

控制与决策

Control and Decision

基于多代理辅助多目标进化优化的建筑节能智能设计方法

张勇, 梁晓珂, 陈志鹏, 巩敦卫

引用本文:

张勇, 梁晓珂, 陈志鹏, 巩敦卫. 基于多代理辅助多目标进化优化的建筑节能智能设计方法[J]. *控制与决策*, 2023, 38(11): 3057–3065.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.2223>

您可能感兴趣的其他文章

Articles you may be interested in

[一种基于MOEA/D的组合权重方法](#)

A combination weight method based on MOEA/D

控制与决策. 2021, 36(12): 3056–3062 <https://doi.org/10.13195/j.kzyjc.2020.0592>

[一种求解约束多目标问题的协作进化算法](#)

A collaborative evolutionary algorithm for solving constrained multi-objective problems

控制与决策. 2021, 36(11): 2656–2664 <https://doi.org/10.13195/j.kzyjc.2020.0791>

[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>

[基于多种群分解预测的动态多目标引力搜索算法](#)

Dynamic multi-objective gravitational searching algorithm based on multi-population decomposition prediction

控制与决策. 2021, 36(12): 2910–2918 <https://doi.org/10.13195/j.kzyjc.2020.1002>

基于多代理辅助多目标进化优化的建筑节能智能设计方法

张 勇, 梁晓珂[†], 陈志鹏, 巩敦卫

(中国矿业大学 信息与控制工程学院, 江苏 徐州 221116)

摘 要: 进化优化具有优异的全局搜索能力, 已成功应用于建筑节能设计问题. 然而, 由于需要借助代价高昂的建筑能耗软件不断评价个体, 现有建筑节能设计进化算法普遍存在运行代价高的问题. 鉴于此, 提出一种面向建筑节能设计的多代理辅助多目标进化优化算法, 简称 MS-MOEA/D. 首先, 依据 MOEA/D 的目标分解特征同时构建多个基础代理模型; 然后, 针对每个待评估个体, 自动选择合适的基础代理模型, 并使用它们的集成结果预测该个体的目标值, 达到提高其预测精度的目的. 同时, 在进化过程中自主确定基础代理模型的更新时机和规模, 以降低代理模型的管理成本; 最后, 将所提出 MS-MOEA/D 与建筑能耗模拟软件 EnergyPlus 相融合, 建立面向建筑节能设计的多目标进化优化仿真平台, 并将该平台应用于中国北京地区常见居民和办公建筑节能设计实例中. 通过与 7 种典型多目标进化算法进行对比, 结果表明, MS-MOEA/D 在显著降低计算代价的基础上能够得到高竞争力的 Pareto 最优解集.

关键词: 进化优化; 多目标; 建筑节能; MS-MOEA/D; 代理模型

中图分类号: TP301.6

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.2223

引用格式: 张勇, 梁晓珂, 陈志鹏, 等. 基于多代理辅助多目标进化优化的建筑节能智能设计方法[J]. 控制与决策, 2023, 38(11): 3057-3065.

Intelligent design of building energy conservation with multi-surrogate assisted MOEA

ZHANG Yong, LIANG Xiao-ke[†], CHEN Zhi-peng, GONG Dun-wei

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: Evolutionary computation has been successfully applied to building energy conservation design problems because of excellent global search capabilities. However, since the need to continuously evaluate individuals by expensive building energy consumption software, existing evolutionary algorithms generally suffer from high operating cost. In view of this, this paper proposes a multi-surrogate assisted multi-objective evolutionary algorithm for building energy conservation design, called MS-MOEA/D. Firstly, multiple basic surrogate models are constructed simultaneously according to the objective decomposition characteristic of the multi-objective evolutionary algorithm MOEA/D. Then, for each individual that needs to be evaluated, the appropriate base surrogate model is automatically selected, and their integration results are used to predict the objective value of the individual, so as to improve its prediction accuracy. At the same time, the update timing and the scale of the basic surrogate model are determined autonomously in the evolution process, in order to reduce the management cost of the surrogate model. The MS-MOEA/D is integrated with the software EnergyPlus to establish a multi-objective evolutionary simulation platform for building energy conservation design, and the platform is used in the energy conservation design examples of atypical residential and office buildings in Beijing, China. Comparing with seven classical multi-objective evolutionary algorithms, experimental results show that the MS-MOEA/D can obtain a highly competitive Pareto optimal solution set while significantly reducing the computational cost.

Keywords: evolutionary optimization; multi-objective; building energy conservation design; MOEA/D; surrogate model

收稿日期: 2021-12-23; 录用日期: 2022-06-24.

基金项目: 徐州市重点研发计划项目(KC20184); 国家自然科学基金项目(62133015).

责任编委: 陈家伟.

[†]通讯作者. E-mail: liangxiaoke@cumt.edu.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

0 引言

能源是社会最重要的资源之一. 由于建筑行业的能源消耗占全球能源消耗总量的40%左右, 目前已有大量学者致力于建筑节能方面的研究^[1-2]. 同时, 实施建筑节能可极大地改善公共环境和公众健康状况^[3-5]. 由于建筑系统的复杂性与各因素间的相互依赖性, 设计人员经常使用一些建筑能耗模拟软件对其进行模拟分析^[6]. 基于这些模拟软件, 学者们已提出了多种优化技术以提高建筑物的能效. Wang等^[7]开发了一种面向对象的框架, 成功地将建筑设计优化过程与建筑能耗模拟程序相关联. Ge等^[8]对中国5个气候区中6个主要城市的办公建筑进行了热舒适和能源性分析. Castro-Lacouture等^[9]提出了一种面向建筑选材的混合整数优化模型. 近年来, 随着进化算法(evolutionary algorithms, EAs)的快速发展^[10-12], 很多学者成功将其应用于建筑节能设计问题. Junghans等^[13]结合遗传算法与模拟退火算法, 设计了一种混合单目标智能优化算法, 用来同时最小化建筑的能耗和温室气体排放. Bamdad等^[14]开发了一种基于连续蚁群优化的建筑节能算法, 并成功应用于澳大利亚的商业建筑. 然而, 建筑节能设计本质是一类典型的多目标优化问题. 由于多目标进化技术的快速发展^[15-16], 如第2代非支配排序遗传算法(NSGA-II)^[17]、多目标人工蜂群优化(MOABC)^[18]、多目标粒子群(MOPSO)^[19]等典型算法开始应用于建筑节能设计问题. 但是, 由于需要借助代价高昂的建筑能耗软件不断评价个体或解的目标值或适应值, 这些算法依然存在运行代价高昂的不足^[20], 限制了它们在建筑节能问题上的推广应用.

