

# 控制与决策

Control and Decision

## 基于迁移学习灰支持向量回归机的交互式进化计算

郭广颂, 高海荣, 张勇

引用本文:

郭广颂, 高海荣, 张勇. 基于迁移学习灰支持向量回归机的交互式进化计算[J]. *控制与决策*, 2021, 36(10): 2399–2408.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0420>

---

### 您可能感兴趣的其他文章

Articles you may be interested in

#### 超启发式交叉熵算法求解模糊分布式流水线绿色调度问题

Hyper-heuristic cross-entropy algorithm for green distributed permutation flow-shop scheduling problem with fuzzy processing time  
*控制与决策*. 2021, 36(6): 1387–1396 <https://doi.org/10.13195/j.kzyjc.2019.1681>

#### 基于正态云模型的状态转移算法求解多目标柔性作业车间调度问题

State transition algorithm based on normal cloud model for solving multi-objective flexible job shop scheduling problem  
*控制与决策*. 2021, 36(5): 1181–1190 <https://doi.org/10.13195/j.kzyjc.2019.1233>

#### 基于向量角分解的高维多目标进化算法

Many-objective evolutionary algorithm based on vector angle decomposition  
*控制与决策*. 2021, 36(3): 761–768 <https://doi.org/10.13195/j.kzyjc.2019.0925>

#### 基于改进多目标优化算法的分布式数据中心负载调度

Multi-objective optimization of energy and performance management in distributed data centers  
*控制与决策*. 2021, 36(1): 159–165 <https://doi.org/10.13195/j.kzyjc.2019.0702>

#### 基于稀疏度阶数优化的杂波密度估计算法

A clutter density estimation algorithm by optimized sparsity order  
*控制与决策*. 2020, 35(12): 2923–2930 <https://doi.org/10.13195/j.kzyjc.2019.0429>

# 基于迁移学习灰支持向量回归机的交互式进化计算

郭广颂<sup>1</sup>, 高海荣<sup>2†</sup>, 张勇<sup>3</sup>

(1. 郑州航空工业管理学院 智能工程学院, 郑州 450046; 2. 山东交通职业学院 交通工程系, 山东 泰安 271000; 3. 中国矿业大学 信息与控制工程学院, 江苏 徐州 221116)

**摘要:** 针对机器感知评价和种群进化, 提出基于迁移学习灰支持向量回归机的个体适应值预测方法和聚类进化策略. 通过共享用户已评价个体适应值学习模型与部分未评价个体适应值学习模型, 实现知识模型差异最小化. 建立具有迁移学习能力的灰支持向量回归机模型, 预测未评价个体适应值. 基于聚类子集计算个体平均距离, 并设计选择算子和交叉算子, 扩大子代搜索区域, 增强种群多样性. 基于上述策略, 采用NSGA-II范式实现交互式进化计算. 最后, 分析算法时间复杂度, 表明算法可提高评价精度, 并克服局部收敛问题. 将该算法应用于室内灯光调色问题, 验证所提出方法的有效性.

**关键词:** 迁移学习; 灰支持向量回归机; 交互; 聚类进化算法; 非被占优解排序遗传算法II

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0420

开放科学(资源服务)标识码(OSID):



**引用格式:** 郭广颂, 高海荣, 张勇. 基于迁移学习灰支持向量回归机的交互式进化计算[J]. 控制与决策, 2021, 36(10): 2399-2408.

## Interactive evolutionary computation based on transfer learning grey support vector regression

GUO Guang-song<sup>1</sup>, GAO Hai-rong<sup>2†</sup>, ZHANG Yong<sup>3</sup>

(1. School of Intelligent Engineering, Zhengzhou University of Aeronautics, Zhengzhou 450046, China; 2. Department of Traffic Engineering, Shandong Transport Vocational College, Tai'an 271000, China; 3. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

**Abstract:** This paper proposes a fitness prediction method based on transfer learning grey support vector regression with the clustering evolution strategy aiming at machine perception evaluation and population evolution, which can minimize knowledge model differences by sharing the user learning model of individual evaluation fitness and the part of unevaluated individuals, and can forecast unevaluated individuals fitness. A selection and crossover operator based on clustering individual average distance are proposed, which can expand offspring search area and enhance population diversity. Based on above strategies, the interactive evolutionary computation applied to NSGA-II is proposed. Finally, the analysis of the time complexity indicates that the proposed method can improve evaluation precision, and overcome the local convergence problem. The method is applied to interior light toning optimization problem, and its outstanding performance is experimentally demonstrated.

**Keywords:** transfer learning; grey support vector regression; interactive; clustering evolutionary algorithm; NSGA-II

## 0 引言

目前, 人机交互是与人工智能相互促进、互相驱动的重要研究领域<sup>[1]</sup>. 交互式进化计算(interactive evolutionary computation, IEC)作为一种重要的人机交互技术取得了长足进步, 已衍生出交互式多目标优化<sup>[2]</sup>、多用户协同进化<sup>[3]</sup>、个性化推荐<sup>[4]</sup>等分支. 事实上, 交互式进化过程中受人的疲劳限制, 人只能评价

少量样本及执行少数进化操作, 系统中存在大量得不到人直接评价的样本. 但为了提高搜索效率, 机器需要大量运算开销并提取大量用户偏好信息. 此外, 已经得到用户评价的样本, 偏好信息还存在随时间变化的动态特征, 这都给进化优化带来了巨大困难. 所以, 人机交互过程的信息不完备性、机器系统可执行性一直制约着交互式进化计算的发展. 总体来看, 机器

收稿日期: 2020-04-14; 修回日期: 2020-07-29.

基金项目: 国家自然科学基金项目(61876185); 河南省重点研发与推广专项(212102210491).

责任编辑: 张国山.

<sup>†</sup>通讯作者. E-mail: lcto-long@163.com.

感知评价和种群进化策略是交互式进化计算的两个核心问题,该问题的有效解答可以促进人机交互过程中存在的提高优化效率,减轻疲劳等一系列固有难题的解决。

采用代理模型替代人完成评价是一种较为成熟的机器感知评价研究思路.代理模型是一种有监督的机器学习模型,即利用代理方法实现数据拟合<sup>[5]</sup>.常用代理模型有 support vector machine、neural networks、Gaussian process 等.这些代理模型有效减少了用户操作负担,进而实现复杂优化问题求解.最近,在进化中引入迁移学习机制受到了学者们的关注. Dinh 等<sup>[6]</sup>处理新任务时,在初始种群中迁移源任务保存的不同档次个体,提高搜索范围;Feng 等<sup>[7]</sup>提出了融合迁移学习的文化基因进化框架;Jiang 等<sup>[8]</sup>为提高算法对环境变化的响应速度,将迁移学习用于动态多目标优化;类似地,文献[9]将已求解的历史问题知识迁移至匹配的新问题中,加快算法搜索.迁移学习作为机器学习的一个重要分支,侧重于将已经学习过的知识迁移应用于新的问题中,给机器感知评价研究提供了新思路。

