary Computation*, 2017, 23(1): 44-58.
- [25] Wu X L, Wang W, Zhang T F, et al. Improved evolutionary multitasking optimization algorithm with similarity evaluation of search behavior[J]. *IEEE Transactions on Evolutionary Computation*, 2025, 29(3): 794-808.
- [26] Li Y C, Gong W Y. Multiobjective multitask optimization with multiple knowledge types and transfer adaptation[J]. *IEEE Transactions on Evolutionary Computation*, 2025, 29(1): 205-216.
- [27] Wu S H, Huang Y X, Wu X Y, et al. Learning to transfer for evolutionary multitasking[J]. *IEEE Transactions on Cybernetics*, 2025, 55(7): 3342-3355.
- [28] Bishop C M. *Pattern recognition and machine learning*[M]. New York: Springer, 2006.
- [29] de Maesschalck R, Jouan-Rimbaud D, Massart D L. The mahalanobis distance[J]. *Chemometrics and Intelligent Laboratory Systems*, 2000, 50(1): 1-18.
- [30] Da B, Ong Y S, Feng L, et al. Evolutionary multitasking for single-objective continuous optimization: Benchmark problems, performance metric, and baseline results[J/OL]. 2017, arXiv: 1706.03470.
- [31] 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*, 2020, 25(2): 262-276.
- [32] Jiang Y, Zhan Z H, Tan K C, et al. Block-level knowledge transfer for evolutionary multitask optimization[J]. *IEEE Transactions on Cybernetics*, 2024, 54(1): 558-571.
- [33] Zheng X L, Qin A K, Gong M G, et al. Self-regulated evolutionary multitask optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2020, 24(1): 16-28.
- [34] Li Y C, Gong W Y, Ming F, et al. MToP: A Matlab optimization platform for evolutionary multitasking[J/OL]. 2023, arXiv: 2312.08134.
- [35] 姚立忠, 赵蕾, 王凌, 等. 基于知识分类转移与负向检测的多目标多任务优化[J]. *中国科学: 技术科学*, 2025, 55(10): 1741-1760.  
(Yao L Z, Zhao L, Wang L, et al. Multi-objective multi-task optimization algorithm based on knowledge classification transfer and negative detection[J]. *Scientia Sinica Technologica*, 2025, 55(10): 1741-1760.)

### 作者简介

殷涛 (2000-), 男, 硕士生, 主要研究方向为智能计算、多任务优化, E-mail: 121796271@qq.com;

姚立忠 (1985-), 男, 副教授, 博士, 主要研究方向为多任务/多目标优化、工业过程建模, E-mail: lizhong\_yao@cqu.edu.cn;

董浩铭 (2001-), 男, 硕士生, 主要研究方向为多目标优化、工业过程建模, E-mail: donghaoming0605@163.com;

罗海军 (1983-), 男, 教授, 博士, 主要研究方向为智能计算、电磁测量, E-mail: luohaijun@cqu.edu.cn.