代理模型辅助进化算法(SAEAs)的核心思想为: 使用低代价的代理模型替代计算代价昂贵的真实目标函数用于评价个体^[21]. 针对昂贵单目标优化问题, 目前学者们已提出很多有效的SAEAs算法^[16, 22-24]. 然而, 面向昂贵多目标优化问题, 现有相关研究成果相对较少. Magnier等^[25]使用TRNSYS训练一个神经网络, 将建立的神经网络与遗传算法进行耦合, 用以优化建筑的热舒适和能源消耗等指标. Chen等^[26]使用带有一个隐藏层的前馈神经网络对智能建筑中的温度进行识别, 给出一种基于粒子群优化的建筑参数设计方法. 针对建筑节能问题, Ji等^[27]提出了一种双代理辅助的协同粒子群优化方法, 以寻找建筑能耗最低的最优解. Khan等^[28]针对医院病房通风系统设计问题, 利用昂贵CFD的结果构建代理模型, 提出了一种基于最小二乘法的代理模型构建方

法. Gengembre等^[29]提出了一种基于全局优化的建筑设计方法, 利用Kriging代理模型和粒子群优化算法最小化单一区域建筑模型, 降低了建筑的生命周期成本. Knowles^[30]使用最大化期望改善准则来更新高斯过程模型, 给出一种基于在线横向近似的混合多目标优化算法(ParEGO). 因为在进化过程中需要不断计算个体的真实函数值, 这些方法用于代理模型管理的计算代价仍然较大. 更为重要的是, 面向计算代价高昂的多目标建筑节能设计问题, 目前仍然没有相关研究成果.

为显著减少EAs处理建筑节能设计问题的计算代价, 本文提出一种多代理模型辅助的改进MOEA/D算法. 首先, 依据MOEA/D的目标分解特征同时构建多个基础代理模型; 然后, 针对每个待评估个体, 自动选择合适的基础代理模型, 并使用它们的集成结果预测该个体的目标值, 达到提高其预测精度的目的. 同时, 在进化过程中自主确定基础代理模型的更新时机和规模, 用以降低代理模型的管理成本.

本文主要内容如下:

1) 建立一种基于目标分解的多代理模型构建和管理机制. 根据每个参考权重向量上最优解的变化程度, 自主确定需要更新的基础代理模型. 在保证代理模型精度的基础上, 该机制可有效降低模型的更新代价.

2) 给出一种基于相邻代理聚合的个体评价机制. 面向不同的待评估个体, 采用邻域聚合机制自主集成多个最相关的基础代理模型, 达到提高其预测精度的目的.

3) 提出一种融合预测结果的参考点更新方式, 在有效避免个体搜索无效目标区域的同时, 可提高所得Pareto前沿的延展性.

4) 将所提方法与能耗模拟软件EnergyPlus相结合, 建立面向昂贵建筑结构节能设计问题的多目标进化优化仿真平台, 并在平台上验证所提出算法的有效性.

1 多目标建筑节能设计问题描述

在建筑设计优化中, 最主要的2个指标是建筑能源消耗和用户不舒适度. 结合EnergyPlus模拟软件^[31]描述问题的多目标优化模型. 以房间朝向 x_{or} 、墙体外保温层厚度 x_{tolw} 、外墙日射吸收率 x_{sar} 、窗户的传热系数 x_{ghc} 、窗户的太阳得热系数 x_{shgc} 、客厅窗户长 x_{lkl} 、客厅窗户宽 x_{lwl} 、卧室窗户长 x_{bwl} 、卧室窗户宽 x_{bww} 、厨房窗户长 x_{kwl} 、厨房窗户宽 x_{kww} 、卫生间

窗户长 x_{wwl} 、卫生间窗户宽 x_{www} 、客厅照明密度 x_{lepd} 、卧室照明密度 x_{bepd} 、厨房照明密度 x_{kepd} 、卫生间照明密度 x_{wepd} 、空调系统供热设置温度 x_{hst} 、空调系统制冷设置温度 x_{cst} 等系统控制参数作为决策变量. 给定上述参数的1组值后, 运行EnergyPlus软件, 该软件即可输出当前建筑的年能耗数(BEC)和年用户不舒适小时数(UDH)等指标. 所建多目标建筑节能优化模型可描述为

$$\begin{aligned} \min F &= (\text{BEC}(X), \text{UDE}(X)); \\ \text{s.t. } X &= (x_{\text{or}}, x_{\text{tolw}}, x_{\text{srar}}, x_{\text{ghic}}, x_{\text{shgc}}, x_{\text{lw1}}, x_{\text{lw2}}, \\ & x_{\text{bw1}}, x_{\text{bw2}}, x_{\text{kw1}}, x_{\text{kw2}}, x_{\text{ww1}}, x_{\text{www}}, \\ & x_{\text{lepd}}, x_{\text{bepd}}, x_{\text{kepd}}, x_{\text{wepd}}, x_{\text{hst}}, x_{\text{cst}}). \end{aligned} \quad (1)$$

当给定这些参数1组取值后, 通常需要长时间运行EnergyPlus软件才能获得这个解的目标函数值(即BEC和UDH值)^[20,32].

2 所提出多代理辅助MOEA/D算法

为有效解决第1节给出的昂贵多目标建筑节能设计问题, 提出一种多代理辅助的MOEA/D求解方法(MS-MOEA/D). 首先, 给出所提算法的基本框架.

2.1 所提出算法框架

图1为所提出MS-MOEA/D算法的基本框架. 该框架主要由4个模块组成, 即多代理模型的构建和管理、基于MOEA/D的种群更新、基于相邻代理聚合

的个体评价、参考点的更新. 其中, 模块“多代理模型的构建和管理”又包含多代理模型的构建/更新、填充样本的生成2个子模块. 模块“多代理模型构建和管理”的作用为: 同时构建多个代表性的基础代理模型, 并使用新增样本不断更新这些基础代理模型, 以尽量确保它们的准确性. 模块“基于MOEA/D的种群更新”的作用为: 使用MOEA/D中的种群更新算子不断产生新解或新个体. 模块“基于相邻代理聚合的个体评价”的作用为: 面向不同的待评估个体, 采用邻域聚合机制自主集成多个基础代理模型, 并采用集成代理模型评价该个体, 达到提高其预测精度的目的. 模块“填充样本的管理”的主要作用为: 从种群中选择高质量的新个体进行真实评价, 并用其更新代理模型使用的样本训练集合Tdata. 模块“参考点的更新”主要用于产生高质量的参考点, 使得算法获得更优的非劣解集.