在种群获得机器感知评价后,面对庞大种群如何充分提取评价信息,在尽可能少的进化代数内快速高效地实现最优解搜索成为亟待解决的问题,聚类进化、集合进化等高效进化策略是解决这一难题的有效工具<sup>[10-11]</sup>.聚类进化策略基于传统聚类分析实现,该策略将种群聚类子集视为小种群,在各个小种群上完成进化,提高了搜索效率<sup>[12-13]</sup>.针对 NSGA-II 拥挤距离测度的局限性,文献[14]根据平均距离划分种群,通过在小种群上执行遗传操作保证优化解在 Pareto 前沿面上均匀分布.聚类进化具有与集合进化类似的搜索速度快、并行性等优点,但算法实现比较简单,更适用于信息缺失环境的交互式进化计算。

上述两类技术为交互式进化计算研究提供了可靠的理论基础,但仍存在如下不足:1) 虽然单纯依靠代理模型直接完成数据驱动能够实现大规模种群个体评价,但数据误差较大,为弥补这一不足而采用的后续进化策略会耗费较大计算资源.目前,应用于进化优化的迁移学习展现了良好的驱动能力,但没有考虑源问题与目标问题的差异性<sup>[6]</sup>,文献[7-8]设计的迁移方法虽然考虑了该差异性,但方法适用于动态优化问题,不适用本文静态优化问题.2) 适合于交互式进化优化的聚类进化策略研究依然不充分,受交互形式和进化代数限制,文献[10,12]的聚类框架没有充分考虑用户偏好,不能完成较少进化代数内的优化

任务.类似地,文献[13]提出的多距离聚类框架只适用于基因型个体聚类,不适合个体表现型聚类。

鉴于此,本文提出基于迁移学习灰支持向量回归机的交互式进化计算(interactive evolutionary computation based on transfer learning grey support vector regression, IEC-TGSVR).该方法首先采用支持向量回归机从源域和目标域中找到最为匹配的历史模型作为当前模型;然后利用当前模型预测已估计的个体适应值,并基于聚类进化策略在聚类子集实现并行进化;最后将所提出方法应用于室内灯光调色问题,以验证算法的有效性。

## 1 相关工作

### 1.1 交互式进化计算

不失一般性,考虑优化问题

$$\max f(x, t) = f(x(t)), x \in S \subseteq R^D.$$

其中:  $f(x, t)$  为不能用明确定义函数表示的与时间  $t$  有关的优化性能指标,即隐式性能指标;  $x$  为  $D$  维决策变量,  $S$  为其取值范围.借鉴传统进化计算的交互式进化计算是解决隐式性能指标优化问题的有效方法,其基本思想是:一个(些)扮演目标函数的用户通过与进化算法互动的人-机交互接口,根据目标对象在心理空间和实际输出的差距评价个体,确定个体适应值  $f(x, t)$ ,系统根据用户输出结果在特征参数空间内搜索全局最优解,产生新一代个体,循环该过程,直到产生用户满意解为止。

### 1.2 迁移学习方法

基于模型的迁移学习方法是一种重要的学习方法,是指从源域和目标域中找到共享的参数信息实现知识迁移.本文采用支持向量回归机实现基于模型的迁移学习过程<sup>[15]</sup>,如图1所示.该方法的数据训练与知识迁移过程如下:首先,基于源域已标注数据采用支持向量回归机建立源域知识模型  $f_h$ ,利用一部分目标域未标注数据建立目标域知识模型  $f_c$ ;然后,引入可调参数用于平衡  $f_h$  和  $f_c$  的结构风险,同时实

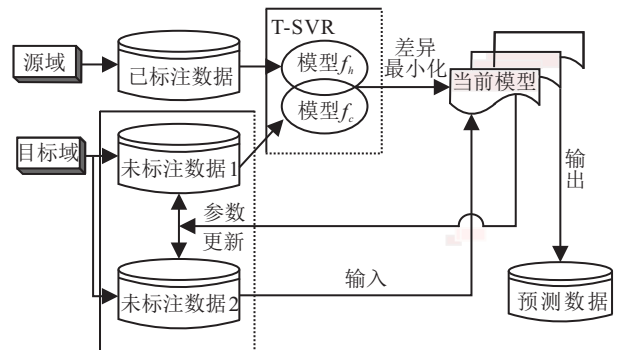


图1 基于模型的迁移学习方法

现模型  $f_h$  和  $f_c$  的差异最小化;最后,基于共享的参数信息,将  $f_h$  和  $f_c$  构成当前模型,并对目标域其他未标注数据完成标注,实现迁移学习任务,当  $f_h$  和  $f_c$  差异过大,知识迁移效果变差时,从目标域知识中重新选择训练数据,更新支持向量回归机模型。

## 2 所提出方法

本文算法基于 NSGA-II 框架实现,算法思想是:首先,将用户已评价个体作为源域,用户未评价个体作为目标域;然后,采用支持向量回归机实现迁移学习机制,将源域的偏好信息迁移到目标域,实现对未评价个体的适应值预测,同时对支持向量回归机输入数据进行灰色预处理,增加预测精度;最后,采用聚类进化策略实现进化优化,提高搜索效率。为实现所提出方法,需要解决适应值估计、迁移学习灰支持向量回归机预测适应值和聚类进化策略等关键问题。

## 3 适应值估计

### 3.1 个体相似度

所提出方法采用大规模种群进化,一般而言,个体间相同的属性越多,其表现型越相似。基于相似性的上述特征,记第  $t$  代种群为  $x(t)$ ,种群规模为  $N$ ,种群  $x(t)$  中第  $i$  个个体为  $x_i(t)$ ,  $i = 1, 2, \dots, N$ , 则  $x_i(t)$  的表现型可以表示为

$$x_i(t) = \{x_{i1}, x_{i2}, \dots, x_{iNg} | x_{ir} \in \{l^{1r}, l^{2r}, \dots, l^{sr}\}\}.$$

其中:  $x_{ir}$  ( $r = 1, 2, \dots, Ng$ ) 为组成个体  $x_i(t)$  的  $r$  个决策变量(属性),  $l^{1r}, l^{2r}, \dots, l^{sr}$  为  $x_{ir}$  的实数型属性值。根据属性意义,若干个属性可以构成一个属性意义单元,记为  $\bar{x}_{ik'}$ ,  $\bar{x}_{ik'} = x_{i1}x_{i2}x_{i3} \dots, k' = 1, 2, \dots, r'$ , 则  $x_i(t)$  的表现型可以表示为

$$x_i(t) = x_{i1}x_{i2} \dots x_{iNg} = \bar{x}_{i1}\bar{x}_{i2} \dots \bar{x}_{ir'}.$$

基于认知的模糊性,采用高斯函数描述个体属性间的相似关系。考虑个体  $x_i(t)$  和  $x_j(t)$ , 设  $x_j(t)$  为参照个体,  $x_i(t)$  为比较个体,其属性相似度为  $\mu_{ij}(\bar{x}_{ik'}, \bar{x}_{jk'})$ , 有

$$\mu_{ij}(\bar{x}_{ik'}, \bar{x}_{jk'}) = e^{-\frac{l(\bar{x}_{ik'}) - l(\bar{x}_{jk'})}{1 + |f(\bar{x}_i(t)) - f(\bar{x}_j(t))|}^2}, \quad (1)$$

其中函数值  $l(\cdot)$  为属性意义单元  $\bar{x}_{ik'}$ 、 $\bar{x}_{jk'}$  的属性值。

个体相似性除了与属性有关外,与表现型也有密切关系。根据具体优化问题,设有一类个体其属性意义单元相同,但组合形式不同。如 3 个不同个体

$$\begin{aligned} x_1(t) &= \bar{x}_{i1}\bar{x}_{i2}\bar{x}_{i3}, \\ x_2(t) &= \bar{x}_{i2}\bar{x}_{i1}\bar{x}_{i3}, \\ x_3(t) &= \bar{x}_{i1}\bar{x}_{i3}\bar{x}_{i2}, \end{aligned}$$