需要说明的是: 1) 在执行模块“基于MOEA/D的种群更新”时, 仅使用代理模型预测种群中个体的目标函数值; 当需要更新代理模型时, 则调用高耗时的EnergyPlus软件计算代表个体的真实目标值. 2) 并不是每次迭代时均执行模块“多代理模型的构建和管理”; 同时, 当执行模块“多代理模型的构建和管理”时, 并不需要更新所有代理模型. 当在某一参考权重向量方向上的最优解连续 T' 代不变时, 才更新该权重向量对应的代理模型.

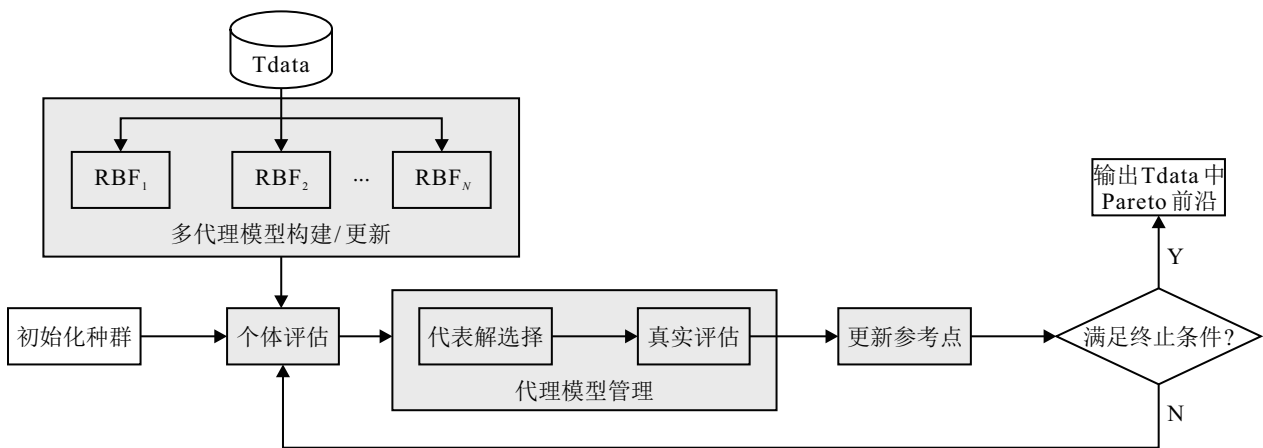


图1 MS-MOEA/D的基本框架

2.2 基于目标分解的多代理模型构建与管理

依据MOEA/D的目标分解特征, 建立一种基于目标分解的多代理模型构建和管理机制. 其中, 分解方法为最常用的切比雪夫分解法^[33]. 针对每个子优化问题建立一个基础代理模型. 当需要评估一个个体的目标值时, 则自主选择与其最为相关的多个基础代理, 并利用它们的集成结果评估该个体. 同时, 在进

化过程中自主确定基础代理的更新时机和规模, 用来提高代理模型的精度.

1) 多代理模型的构建/更新.

不妨设MOEA/D均匀产生的 N 个参考权重向量为 $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_N)$, 在每个权重向量上为每个目标函数产生一个初始基础代理模型, 用来评价该权重向量所确定子优化问题的最优解. 具体地, 首先,

根据文献[34]的建议,使用拉丁超立方采样技术^[35]在决策变量范围内选取 $(D+1)(D+2)/2$ 个采样点,其中 D 为决策变量的个数;然后,将这些点代入EnergyPlus软件中进行仿真运算,得出这些点的2个真实目标函数值,并将其加入至训练数据集Tdata;接着,面向每个权重向量,从Tdata中选择 $g^{\text{tche}}(X|\lambda_i, Z^*)$ 值最小的 N' 个数据点,并使用这些点分别针对每个目标函数训练一个RBF模型,进而产生一对初始基础代理模型.重复上述步骤,直至为每个权重向量产生一对初始基础代理模型.RBF网络中隐含层的节点数取SRGTSToolbox中默认值.此外,本文RBF网络采用常见的 K 均值聚类算法,确定其中心向量和偏差,利用最小均方算法LMS调整网络的连接权值.

2) 填充样本的生成.

在种群进化中需不断选择高质量的训练样本,用于更新这些基础代理模型.针对当前基础代理模型,当在参考权重向量方向 λ_i 上的最优解 $X_{\lambda_i}^*$ (即 $g^{\text{tche}}(X|\lambda_i, Z^*)$ 值最小的解)连续 T' 代不变时,在很大程度上意味着该权重向量方向上的种群可能已收敛.此时,若所用代理模型很精确,则可以认为算法已找到真实问题的最优解;若所用代理模型不精确,则意味着所得结果为当前问题一个伪最优解,需要更新代理模型.由于很难判断代理模型的精度,在整个进化过程中均需要不断更新代理模型,直至算法满足终止条件.

在代理模型的管理过程中,除代理模型更新时机外,选择“正确的”个体进行真实评估进而产生新样本也是一项挑战.为了获得良好的训练样本,应同时考虑代理模型的精确性、群体的收敛性和多样性以选择代表性个体.鉴于此,提出一种基于目标分解的填充样本生成方法.

假设权重向量 λ_i 所对应的一对基础代理模型为 $(\text{RBF}_i^1, \text{RBF}_i^2)$,权重向量 λ_i 对应的最优解为 $X_{\lambda_i}^*$ (即 $g^{\text{tche}}(X|\lambda_i, Z^*)$ 值最小的解),算法1为所提出填充样本生成方法的伪代码.首先,分别从当前种群 $\text{POP}(t)$ 和上代种群 $\text{POP}(t-1)$ 中确定 $X_{\lambda_i}^*$ 的 τ 个邻域个体,不妨设为 $\text{NB}_i(t)$ 和 $\text{NB}_i(t-1)$;然后,计算 $\text{NB}_i(t)$ 与 $\text{NB}_i(t-1)$ 间的支配关系,记 $\text{NB}_i(t)$ 支配 $\text{NB}_i(t-1)$ 中个体的程度为 $\text{dom}(\text{NB}_i(t), \text{NB}_i(t-1))$.由于 $\text{NB}_i(t)$ 中包含目前为止 λ_i 及其邻域发现的最优解,有 $\text{dom}(\text{NB}_i(t), \text{NB}_i(t-1)) \geq 0$;接着,分为如下2种情况生成填充样本.

情况1: $\text{dom}(\text{NB}(t), \text{NB}(t-1)) > \text{dom}(\text{NB}(t-1),$

$\text{NB}(t))$,这意味着 $\text{NB}(t)$ 比 $\text{NB}(t-1)$ 的收敛性更好.此时,选择 $\text{NB}(t)$ 中 $g^{\text{tche}}(X|\lambda_i, Z^*)$ 值最小的个体 $X_{\lambda_i}^*$ 进行真实评价,并用其作为填充样本.选择最优解 $X_{\lambda_i}^*$ 作为填充样本,可提高基础代理模型 $(\text{RBF}_i^1, \text{RBF}_i^2)$ 在 $X_{\lambda_i}^*$ 附近的预测精度,进而间接改善算法的局部开发能力.

情况2: $\text{dom}(\text{NB}_i(t), \text{NB}_i(t-1)) \leq \text{dom}(\text{NB}_i(t-1), \text{NB}_i(t))$,这意味着最近2次迭代中 $X_{\lambda_i}^*$ 的邻域个体未发生变化,此时,同时选择 $\text{NB}_i(t)$ 内不确定程度最大的个体和 $g^{\text{tche}}(X|\lambda_i, Z^*)$ 值最小的个体进行真实评估.选择不确定程度最大的个体作为填充样本,可同时改善多个基础代理模型的预测精度,进而间接改善算法的探索能力.值得注意的是,只有当一个权重向量上的最优解连续 T' 代不变时,才会更新该权重向量所对应的基础代理模型对.对于个体 X ,其不确定程度为

$$u(X) = \frac{1}{M} \sum_{i=1}^M \sum_{j=1}^{\tau+1} \sqrt{\frac{(\hat{f}_i^j(X) - \bar{f}_i(X))^2}{\tau+1}}. \quad (2)$$

其中: M 为目标个数, $\hat{f}_i^j(X)$ 为个体 X 的代理模型评估值, τ 为该个体的邻域大小, $\bar{f}_i(X)$ 为解 X 在第 i 个目标上的平均近似值.

算法1 填充样本生成方法的伪代码.

输入: 样本集合Tdata,需要更新的一对基础代理模型 $(\text{RBF}_i^1, \text{RBF}_i^2)$,最优解 $X_{\lambda_i}^*$;

输出: 更新后的样本集合Tdata.

1. 分别从当前种群和上代种群中确定 $X_{\lambda_i}^*$ 的邻域,记为 $\text{NB}_i(t)$ 和 $\text{NB}_i(t-1)$.

2. 计算 $\text{dom}(\text{NB}_i(t), \text{NB}_i(t-1))$ 和 $\text{dom}(\text{NB}_i(t-1), \text{NB}_i(t))$ 值.

3. if $\text{dom}(\text{NB}_i(t), \text{NB}_i(t-1)) > \text{dom}(\text{NB}_i(t-1), \text{NB}_i(t))$.

4. 将 $X_{\lambda_i}^*$ 代入EnergyPlus,计算 $(\text{BEC}(X_{\lambda_i}^*), \text{UDE}(X_{\lambda_i}^*))$.

5. 将样本 $(X_{\lambda_i}^*, \text{BEC}(X_{\lambda_i}^*), \text{UDE}(X_{\lambda_i}^*))$ 存入Tdata.

6. else.

7. 由式(2)计算 $\text{NB}_i(t)$ 中所有个体的不确定程度,选出不确定程度最大的个体 $X_{\lambda_i}^u$.

8. 将 $X_{\lambda_i}^u$ 代入EnergyPlus,计算 $(\text{BEC}(X_{\lambda_i}^u), \text{UDE}(X_{\lambda_i}^u))$.

9. 将 $X_{\lambda_i}^*$ 代入EnergyPlus,计算 $(\text{BEC}(X_{\lambda_i}^*), \text{UDE}(X_{\lambda_i}^*))$.

10. 将样本 $(X_{\lambda_i}^*, \text{BEC}(X_{\lambda_i}^*), \text{UDE}(X_{\lambda_i}^*))$ 和 $(X_{\lambda_i}^u, \text{BEC}(X_{\lambda_i}^u), \text{UDE}(X_{\lambda_i}^u))$ 存入Tdata.

11. end.

2.3 基于相邻代理聚合的个体评价

基于构建的 N 对基础代理模型, 提出一种基于相邻代理聚合的个体评价机制 (SA-IEM), 用于预测种群中个体的目标函数值. 以待评价个体 X_i 为例, 具体方法如下: 首先, 确定该个体所对应的参考权重向量 λ_i 及其 τ 个邻域权重向量, 不妨统一记为 $\{\lambda_i^1, \lambda_i^2, \dots, \lambda_i^\tau\}$. 为便于描述, 令 $\lambda_i^0 = \lambda_i$, 则可将 $\tau + 1$ 个参考权重向量统一表述为 $\{\lambda_i^0, \lambda_i^1, \dots, \lambda_i^\tau\}$; 然后, 从基础代理模型库中确定上述 $\tau + 1$ 个参考权重向量对应的 $\tau + 1$ 对基础代理模型, 不妨记为 $\{\text{SM}_{\lambda_i^0}, \text{SM}_{\lambda_i^1}, \dots, \text{SM}_{\lambda_i^\tau}\}$; 接着, 利用这 $\tau + 1$ 对基础代理模型分别评估当前个体的目标值, 不妨记评估结果为 $\hat{f}_m(X_i | \text{SM}_{\lambda_i^j}), j = 0, 1, \dots, \tau, m = 1, 2, \dots, M$; 最后, 针对每个目标函数, 采用式(3)聚合 $\tau + 1$ 个评估结果, 得到 X_i 的最终目标值为

$$\hat{f}_m(X_i) = \sum_{j=0}^{\tau} \omega_j \times \hat{f}_m(X_i | \text{SM}_{\lambda_i^j}), \quad (3)$$

其中 ω_j 为 $\text{SM}_{\lambda_i^j}$ 的权重. 当一个解的某维分量值超过其上下界时, 取其对应的上下限制. 进一步地, 算法2为所提出个体评估机制的伪代码.