$x_1(t)$ 、 $x_2(t)$ 、 $x_3(t)$  属性意义单元完全相同,但组合形式不同。这类个体在决策空间不同,但在目标空间的解有可能完全相同,称其为多模态个体。这类个体可以为用户提供多种选择,并对算法找到更稳定的解提供依据。针对这一现象,将个体  $x_i(t)$  与  $x_j(t)$  的表现型相似度记为  $\mu(x_i(t), x_j(t))$ , 有

$$\begin{aligned} \mu(x_i(t), x_j(t)) &= \\ & \sum (\max\{\mu_{ij}(\bar{x}_{i1}, \bar{x}_{j1}), \mu_{ij}(\bar{x}_{i1}, \bar{x}_{j2}), \dots, \mu_{ij}(\bar{x}_{i1}, \bar{x}_{jr'})\} + \max\{\mu_{ij}(\bar{x}_{i2}, \bar{x}_{j1}), \mu_{ij}(\bar{x}_{i2}, \bar{x}_{j2}), \dots, \\ & \mu_{ij}(\bar{x}_{i2}, \bar{x}_{jr'})\} + \dots + \max\{\mu_{ij}(\bar{x}_{ir'}, \bar{x}_{j1}), \mu_{ij}(\bar{x}_{ir'}, \bar{x}_{j2}), \dots, \mu_{ij}(\bar{x}_{ir'}, \bar{x}_{jr'})\}) / r'. \quad (2) \end{aligned}$$

### 3.2 非中心个体适应值估计

选择部分代表个体  $x_A(t)$  ( $A = 1, 2, \dots, N_c$ ) 作为种群聚类中心个体,并由用户评价适应值  $f(x_A(t))$ 。按式(2)逐一计算种群中其他非中心个体(非用户评价个体)  $x_o(t)$  与各中心个体的相似度  $\mu(x_o(t), x_A(t))$ , 将满足

$$\max_{A=1, 2, \dots, N_c, o \neq i} \{\mu(x_o(t), x_A(t)), o = 1, 2, \dots, N - N_c\}$$

的个体归为一类,记为  $x_A(t) = \{x_A(t)\}$ ,  $A \in \{1, 2, \dots, N_c\}$ 。根据个体表现型越相似,个体适应值就越接近的一般性规律估计聚类子集非中心个体适应值,则各聚类子集内非中心个体  $x_o(t)$  ( $x_o(t) \in x_A(t)$ ) 的估计适应值可以表示为

$$f(x_o(t)) = \frac{\sum_{A=1}^{N_c} e^{-(1-\mu(x_o(t), x_A(t)))} \cdot f(x_A(t))}{\sum_{A=1}^{N_c} e^{-(1-\mu(x_o(t), x_A(t)))}}. \quad (3)$$

## 4 迁移学习灰支持向量回归机预测适应值

基于文献[15-16],结合交互式进化计算特点,提出迁移学习灰支持向量回归机模型(transfer learning grey support vector regression, TG-SVR),用于预测根据式(3)计算的非用户评价个体适应值。

首先,对输入数据作灰处理。将个体精确数适应值  $f(x_k(t))$  ( $x_k(t) \in x(t)$ ) 记为序列  $F_0 = (f_0(x_1(t)), f_0(x_2(t)), \dots, f_0(x_N(t)))$ , 并归一化。记归一化后数据序列为

$$F'_0 = (f'_0(x_1(t)), f'_0(x_2(t)), \dots, f'_0(x_N(t))),$$

并建立  $F'_0$  的 1-AGO 序列  $F'_1 = (f'_1(x_1(t)), f'_1(x_2(t)), \dots, f'_1(x_N(t)))$ , 有

$$F'_1 = \sum_{k=1}^q f'_0(x_k(t)), \quad q = 1, 2, \dots, N. \quad (4)$$

以用户评价个体为中心对  $F_1'$  聚类, 设  $N_c$  为用户评价适应值数目, 则  $F_1'$  可以划分为  $N_c$  个子类. 在交互式进化计算中, 由于用户的标注数据量有限, 仅靠用户标注数据不足以建立完整机器模型, 从目标域各子类中按相似度序值, 选择前 10 个数据和源域  $N_c$  个用户已评价适应值数据共同作为训练数据, 其余数据作为测试数据. 训练样本集记为  $D_L = \{(x_i(t), f_1'(x_i))\}, i = 1, 2, \dots, N_s\}, N_s = 11N_c$ , 测试样本集记为  $D_T = \{(x_{i'}(t), f_1'(x_{i'}))\}, i' = 1, 2, \dots, N_e\}, N_e = N - 11N_c$ . 训练数据中, 用户标注数据建立模型  $f_h$ , 与用户标注数据最相似数据建立模型  $f_c$ . 由于用户标注数据数量较少, 与用户标注数据最相似数据信息不完备,  $f_h$  和  $f_c$  单独学习能力较差, 需要共享匹配建立当前模型. 由此, 建立迁移学习灰支持向量回归机模型

$$\begin{aligned} \hat{F}'_1(x_k(t)) &= \omega f'_1(x_k(t)) + b, \\ \forall k &= 1, 2, \dots, N_s - 1. \end{aligned} \tag{5}$$

其中:  $b$  为偏置项,  $\omega$  为权重,  $\omega$  和  $b$  由高维特征空间内的训练集进行估计, 有

$$\begin{cases} |f'_0(x_{k+1}(t)) - \hat{F}'_1(x_k(t))| \leq \varepsilon; \\ |f'_0(x_{k+1}(t)) - \hat{F}'_1(x_k(t))| - \varepsilon, \text{ otherwise.} \end{cases} \tag{6}$$

设  $(\omega_h, b_h)$  和  $(\omega_c, b_c)$  分别表示模型  $f_h$  和  $f_c$  的回归超平面, 引入非负松弛变量  $\xi_k$  和  $\xi_k^*$ , 则式(6)可以写为<sup>[13]</sup>

$$\begin{aligned} \min \quad & \frac{1}{2} \|\omega_h^2\| + \frac{C}{N} \sum_{k=1}^{N_s-1} \xi_k^{(*)} + \frac{1}{2} \|\omega_c^2\| + \frac{C}{N} \sum_{k=N_s}^N \xi_k^{(*)} + \\ & Cv\varepsilon + \frac{\lambda}{2} (\|(\omega_h - \omega_c)^2\| + (b_h - b_c)^2). \\ \text{s.t.} \quad & \omega f'_1(x_k(t)) + b_h - f'_0(x_{k+1}(t)) \leq \varepsilon + \xi_k, \\ & k = 1, 2, \dots, N_s - 1; \\ & f'_0(x_{k+1}(t)) - \omega f'_1(x_k(t)) - b_h \leq \varepsilon + \xi_k^*, \\ & k = 1, 2, \dots, N_s - 1; \\ & \omega f'_1(x_k(t)) + b_c - f'_0(x_{k+1}(t)) \leq \varepsilon + \xi_k, \\ & k = N_s, N_s + 1, \dots, N; \\ & f'_0(x_{k+1}(t)) - \omega f'_1(x_k(t)) - b_c \leq \varepsilon + \xi_k^*, \\ & k = N_s, N_s + 1, \dots, N; \\ & \xi_k \geq 0, \xi_k^* \geq 0, k = 1, 2, \dots, N. \end{aligned} \tag{7}$$