算法2 基于相邻代理聚合的个体评价.

输入: 个体 X , 参考权重向量 λ , 基础代理模型;

输出: 代理模型预测的每个粒子的目标值.

1. for 种群中每一个个体 X_i .
2. 确定该个体所对应的参考权重向量 λ_i 及其 τ 个邻域权重向量, 记为 $\{\lambda_i^1, \lambda_i^2, \dots, \lambda_i^\tau\}$.
3. 确定上述 $\tau + 1$ 个参考权重向量对应的 $\tau + 1$ 对基础代理模型, 记为 $\{\text{SM}_{\lambda_i^0}, \text{SM}_{\lambda_i^1}, \dots, \text{SM}_{\lambda_i^\tau}\}$.
4. 分别计算该权重向量距离 τ 个邻域权重向量的距离.
5. 根据式(4)计算每对基础代理模型所占权重 ω_j .
6. 由式(3)集成代理模型, 预测每个粒子的目标值 $\hat{f}_m(X_i)$.
7. end.

式(3)中: 权重 ω_j 决定了个体评估值的精确程度. 鉴于在 MOEA/D 中个体 X_i 主要偏重于求解参考权重向量 λ_i 确定的子优化问题, 设置代理模型对 $\text{SM}_{\lambda_i^0}$ 所预测目标函数值的权重 $\omega_0 = 0.5$. 对于其余 τ 对代理模型, 由它们对应的权重向量 $\{\lambda_i^1, \lambda_i^2, \dots, \lambda_i^\tau\}$ 与 λ_i^0 间的距离确定其权重, 如下式所示:

$$\omega_j = 0.5 \frac{|\lambda_i^0 - \lambda_i^j|^{-1}}{\sum_{q=1}^{\tau} |\lambda_i^0 - \lambda_i^q|^{-1}}, \quad (4)$$

其中 $|\lambda_i^0 - \lambda_i^j|^{-1}$ 为 λ_i^0 与 λ_i^j 间距离的倒数. 可见, λ_i^0

与 λ_i^j 距离越近, $\text{SM}_{\lambda_i^j}$ 所预测目标函数值的权重越大. $\text{SM}_{\lambda_i^j}$ 与 $\text{SM}_{\lambda_i^0}$ 所代理的子优化问题越相似, $\text{SM}_{\lambda_i^j}$ 所预测目标函数值的权重越大.

2.4 参考点的更新

不同于传统数值优化问题, 文中种群个体具有 2 种目标函数值, 即真实目标值和预测目标值. 鉴于此, 参考 2 种目标函数值来确定参考点. 假设第 t 次迭代时样本集 Tdata 中保存的 M 个目标函数的最小值为 $f_m^{\min} (m = 1, 2, \dots, M)$, 代理模型评价过的解集中保存的 M 个目标函数的最小值为 $\hat{f}_m^{\min} (m = 1, 2, \dots, M)$, 则新的参考点为

$$z_m^* = \begin{cases} f_m^{\min}, & f_m^{\min} < \hat{f}_m^{\min}; \\ \frac{t}{T_{\max}} \times f_m^{\min} + \left(1 - \frac{t}{T_{\max}}\right) \times \hat{f}_m^{\min}, & \text{otherwise.} \end{cases} \quad (5)$$

当真实最小值 f_m^{\min} 小于预测最小值 \hat{f}_m^{\min} 时, 选择 f_m^{\min} 作为参考点可扩大种群的搜索范围, 进而获得延展性更好的真实 Pareto 前端. 当 \hat{f}_m^{\min} 小于 f_m^{\min} 时, 存在如下可能的情况: 由于代理模型的精度较低, \hat{f}_m^{\min} 值可能明显小于被优化问题的真正最小值. 此时, 直接选择 \hat{f}_m^{\min} 作为新的参考点, 极有可能引导部分个体不断搜索未包含任何非劣解的无效目标区域. 如图2所示, 灰色曲线为真实 Pareto 前沿, 左下角灰色和黑色圆点分别为由 f_m^{\min} 和代理模型确定的参考点, 曲线上方灰色圆点为种群中的 10 个个体. 由图2可见, 若选择代理模型确定的黑色圆点作为参考点, 则种群中的 2 个边界个体将会一直搜索灰色阴影部分中的最优解, 而该阴影部分却为无效目标区域, 进而降低种群的搜索效率. 为此, 式(5)采用 \hat{f}_m^{\min} 与 f_m^{\min} 的加权折中值作为新的参考点. 在算法运行前期为预测最小值设置较大的比重, 在发挥代理模型作用的同时可减少其不精确性带来的误差; 随着迭代次数的增加, 逐渐




图2 参考点选择的有效性分析

增大式(5)中真实最小值 f_m^{\min} 的比重, 以确保结果更加准确.

3 应用案例

3.1 案例描述

实验以中国北京地区的一类居民建筑 and 一类办公室建筑设计为例, 验证所提出算法的有效性. 图3为居民建筑和办公建筑的基础外形, 其总面积分别为 110 m^2 和 31.68 m^2 .

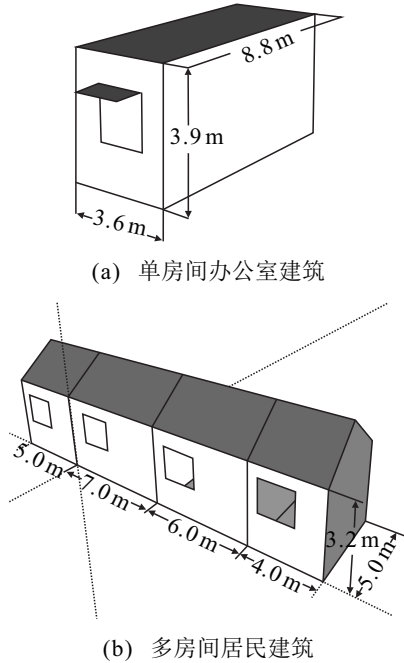


图3 所用2个建筑实例的外形图

参考 EnergyPlus 软件手册和建筑节能设计标准^[36] 的建议, 设置它们的回风量系数为0, 辐射系数为0.37, 可见光系数为0.18, 光的热量传输到区域空气中的系数 $f_{\text{convected}}$ 为0.40.