其中:  $\xi_k^{(*)}$  表示有 “\*” 和无 “\*” 两种情况;  $\|\omega_h^2\|/2$ 、 $\|\omega_c^2\|/2$  用于控制模型的拟合精度;  $v$  用于调节支持向量的个数;  $C$  为正则化常数, 控制对超出误差样本的惩罚程度,  $C$ 、 $v$  由用户设置. 式(7)的对偶问题等价于

核空间另一 SVR 对偶问题<sup>[15]</sup>, 即

$$\begin{aligned} \max \quad & W(\alpha, \alpha^*) = -\frac{1}{2} \sum_{i,j=1}^N (\alpha_i - \alpha_i^*) H(\alpha_j - \alpha_j^*) + \\ & \sum_{j=1}^N \sum_{k=1}^N (\alpha_j - \alpha_j^*) f'_0(x_{k+1}(t)); \\ \text{s.t.} \quad & \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0, \sum_{i=1}^N (\alpha_i + \alpha_i^*) = Cv, \\ & \alpha_i, \alpha_i^* \in [0, C/N], i = 1, 2, \dots, N. \end{aligned} \tag{8}$$

其中:  $H$  为核函数, 且  $H = P_{ij} \langle f'_1(x_i(t)), f'_1(x_j(t)) \rangle + Q_{ij}$ , 这里

$$\begin{aligned} P_{ij} &= \begin{cases} \frac{1 + \lambda}{1 + 2\lambda}, & 1 \leq i, j \leq N_s - 1 \text{ or} \\ & N_s \leq i, j \leq N; \\ \frac{\lambda}{1 + 2\lambda}, & \text{otherwise.} \end{cases} \\ Q_{ij} &= \begin{cases} \frac{1}{4\lambda}, & 1 \leq i, j \leq N_s - 1 \text{ or } N_s \leq i, j \leq N; \\ -\frac{1}{4\lambda}, & \text{otherwise.} \end{cases} \end{aligned} \tag{9}$$

$\langle f'_1(x_i(t)), f'_1(x_j(t)) \rangle$  为向量内积,  $\lambda$  为权衡因子. 选择

$$\begin{aligned} \langle f'_1(x_i(t)), f'_1(x_j(t)) \rangle &= \\ \exp(-\sigma \|f'_1(x_i(t)), f'_1(x_j(t))\|^2), \quad \sigma > 0. \end{aligned}$$

代入式(8), 求得  $\alpha_i$ 、 $\alpha_i^*$  和  $b$  后, 迁移学习灰支持向量回归机当前模型为

$$\begin{aligned} \hat{F}'_1(x_{i'}(t)) &= \sum_{k=1}^{N_s-1} (\alpha_i - \alpha_i^*) (P_{ij} \langle f'_1(x_k(t)), \\ & f'_1(x_{i'}(t)) \rangle + Q_{ij}) + b, \\ \forall k &= 1, 2, \dots, N_s - 1. \end{aligned} \tag{10}$$

其中:  $\hat{F}'_1(x_{i'}(t))$  为对测试个体  $x_{i'}(t)$  的 1-AGO 序列适应值  $f'_1(x_{i'}(t))$  的迁移学习灰支持向量回归机预测值.

将  $\hat{F}'_1(x_{i'}(t))$  恢复为原始序列刻度  $\hat{F}(x_{i'}(t))$ , 同时, 计算模型逼近误差  $\delta$ , 有

$$\delta = \frac{1}{N_e - 1} \sum_{i'=1}^{N_e-1} \frac{|\hat{F}(x_{i'}(t)) - f(x_{i'}(t))|}{f(x_{i'}(t))} \times 100\%. \tag{11}$$

$\delta$  反映了当前模型的性能, 较小的  $\delta$  表示模型具有较强的逼近性. 当  $\delta$  大于事先设定的阈值  $\varphi_{\text{GSVR}}$  时, 根据用户新的标注数据, 从目标域中删除原有 30% 训练数据, 从目标域剩余数据中重新按相似度选择 30% 训练数据补充, 按式(7)更新迁移学习灰支持向量回归机模型.

## 5 聚类进化策略

### 5.1 聚类选择算子

设第  $t$  代聚类子集  $x_A$ 、 $x_B$  内有个体  $x_i$ 、 $x_j$ . 对个体  $x_i$ 、 $x_j$  进行选择操作时, 首先判断随机选择个体  $x_i$ 、 $x_j$  的支配关系. 若可以确定支配关系则较优个体被选择; 若  $x_i$ 、 $x_j$  互不支配, 则比较两个个体平均距离内个体数量, 数量少的个体被优先选择; 如果  $x_i$ 、 $x_j$  平均距离内具有相同个体数量, 则随机选择两者其一.  $x_i$  的平均距离为

$$\text{step}(x_i) = \frac{f_{\max}(x_A) - f(x_i)}{2|x_A|}. \quad (12)$$

其中:  $f_{\max}(x_A)$  为聚类子集  $x_A$  中的最大适应值,  $f(x_i)$  为  $x_i$  的适应值. 同理, 可得  $x_j$  的平均距离为

$$\text{step}(x_j) = \frac{f_{\max}(x_B) - f(x_j)}{2|x_B|}.$$

### 5.2 聚类交叉算子

与聚类选择算子设计类似, 为了增加种群个体的多样性, 在交叉算子中引入聚类子集决策变量的平均距离. 对于第  $t$  代聚类子集  $x_A$ 、 $x_B$  内的个体  $x_i$ 、 $x_j$ ,  $x_i = x_{i1}x_{i2} \dots x_{iN_g}$ ,  $x_j = x_{j1}x_{j2} \dots x_{jN_g}$ , 交叉算子<sup>[14]</sup>如下:

$$x_{\text{new}} = (x_i + (r_1 \times \text{step}_{x_A})) \otimes (x_j + (r_2 \times \text{step}_{x_B})). \quad (13)$$

其中:  $x_{\text{new}}$  为交叉后生成的新个体,  $r_1$ 、 $r_2$  为  $[-1, 1]$  内随机数,  $\text{step}_{x_A}$ 、 $\text{step}_{x_B}$  分别为聚类子集  $x_A$ 、 $x_B$  每维决策变量的平均距离. 记  $|x_A|$  为聚类子集  $x_A$  的规模,  $l_1^r, l_2^r, \dots, l_{|x_A|}^r$  为聚类子集  $x_A$  内个体第  $r$  维决策变量的属性值, 则聚类子集  $x_A$  第  $r$  维决策变量的平均距离为

$$\text{step}_{x_A}^r = \frac{\max\{l_1^r, l_2^r, \dots, l_{|x_A|}^r\} - \min\{l_1^r, l_2^r, \dots, l_{|x_A|}^r\}}{2|x_A|}, \quad (14)$$

进而有  $\text{step}_{x_A} = (\text{step}_{x_A}^1, \text{step}_{x_A}^2, \dots, \text{step}_{x_A}^{N_g})$ . 同理可得  $\text{step}_{x_B} = (\text{step}_{x_B}^1, \text{step}_{x_B}^2, \dots, \text{step}_{x_B}^{N_g})$ .

综合上述, 本文算法如下.

#### 算法 1 IEC-TGSVR.

- 1) data:  $P, N, p_c \cdot p_m, T$ ;
- 2) result: IEC-TGSVR.
- 3) step 1: initializing population
- 4)  $t \leftarrow 0$ ;
- 5) while  $t < T$  do
- 6) step 2: uscrs evaluation individuals
- 7) for  $A \leftarrow 1$  to  $N_c$  do
- 8)  $p(t) \leftarrow f(x_A(t))$ ;

9) step 3: calculating individual similarity by 式 (2), clustering  $p(t)$  and estimating fitness by 式 (3)

10) for  $0 \leftarrow 1$  to  $N - N_c$  do

11)  $x_A(t) \leftarrow x_o(t)$  by 式 (2);

12)  $p(t) \leftarrow f(x_o(t))$  by 式 (3)

13) end

14) step 4: establishing TGSVR, and predicting fitness

15) for  $k \leftarrow 1$  to  $N$  do

16)  $p(t) \leftarrow f'_0(x_k(t))$

17)  $(\omega_h, b_h), (\omega_c, b_c) \leftarrow \max W(\alpha, \alpha^*)$  by 式 (8)

18) for  $i' \leftarrow 1$  to  $N_e$  do

19)  $p(t) \leftarrow \hat{F}'_1(x_i(t))$  by 式 (11)

20) end

21) end

22) end

23) step 5: generating the temporary population

24) for  $i \leftarrow 1$  to  $N$  do

25)  $x_i \leftarrow \text{step}(x_i)$  by 式 (14)

26)  $x_A, x_B \leftarrow \text{step}_{x_A}^r, \text{step}_{x_B}^r$  by 式 (16)

27)  $p'(t) \leftarrow \text{selection-crossover-mutation-pop}(p(t))$ ;

28)  $Q(t) = p(t) \cup p'(t)$ ;

29)  $F \leftarrow \text{fast-non-dominated-sor}(Q(t))$ ;

30)  $p(t+1) \leftarrow \emptyset$ ;  $i \leftarrow 1$ ;

31) end

32) step 6: obtaining ranks and crowding distances of the first  $N_c$  individuals

33) repeat

34)  $F_i \leftarrow \text{step}(x_i)$  by 式 (14)

35)  $p(t+1) \leftarrow p(t+1) \cup F_i$ ;

36)  $i \leftarrow i + 1$ ;

37)  $|p(t+1)| + |F_i| \leq N_c$

38) until

39)  $\text{sort}(F_i, \succ_n)$ ;

40)  $p(t+1) \leftarrow p(t+1) \cup F_i[1 : (N_c - |p(t+1)|)]$ ;

41)  $t \leftarrow t + 1$ ;

42) end while

### 5.3 性能分析

运算主要分 3 部分: 1) 个体相似度计算时间复杂度为  $O(N - N_c)$ , 个体适应值估计时间复杂度为  $O(N_c^2)$ ; 2) 迁移学习灰支持向量机计算时间复杂度为  $O(N_c^3)$ ; 3) NSGA-II 的计算时间复杂度为  $O(N^2)$ . 综

上所述,本文算法的时间复杂度为 $O(N_c^3)$ .

## 6 实例验证

### 6.1 问题描述

将所提出方法应用于室内灯光调色问题,验证方法的有效性. 灯光调色是一种重要的建筑装饰手段,室内灯光调色系统通过3盏色灯的3种颜色变化以及它们相互叠加得到的各种调和颜色渲染室内装修效果. 这是一类适宜用交互式进化优化方法求解的隐式指标优化问题.

本问题将3盏LED色灯组合方案作为个体,即个体由3个属性意义单元组成, $r' = 3$ . 由于每盏色灯均

由红(R)、绿(G)、蓝(B)三种颜色通道构成,样本染色体由每盏色灯的RGB三个决策变量(属性)组成,每1个RGB变量取值范围(属性值)均为 $0 \sim 255$ . 每个属性值用8位二进制编码,每个染色体共有9个色彩属性, $N_g = 9$ ,染色体共由72位二进制编码组成. 其中:前24位表示第1盏灯,中间24位表示第2盏灯,最后24位表示第3盏灯. 图2给出了染色体编码过程,其中个体 $((0, 191, 191), (0, 255, 127), (255, 170, 255))$ 的染色体编码为 $((00000000 \ 10111111 \ 10111111) (00000000 \ 11111111 \ 01111111) (11111111 \ 10101010 \ 11111111))$ .

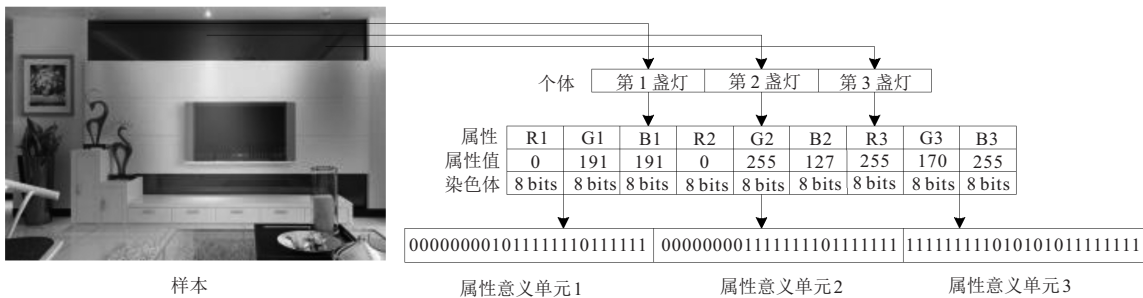


图2 个体与染色体编码

### 6.2 参数设置及操作

目前尚没有迁移学习应用于交互式进化优化的直接基准性算法,所以基于所提出算法思想,以改造的基于传统支持向量回归机的交互式进化计算(interactive evolutionary computation base on support vector regression, IEC-SVR)、基于灰支持向量回归机的交互式进化计算(interactive evolutionary computation base on grey support vector regression, IEC-GSVR)和基于灰支持向量回归机预测适应值的交互式集合进化计算(set-based interactive evolutionary computation with forecasting fitness by grey support vector regression, SIEC-GSVR)<sup>[11]</sup>3种相关算法作为比较算法,验证所提出算法在搜索效率、优化质量、减轻用户疲劳等方面的有效性.

采用 Visual Basic 6.0 软件,分别基于4种算法开发相应系统. 4种算法均采用大规模种群进化,遗传操作采用规模为2的联赛选择,种群规模 $N = 200$ ,交叉和变异概率分别为 $p_c = 0.5$ 、 $p_m = 0.1$ ,用户评价个体数 $N_c = 6$ ,适应值范围是 $1 \sim 99$ 之间的整数,最大进化代数 $T = 15$ . 本文算法主要参数如下:式(7)中 $C/N = 1, v = 0.25$ ;式(9)和(10)中 $\lambda = 5$ ;TG-SVR高斯核函数参数 $\sigma = 0.06$ ;式(13)的阈值 $\varphi_{GTSVR} = 0.2$ . 选择男女各5名在校大学生作为测试用户,记为

用户1~10. 基于4种方法的进化优化系统人机交互界面统一如图3所示.