3.2 对比算法和性能指标

选择5种典型的多目标进化算法和2种典型的代理辅助多目标进化算法作为对比算法, 分别为

表1 各算法的参数设置

算法	参数设置
MS-MOEA/D	样本数目为25, $T'=2$, 聚合数目 $\tau=3$, 真实评价次数 NFE = 600
NSGA-II	交叉比0.7, 变异比0.4, 突变率0.02, 耐受性0.001
MOPSO	加速度系数 $c_1=c_2=2$, 惯性权重为0.5, 储备集规模为50
MOABC	每个食物源的最大搜索次数为5
BBMOPSO-A	储备集规模50
MOEA/D	邻居规模20
ParEGO	真实评价次数为600
CSEA	真实评价次数为600

NSGA-II^[17], MOABC^[18], MOPSO^[19], MOEA/D^[32], 基于自适应扰动因子的改进骨干多目标粒子群优化算法 (BBMOPSO-A)^[37], ParEGO^[30] 和基于分类的代理辅助进化算法 (CSEA)^[38]. 为公平比较, 这些对比算法的种群规模和最大迭代次数皆设置为20和50, 所有算法均运行20次. 这些算法的其他参数, 皆采用原始文献的建议值. 表1为这些算法的具体参数设置. 采用超体积 (HV)^[39] 评价算法的性能, 该测度可同时评价1组最优解的分布性和收敛性.

特别地, 本文也详细分析了样本数目、聚合数目、基础模型数目等关键参数, 以及个体评价和代理模型构建等算子对算法性能的影响.

3.3 对比分析

3.3.1 与经典多目标进化算法进行对比

本节将所提出 MS-MOEA/D 算法与5种典型多目标进化算法进行比较. 使用显著性水平为0.05的 t -test 检验判断不同算法的显著差异性, 其中: “R+” 表示 MS-MOEA/D 的性能显著优于某一对比算法, “=” 表示2个算法性能相当, “-” 表示计算无意义.

表2和表3分别为 MS-MOEA/D 与5种对比算法

表2 MS-MOEA/D与5种多目标进化算法得到的HV值

	算法	best	worst	average	std	t-test
单房间	MS-MOEA/D	72 796.5	20 447.5	32 416.1	18 696.7	-
	MOEA/D	32 840	15 898.2	19 691.1	7 372.8	R+
	MOABC	27 958.3	18 326.3	26 031.9	4 307.5	=
	MOPSO	33 138.4	18 959.7	24 766.6	6 153.6	R+
	NSGA-II	16 724.6	5 184.8	12 743.3	5 565.9	R+
	BBMOPSO-A	27 978.4	24 414.9	26 074	1 355.7	=
多房间	MS-MOEA/D	10 982.2	5 708.9	7 899.1	2 115.1	-
	MOEA/D	6 704.6	3 857.1	5 348.6	1 029.2	R+
	MOABC	7 938.1	5 274.9	6 937.5	1 086.1	=
	MOPSO	9 533.5	5 094.2	7 015.4	1 717.7	=
	NSGA-II	5 460.4	4 746.6	5 032.1	390.9	R+
	BBMOPSO-A	9 796.3	4 980.6	7 828.5	2 013.2	=

表3 MS-MOEA/D与5种经典多目标进化算法的运行时间

	算法	best	worst	average	std	单位: s
单房间	MS-MOEA/D	1 666.33	2 203.68	1 774.58	194.3	
	MOEA/D	2 994.93	3 270.98	3 114.65	112.43	
	MOABC	3 043.71	3 908.09	3 425.23	344.82	
	MOPSO	3 099.52	3 868.59	3 415.31	353.93	
	NSGA-II	3 673.4	4 275.58	3 940.45	239.66	
	BBMOPSO-A	3 086.96	4 854.85	3 685.67	711.98	
多房间	MS-MOEA/D	3 485.2	3 784.15	3 616.96	138.57	
	MOEA/D	5 797.87	6 319.09	6 105.44	224.79	
	MOABC	6 039.18	6 825.56	6 471.28	339.74	
	MOPSO	6 422.66	7 191.59	6 735.34	295.77	
	NSGA-II	6 250.54	6 963.35	6 542.55	298.08	
	BBMOPSO-A	6 162.75	6 833.19	6 473.06	294.51	

得到的HV值和运行时间. 可以看出: 1) 在单房间办公室案例中, MS-MOEA/D获得了最高的平均HV值, 且其值比MOEA/D、MOPSO与NSGA-II分别高出12 725.7 649.5和19 672.8; 2) 得益于代理模型的辅助, MS-MOEA/D的运行时间得到了大大缩短, 其平均时间为1 774.58 s, 其余5种算法的平均时间为3 516.26 s; 3) 在多房间案例中, MS-MOEA/D获得了最高的平均HV值, 为7 899.1, 且其值高出MOEA/D约47.6%, 高出NSGA-II约56.1%. 从时间方面而言, MS-MOEA/D算法的平均运行时间为3 616.96 s, 其余5种算法的平均时间为6 465.53 s.

3.3.2 与代理辅助多目标进化算法进行对比

本节将所提出MS-MOEA/D算法与ParEGO和CSEA进行比较. 表4和表5分别为3种算法得到的HV值和运行时间. 由表4和表5可见: 1) 在单房间办公室案例中, MS-MOEA/D获得了最佳的平均HV值, 为32 416.1, 其值比ParEGO与CSEA的平均HV值(25 850.7和21 434.6)分别提高了25.40%、51.23%; MS-MOEA/D的平均运行时间为1 774.58 s, 也明显快于ParEGO与CSEA. 2) 在多房间居民建筑案例中, MS-MOEA/D与ParEGO的平均运行时间相差很小, 且均明显快于CSEA算法; 但是, MS-MOEA/D得到的平均HV值为7 899.1, 要优于ParEGO与CSEA. 总体而言, 与ParEGO、CSEA相比, 在解决昂贵多目标优

化问题方面MS-MOEA/D极具竞争力.

表4 MS-MOEA/D与2种代理辅助进化算法得到的HV值

算法		best	worst	average	std	t-test
单房间	MS-MOEA/D	72 796.5	20 447.5	32 416.1	18 696.7	-
	ParEGO	32 336.2	21 225.1	25 850.7	4 908.4	=
	CSEA	26 570.7	18 021.6	21 434.6	3 934.7	R+
多房间	MS-MOEA/D	10 982.2	5 708.9	7 899.1	2 115.1	-
	ParEGO	8 576.9	4 990.6	6 895.2	1 990.1	=
	CSEA	9 267.1	4 268.9	6 490	1 986.8	=

表5 MS-MOEA/D与2种代理辅助进化算法的运行时间 单位: s

算法		best	worst	average	std
单房间	MS-MOEA/D	1 666.33	2203.68	1 774.58	194.3
	ParEGO	2 477.83	2 742.81	2 578.12	110.75
	CSEA	1 833.07	2 022.66	1 883.47	90.63
多房间	MS-MOEA/D	3 485.2	3 784.15	3 616.96	138.57
	ParEGO	3 417.29	3 941.69	3 614.04	240.43
	CSEA	4 605.26	5 054.95	4 702.28	480.56

进一步地, 对比MS-MOEA/D、ParEGO与CSEA得到的2个目标函数的最小值. 针对单房间建筑和多房间建筑, 表6和表7分别为MS-MOEA/D与2种对比算法得到的结果. 由表6和表7可见, 针对2个优化目标, 在两类建筑上MS-MOEA/D均获得了排名第2的结果. 然而, 如前所述, MS-MOEA/D所得Pareto解集的整体性能要优于ParEGO与CSEA.

表6 单房间办公室建筑中不同算法针对2个目标得到的最小值

算法	目标1/(MJ/m ²)				目标2/h			
	最佳	平均	方差	排名	最佳	平均	方差	排名
MS-MOEA/D	5.02	5.25	0.18	2	39.93	55.13	23.61	2
ParEGO	5.17	5.29	0.12	3	40.5	55.21	13.46	3
CSEA	4.96	5.06	0.14	1	36.25	53.5	26.49	1

表7 多房间居民建筑中不同算法针对2个目标得到的最小值

算法	目标1/(MJ/m ²)				目标2/h			
	最佳	平均	方差	排名	最佳	平均	方差	排名
MS-MOEA/D	45.84	46.62	0.73	2	2 640.25	2 873.5	163.89	2
ParEGO	46.35	46.91	0.44	3	2 928.5	2 974.2	27.15	3
CSEA	45.26	46.18	0.67	1	2 598	2 724.8	122.28	1

4 结论

针对建筑节能设计问题, 提出一种多代理模型辅助的MOEA/D优化方法, 即MS-MOEA/D. 通过引入基于目标分解的多代理模型构建和管理机制、基于相邻代理聚合的个体评价机制、融合预测结果的参考点更新方式等策略, 显著提高了算法的性能. 实验结果表明, MS-MOEA/D能够以较小的计算代价获得高

质量的Pareto最优解集.

参考文献(References)

- [1] Esmaeilzadeh A, Zakerzadeh M R, Koma A Y. The comparison of some advanced control methods for energy optimization and comfort management in buildings[J]. Sustainable Cities and Society, 2018, 43: 601-623.
- [2] Longo S, Montana F, Riva S E. A review on optimization

- and cost-optimal methodologies in low-energy buildings design and environmental considerations[J]. *Sustainable Cities and Society*, 2019, 45: 87-104.
- [3] He Y D, Li N P, He M L, et al. Using radiant cooling desk for maintaining comfort in hot environment[J]. *Energy and Buildings*, 2017, 145: 144-154.
- [4] Imanari T, Omori T, Bogaki K. Thermal comfort and energy consumption of the radiant ceiling panel system: Comparison with the conventional all-air system[J]. *Energy and Buildings*, 1999, 30(2): 167-175.
- [5] Ilbeigi M, Ghomeshi M, Dehghanbanadaki A. Prediction and optimization of energy consumption in an office building using artificial neural network and a genetic algorithm[J]. *Sustainable Cities and Society*, 2020, 61: 102325.
- [6] Nguyen A T, Reiter S, Rigo P. A review on simulation-based optimization methods applied to building performance analysis[J]. *Applied Energy*, 2014, 113(6): 1043-1058.
- [7] Wang W M, Rivard H, Zmeureanu R. An object-oriented framework for simulation-based green building design optimization with genetic algorithms[J]. *Advanced Engineering Informatics*, 2005, 19(1): 5-23.
- [8] Ge F H, Guo X L, Liu H K, et al. Energy performance of air cooling systems considering indoor temperature and relative humidity in different climate zones in China[J]. *Energy and Buildings*, 2013, 64(5): 145-153.
- [9] Castro-Lacouture D, Sefair J A, Flórez L, et al. Optimization model for the selection of materials using a LEED-based green building rating system in Colombia[J]. *Building and Environment*, 2009, 44(6): 1162-1170.
- [10] 王闯, 韩非, 申雨轩, 等. 基于事件触发的全信息粒子群优化器及其应用[J]. *自动化学报*, DOI: 10.16383/j.aas.c200621.
(Wang C, Han F, Shen Y X, et al. Full-information particle swarm optimizer based on event-triggering strategy and its applications[J]. *Acta Automatica Sinica*, DOI: 10.16383/j.aas.c200621.)
- [11] 马永杰, 陈敏, 龚影, 等. 动态多目标优化进化算法研究进展[J]. *自动化学报*, 2020, 46(11): 2302-2318.
(Ma Y J, Chen M, Gong Y, et al. Research progress of dynamic multi-objective optimization evolutionary algorithm[J]. *Acta Automatica Sinica*, 2020, 46(11): 2302-2318.)
- [12] 韩红桂, 张璐, 卢薇, 等. 城市污水处理过程动态多目标智能优化控制研究[J]. *自动化学报*, 2021, 47(3): 620-629.
(Han H G, Zhang L, Lu W, et al. Research on dynamic multiobjective intelligent optimal control for municipal wastewater treatment process[J]. *Acta Automatica Sinica*, 2021, 47(3): 620-629.)
- [13] Junghans L, Darde N. Hybrid single objective genetic algorithm coupled with the simulated annealing optimization method for building optimization[J]. *Energy and Buildings*, 2015, 86: 651-662.
- [14] Bamdad K, Cholette M E, Guan L S, et al. Ant colony algorithm for building energy optimisation problems and comparison with benchmark algorithms[J]. *Energy and Buildings*, 2017, 154: 404-414.
- [15] 公茂果, 焦李成, 杨咚咚, 等. 进化多目标优化算法研究[J]. *软件学报*, 2009, 20(2): 271-289.
(Gong M G, Jiao L C, Yang D D, et al. Research on evolutionary multi-objective optimization algorithms[J]. *Journal of Software*, 2009, 20(2): 271-289.)
- [16] 王峰, 张衡, 韩孟臣, 等. 基于协同进化的混合变量多目标粒子群优化算法求解无人机协同多任务分配问题[J]. *计算机学报*, 2021, 44(10): 1967-1983.
(Wang F, Zhang H, Han M C, et al. Co-evolution based mixed-variable multi-objective particle swarm optimization for UAV cooperative multi-task allocation problem[J]. *Chinese Journal of Computers*, 2021, 44(10): 1967-1983.)
- [17] Delgarm N, Sajadi B, Delgarm S, et al. A novel approach for the simulation-based optimization of the buildings energy consumption using NSGA-II: Case study in Iran[J]. *Energy and Buildings*, 2016, 127: 552-560.
- [18] Delgarm N, Sajadi B, Delgarm S. Multi-objective optimization of building energy performance and indoor thermal comfort: A new method using artificial bee colony[J]. *Energy and Buildings*, 2016, 131: 42-53.
- [19] Delgarm N, Sajadi B, Kowsary F, et al. Multi-objective optimization of the building energy performance: A simulation-based approach by means of particle swarm optimization[J]. *Applied Energy*, 2016, 170: 293-303.
- [20] Zhang Y, Yuan L J, Cheng S. Building energy performance optimization: A new multi-objective particle swarm method[J]. *Lecture Notes in Computer Science*, 2019, 11655: 139-1471.
- [21] Grefenstette J J, Fitzpatrick J M. Genetic search with approximate function evaluation[C]. *Proceedings of the 1st International Conference on Genetic Algorithms*. Pittsburgh, 1985: 112-120.
- [22] Tong H, Huang C W, Liu J L, et al. Voronoi-based efficient surrogate-assisted evolutionary algorithm for very expensive problems[C]. *IEEE Congress on Evolutionary Computation*. Wellington, 2019: 1996-2003.
- [23] Sun C L, Jin Y C, Cheng R, et al. Surrogate-assisted cooperative swarm optimization of high-dimensional