图3 人机交互界面

### 6.3 实验结果与分析

算法性能比较测试分2个项目进行:以灯光调色效果符合“温馨”标准的非固定解优化测试(项目1)和以图2所示个体 $((0, 191, 191), (0, 255, 127), (255, 170, 255))$ 为优化目标的固定解优化测试(项目2),验证所提出方法在搜索效率、求解能力和可用性等方面的有效性.

非固定解优化测试项目的目的是测试算法对个性偏好目标的搜索能力. 要求10位用户根据“温馨”风格标准,采用所提出算法和对比方法在最大进化代数内不限耗时各运行5次. 项目1结束一周后,进行以

图 2 所示个体 ((0,191,191), (0,255,127), (255,170,255)) 为优化目标的固定解优化测试. 固定解优化测试的目的是测试算法对共性偏好目标的搜索能力, 该项目要求 10 名用户在最大进化代数内不限耗时, 分别利用所提出算法和比较算法各运行 5 次, 2 个测试项目总计 300 人次进化优化.

在算法搜索效率方面, 分别统计 2 个项目的算法进化代数、优化耗时和最优解适应值均值, 并用  $t$  检验, 统计结果如表 1 所示. 统计 3 种算法的评价最优解数目、算法效用和成功率, 其中成功率采用二分式成功法 (binary success) 统计, 记算法效用函数  $\text{eff}$  为

$$\text{eff} = \frac{1}{T'} \sum_{t=1}^{T'} \frac{N_{co}^t}{N_c} \quad (15)$$

其中:  $T'$  为算法运行终止进化代数;  $N_{co}^t$  为当前  $t$  代用户评价满意的个体数目;  $\text{eff}$  越大, 算法效用越高. 统

计结果如表 2 所示.

在算法求解能力方面, 采用性能指标  $J$  衡量算法的泛化性, 即

$$J = \frac{\sum_{i'=1}^{N_e} (f(x_{i'}(t)) - \hat{F}(x_{i'}(t)))^2}{N_e \cdot (f_{\max}(x_{i'}(t)) - f_{\min}(x_{i'}(t)))^2} \quad (16)$$

较小的  $J$  值表示较强的泛化能力, 统计 10 位用户的  $J$  均值, 结果如表 3 所示. 在本文方法中, 用户评价数目  $N_c$  和参数  $\lambda$  对 TG-SVR 性能影响很大, 采用交叉验证算法泛化性对  $N_c$  和  $\lambda$  的敏感性, 结果如表 4 所示.

由式 (13), 统计 2 个项目中的算法的迁移学习灰支持向量机逼近误差均值如图 4 所示. 为了分析聚类进化效果, 统计每一进化代中种群聚类子集个体数量的标准差, 如图 5 所示. 记每一进化代中非被占优解的个数为  $ND$ , 则非被占优解比例为  $ND/N$ , 统计结果如图 6 所示.

表 1 算法进化代数、优化耗时和最优解适应值比较

指标	算法	项目 1			项目 2		
		均值	方差	$t$ 检验	均值	方差	$t$ 检验
进化代数	本文算法	<b>9.45</b>	<b>3.18</b>	<b>0.0357</b>	<b>10.64</b>	<b>4.31</b>	<b>0.0238</b>
	IEC-GSVR	10.16	3.64		11.54	4.58	
	本文算法	<b>9.45</b>	<b>3.18</b>	<b>0.0168</b>	<b>10.64</b>	<b>4.31</b>	<b>0.0095</b>
	IEC-SVR	12.49	4.72		13.08	5.49	
	本文算法	<b>9.45</b>	<b>3.18</b>	<b>0.0223</b>	<b>10.64</b>	<b>4.31</b>	<b>0.0179</b>
	SIEC-GSVR	10.08	3.79		11.36	4.45	
优化耗时	本文算法	<b>4'16"</b>	<b>2.75</b>	<b>0.0347</b>	<b>5'28"</b>	<b>2.39</b>	<b>0.0135</b>
	IEC-GSVR	5'32"	3.07		6'12"	2.56	
	本文算法	<b>4'16"</b>	<b>2.75</b>	<b>0.0208</b>	<b>5'28"</b>	<b>2.39</b>	<b>0.0073</b>
	IEC-SVR	6'45"	3.52		6'46"	3.94	
	本文算法	<b>4'16"</b>	<b>2.75</b>	<b>0.0363</b>	<b>5'28"</b>	<b>2.39</b>	<b>0.0165</b>
	SIEC-GSVR	5'18"	2.98		5'44"	2.46	
最优解适应值	本文算法	<b>88.58</b>	<b>10.37</b>	<b>0.0329</b>	<b>83.94</b>	<b>11.39</b>	<b>0.0384</b>
	IEC-GSVR	85.66	17.32		80.35	23.75	
	本文算法	<b>88.58</b>	<b>10.37</b>	<b>0.0175</b>	<b>83.94</b>	<b>11.39</b>	<b>0.0276</b>
	IEC-SVR	80.43	18.65		78.61	19.28	
	本文算法	<b>88.58</b>	<b>10.37</b>	<b>0.0254</b>	<b>83.94</b>	<b>11.39</b>	<b>0.0163</b>
	SIEC-GSVR	86.41	16.39		81.53	20.73	

表 2 算法优化解数目、算法效用和成功率

算法	项目 1			项目 2		
	评价最优解数目	算法效用 $\text{eff}/\%$	成功率 $\%$	完全匹配解用户	算法效用 $\text{eff}/\%$	成功率 $\%$
本文算法	<b>41.36</b>	<b>36.25</b>	<b>88.63</b>	<b>4</b>	<b>32.78</b>	<b>82.45</b>
SIEC-GSVR	<b>38.55</b>	<b>30.61</b>	<b>80.26</b>	<b>3</b>	<b>30.84</b>	<b>80.19</b>
IEC-GSVR	35.62	27.12	77.35	3	25.84	75.36
IEC-SVR	34.82	18.67	75.28	2	17.59	70.62

表3 算法泛化性

用户	项目1-J值				项目2-J值			
	本文算法	SIEC-GSVR	IEC-GSVR	IEC-SVR	本文算法	SIEC-GSVR	IE-GSVR	IEC-SVR
1	<b>2.042 7e-003</b>	3.514 3e-003	5.189 7e-003	5.651 7e-003	<b>3.175 4e-003</b>	4.785 3e-003	5.420 3e-003	7.182 3e-003
2	<b>3.152 0e-003</b>	3.214 6e-003	4.350 9e-002	6.619 7e-003	<b>2.962 7e-003</b>	2.745 3e-003	2.972 9e-003	3.153 7e-002
3	<b>1.170 7e-003</b>	1.265 1e-003	3.998 6e-003	3.370 3e-003	<b>3.110 2e-003</b>	3.510 2e-003	3.921 5e-003	5.389 2e-003
4	<b>2.284 3e-003</b>	3.173 5e-003	3.078 3e-003	3.538 8e-002	<b>1.762 8e-003</b>	2.052 5e-003	2.146 0e-003	3.460 6e-003
5	<b>1.545 3e-003</b>	1.658 2e-003	4.813 4e-003	6.520 1e-003	<b>3.089 2e-003</b>	3.614 2e-003	3.738 9e-003	6.549 5e-003
6	<b>5.679 2e-003</b>	6.258 4e-003	6.940 0e-002	8.480 9e-003	<b>4.386 2e-004</b>	4.927 1e-003	5.101 3e-003	8.293 7e-003
7	<b>2.191 1e-003</b>	2.506 2e-003	2.794 1e-002	2.334 9e-002	<b>2.581 6e-003</b>	2.814 9e-003	3.456 9e-003	3.867 4e-002
8	<b>1.081 7e-003</b>	1.135 2e-003	2.374 0e-003	5.030 3e-002	<b>2.365 4e-003</b>	3.854 9e-003	4.418 6e-003	5.150 8e-003
9	<b>3.892 5e-003</b>	4.149 2e-003	5.817 4e-002	8.925 3e-003	<b>3.652 4e-003</b>	4.524 6e-003	4.145 2e-003	6.612 2e-003
10	<b>1.308 4e-004</b>	2.064 3e-003	2.224 5e-003	2.781 5e-004	<b>1.767 5e-003</b>	1.965 7e-003	2.190 8e-003	3.354 1e-003
<i>t</i> 检验	0.022	—	—	—	0.047	—	—	—
	0.032	—	—	—	0.019	—	—	—
	0.040	—	—	—	0.046	—	—	—

表4  $N_c$  和  $\lambda$  对本文算法泛化性的敏感性

$N_c$	$\lambda, \sigma$	项目1-J值	项目2-J值	<i>t</i> 检验
6	(5, 0.06)	2.481 5e-003	2.238 3e-003	0.477
	(4, 0.06)	3.530 9e-003	3.634 2e-003	
	(3, 0.06)	4.515 6e-003	4.194 7e-003	
5	(5, 0.06)	4.452 9e-003	4.652 9e-003	0.477
	(4, 0.06)	5.176 3e-003	5.799 3e-003	
	(3, 0.06)	5.884 1e-003	6.164 1e-003	
4	(5, 0.06)	6.857 4e-003	6.429 2e-003	0.477
	(4, 0.06)	7.285 1e-003	7.548 3e-003	
	(3, 0.06)	8.309 2e-003	8.604 2e-003	

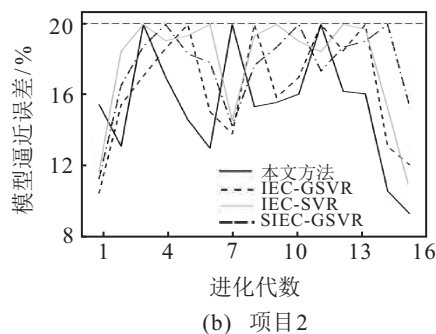



图4 迁移学习支持向量机逼近误差

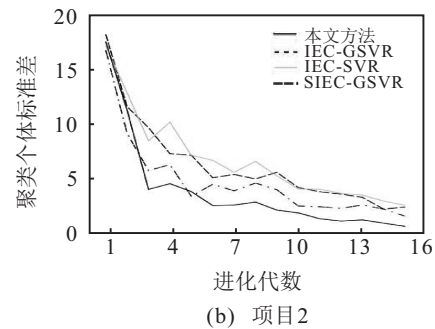



图5 聚类个体标准差

在算法可用性方面,统计用户的迷失度  $L$ . 迷失度用于度量用户对操作对象的迷茫程度,反映用户的疲劳性感受,有

$$L = \sqrt{(N'_o / (T' \cdot N_c) - 1)^2 + (N''_o / N'_o - 1)^2} \quad (17)$$

其中:  $N'_o$  为用户在一次进化任务中评价的互异个体数目,  $N''_o$  为用户在一次进化任务中获得的最优评价的个体数目,  $T'$  为算法运行终止进化代数. 用户迷失度箱图如图7所示.

由表1~表4和图4~图7对实验结果分析如下:

1) 搜索效率方面.

由表1可见,2个项目,所提出算法的进化代数

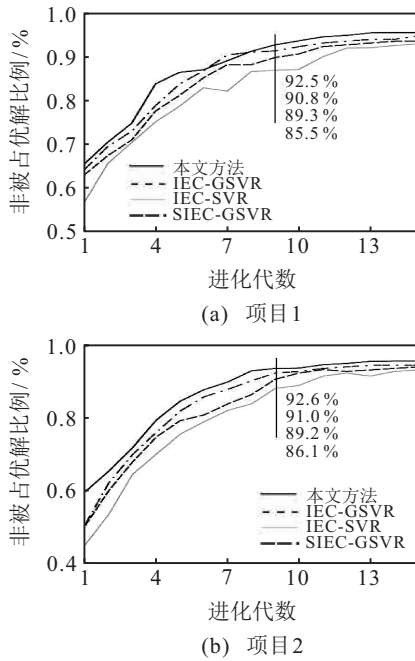


图6 非被占优解比例

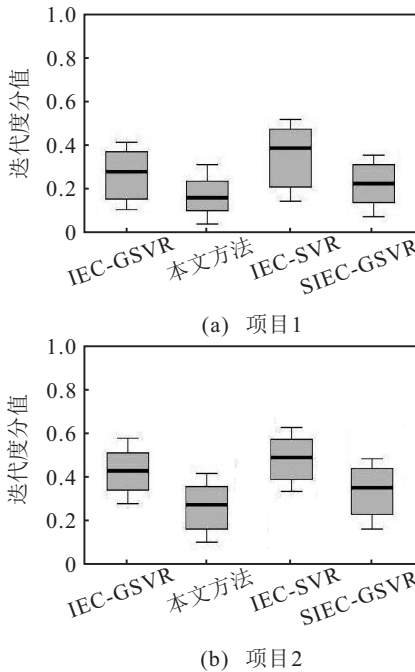


图7 用户迷失度

和优化耗时均小于对比方法,最优解适应值则高于对比方法,且 $t$ 检验差异显著( $p < 0.05$ ).表明所提出方法可以在最少的操作量和操作时间里获得质量最好的优化解.但项目2与项目1对比,前者在进化代数和优化耗时上均高于后者,最优解适应值则低于后者.这是因为相比非固定优化解,固定解优化搜索难度较大,算法在较少的进化代数内难以找到与目标相似或完全匹配的个体,个体适应值相对较低,较长的进化代数导致耗时增加.

由表2可见,2个项目,所提出算法的算法效用和成功率都是最高的.项目1中,所提出算法的评价

最优解数目高于对比方法;项目2中,所提出算法获得完全匹配解用户最多.这表明所提出算法对于优化的搜索效率最高.

2) 求解能力方面.

由表3可见,所提出算法的 $J$ 值均小于对比方法, $t$ 检验结果差异显著( $p < 0.05$ ).表明所提出算法具有更好的泛化性,更适用于信息不充分情况下的决策优化.原因在于所提出算法采用可调参数用于平衡 $f_h$ 和 $f_c$ 的结构风险,对于用户未评价个体适应值的信息补偿更客观,有效提高了适应值预测能力.

由表4可见,所提出算法对参数 $N_c$ 和 $\lambda$ 较为敏感. $N_c$ 改变,意味着 $f_h$ 和 $f_c$ 的差异改变.当 $N_c$ 减小时, $f_h$ 和 $f_c$ 差异会增大, $J$ 值相应增大,算法泛化性降低.当 $N_c$ 保持不变时,权衡因子 $\lambda$ 减小同样会使 $f_h$ 和 $f_c$ 的差异增大, $J$ 值也相应增大.

由图4可见,在进化过程中,4种方法的模型逼近误差均呈锯齿状波动,反映出支持向量回归机逼近误差超过阈值时,需要不断更新模型,重新获得逼近精度的提高.2个项目中,所提出算法和SIEC-GSVR的模型更新3次,其他方法模型更新4次,这表明IEC-SVR与IEC-GSVR的模型匹配能力相对较差.由图4还可以看出,大约从第5代以后,除模型更新时刻外,所提出算法的逼近误差低于对比方法,表明所提出算法的整体预测精度最高.SIEC-GSVR虽然模型更新次数较少,但逼近误差略大于IEC-GSVR,原因在于采用集合进化后,SIEC-GSVR收敛速度加快,但同时也让逼近误差增加.

由图5可见,4种方法的聚类个体数量标准差均逐渐减小,表明子集内个体数量逐渐变均匀.但所提出算法的聚类个体标准差最小,表明所提出算法的聚类进化策略能更快地保持小种群个体数量相对均匀,克服了局部收敛.同时,采用基于多模态优化的个体相似度比较,可以获得更多的多模态个体,增加了算法聚类效果.

由图6可见,2个测试项目中,4种方法的非被占优解比例均不断增加,且本文方法最高,采用GSVR的SIEC-GSVR和IEC-GSVR则高于IEC-SVR.

3) 可用性方面.

由图7可见,2个项目中,所提出算法的迷失度都是最小的,且迷失度均小于0.5.项目1中,4种方法的迷失度均小于0.5,项目2中,IEC-GSVR和IEC-SVR部分用户迷失度大于0.5,这表明固定解优化更容易产生疲劳.另外,SIEC-GSVR的迷失度在3种对比方法中最低,表明提高收敛速度和适应值准确性

可以更好地降低用户迷失性. 对实验数据进行 Mann-Whitney U 非参数检验, 结果显示所提出算法与对比方法差异显著 ( $p < 0.05$ ), 这表明用户使用所提出算法没有产生迷失特征, 有效预防了疲劳发生.

综上所述, 所提出算法搜索效率最高、求解能力更强、可用性更好, 明显提高了算法性能, 可以有效求解色彩调和这类大样本复杂优化问题.

## 7 结论

针对交互式进化计算大规模种群评价与相关进化策略改进问题, 提出基于迁移学习灰支持向量回归机的个体适应值预测方法和聚类进化策略, 将代理模型引入迁移学习机制完成适应值评价, 在已估计个体适应值基础上进行适应值预测. 同时, 采用基于个体平均距离的聚类进化策略实现聚类子集的并行进化. 最后, 在室内灯光调色问题上验证所提出算法能有效提高优化效率, 减轻用户疲劳. 开发更合理的迁移学习方法应用于交互式进化计算是下一步要研究的问题.

## 参考文献(References)

- [1] 范向民, 范俊君, 田丰, 等. 人机交互与人工智能: 从交替浮沉到协同共进[J]. 中国科学: 信息科学, 2019, 49(3): 361-368.  
(Fan X M, Fan J J, Tian F, et al. Human-computer interaction and artificial intelligence: From competition to integration[J]. Scientia Sinica: Informations, 2019, 49(3): 361-368.)
- [2] Xin B, Chen L, Chen J, et al. Interactive multiobjective optimization: A review of the state-of-the-art[J]. IEEE Access, 2018, 6: 41256-41279.
- [3] Yan P, Hideyuki T. Research progress survey on interactive evolutionary computation[J]. Journal of Ambient Intelligence and Humanized Computing, 2018: 1-14.
- [4] 陈杨. 面向个性化搜索的交互式分布估计算法[D]. 徐州: 中国矿业大学, 2019.  
(Chen Y. Interactive estimation of distribution algorithm for personalized search[D]. Xuzhou: China University of Mining and Technology, 2019.)
- [5] Alan T W M, Yew S O, Abhishek G, et al. Multiproblem surrogates: Transfer evolutionary multiobjective optimization of computationally expensive problems[J]. IEEE Transactions on Evolutionary Computation, 2019, 23(1): 15-28.
- [6] Dinh T T H, Chu T H, Nguyen Q U. Transfer learning in genetic programming[C]. IEEE Congress on Evolutionary Computation. Piscataway: IEEE, 2015: 1145-1151.
- [7] Feng L, Ong Y S, Tan A H, et al. Memes as building blocks: A case study on evolutionary optimization+transfer learning for routing problems[J]. Memetic Computing, 2015, 7(3): 159-180.
- [8] Jiang M, Huang Z, Qiu L, et al. Transfer learning based dynamic multiobjective optimization algorithms[J]. IEEE Transactions on Evolutionary Computation, 2018, 22(4): 501-504.
- [9] 张勇, 杨康, 郝国生, 等. 基于相似历史信息迁移学习的进化优化框架[J]. 自动化学报, 2021, 47(3): 1-14.  
(Zhang Y, Yang K, Hao G S, et al. Evolutionary optimization framework based on transfer learning of similar historical information[J]. Acta Automatica Sinica, 2021, 47(3): 1-14.)
- [10] Saha Indrajit, Maulik Ujjwal. Incremental learning based multiobjective fuzzy clustering for categorical data[J]. Information Sciences, 2014, 267: 35-57.
- [11] 郭广颂, 文振华, 郝国生. 基于灰支持向量回归机预测适应值的交互式集合进化计算[J]. 控制与决策, 2020, 35(2): 309-318.  
(Guo G S, Wen Z H, Hao G S. Set-based interactive evolutionary computation with forecasting fitness by grey support vector regression[J]. Control and Decision, 2020, 35(2): 309-318.)
- [12] Mukhopadhyay A, Maulik U, Bandyopadhyay S. Multiobjective genetic algorithm-based fuzzy clustering of categorical attributes[J]. IEEE Transactions on Evolutionary Computation, 2009, 13(5): 991-1005.
- [13] 刘丛, 万秀华. 基于多目标进化算法的多距离聚类研究[J]. 计算机应用研究, 2019, 36(1): 94-98.  
(Liu C, Wan X H. Research on multiple distance clustering based on multi-objective evolutionary algorithm[J]. Application Research of Computers, 2019, 36(1): 94-98.)
- [14] 崔志华, 张茂清, 常宇, 等. 基于平均距离聚类的 NSGA-II[J]. 自动化学报, DOI: 10.16383/j.aas.C180540.  
(Cui Z H, Zhang M Q, Chang Y, et al. NSGA-II with average distance clustering[J]. Acta Automatica Sinica, DOI: 10.16383/j.aas.C180540.)
- [15] 史炎中, 王士同, 蒋亦樟, 等. 迁移学习支持向量回归机[J]. 计算机应用, 2013, 33(11): 3084-3089.  
(Shi Y Z, Wang S T, Jiang Y Z, et al. Transfer learning support vector regression[J]. Journal of Computer Applications, 2013, 33(11): 3084-3089.)
- [16] Wei Y, Zhu Y, Leung C, et al. Instilling social to physical: Co-regularized heterogeneous transfer learning[C]. Thirtieth AAAI Conference on Artificial Intelligence. Palo Alto: AAAI, 2016, 2: 1338-1344.

## 作者简介

郭广颂(1978—), 男, 教授, 从事进化计算、机器学习等研究, Email: guogs78@126.com;

高海荣(1980—), 男, 讲师, 从事数值计算与优化的研究, E-mail: lcto-long@163.com;

张勇(1979—), 男, 教授, 博士生导师, 从事群体智能、机器学习等研究, Email: yongzh401@126.com.