- expensive problems[J]. IEEE Transactions on Evolutionary Computation, 2017, 21(4): 644-660.
- [24] Wang H D, Jin Y C, Doherty J. Committee-based active learning for surrogate-assisted particle swarm optimization of expensive problems[J]. IEEE Transactions on Cybernetics, 2017, 47(9): 2664-2677.
- [25] Magnier L, Haghghat F. Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and artificial neural network[J]. Building and Environment, 2010, 45(3): 739-746.
- [26] Chen L, Fang Q S, Zhang Z Y. Research on the identification of temperature in intelligent building based on feed forward neural network and particle swarm optimization algorithm[C]. The 6th International Conference on Natural Computation. Yantai, 2010: 1816-1820.
- [27] Ji X F, Zhang Y, Gong D W, et al. Dual-surrogate-assisted cooperative particle swarm optimization for expensive multimodal problems[J]. IEEE Transactions on Evolutionary Computation, 2021, 25(4): 794-808.
- [28] Khan M A I, Noakes C J, Toropov V V. Multi-objective optimization of the ventilation system design in a two-bed ward with an emphasis on infection control[C]. Proceedings of the Building Simulation and Optimization Conference. Loughborough, 2012: 9-18.
- [29] Gengembre E, Ladevie B, Fudym O, et al. A Kriging constrained efficient global optimization approach applied to low-energy building design problems[J]. Inverse Problems in Science and Engineering, 2012, 20(7): 1101-1114.
- [30] Knowles J. ParEGO: A hybrid algorithm with on-line landscape approximation for expensive multiobjective optimization problems[J]. IEEE Transactions on Evolutionary Computation, 2006, 10(1): 50-66.
- [31] Crawley D B, Pedersen C O, Lawrie L K, et al. EnergyPlus: Energy simulation program[J]. Ashrae Journal, 2000, 42(4): 49-56.
- [32] 张勇, 梁晓珂, 袁丽娟. 面向节能的建筑设计多目标优化方法[J]. 华中科技大学学报: 自然科学版, 2021, 49(7): 107-112.
(Zhang Y, Liang X K, Yuan L J. Multi-objective optimization algorithm for building energy-saving design[J]. Journal of Huazhong University of Science and Technology: Natural Science Edition, 2021, 49(7): 107-112.)
- [33] Zhang Q F, Li H. MOEA/D: A multiobjective evolutionary algorithm based on decomposition[J]. IEEE Transactions on Evolutionary Computation, 2007, 11(6): 712-731.
- [34] Garud S S, Karimi I A, Kraft M. Design of computer experiments: A review[J]. Computers and Chemical Engineering, 2017, 106: 71-95.
- [35] 郑金华, 罗彪. 一种基于拉丁超立方体抽样的多目标进化算法[J]. 模式识别与人工智能, 2009, 22(2): 223-233.
(Zheng J H, Luo B. A Latin hypercube sampling based multi-objective evolutionary algorithm[J]. Pattern Recognition and Artificial Intelligence, 2009, 22(2): 223-233.)
- [36] 中华人民共和国住房和城乡建设部. 严寒和寒冷地区居住建筑节能设计标准[M]. 北京: 中国建筑工业出版社, 2018: 19-27.
(Ministry of Housing and Urban-Rural Development, PRC. Design standards for energy efficiency of residential buildings in cold and cold regions[M]. Beijing: China Architecture and Building Press, 2018: 19-27.)
- [37] Zhang Y, Yuan L J, Zhang Q, et al. Multi-objective optimization of building energy performance using a particle swarm optimizer with less control parameters[J]. Journal of Building Engineering, 2020, 32: 101505.
- [38] Pan L Q, He C, Tian Y, et al. A classification-based surrogate-assisted evolutionary algorithm for expensive many-objective optimization[J]. IEEE Transactions on Evolutionary Computation, 2019, 23(1): 74-88.
- [39] Zitzler E, Thiele L. Multiobjective evolutionary algorithms: A comparative case study and the strength Pareto approach[J]. IEEE Transactions on Evolutionary Computation, 1999, 3(4): 257-271.

作者简介

张勇(1979—), 男, 教授, 博士生导师, 从事智能优化、数据驱动等研究, E-mail: yongzh401@126.com;

梁晓珂(1998—), 女, 硕士生, 从事建筑节能优化的研究, E-mail: liangxiaoke@cumt.edu.cn;

陈志鹏(1999—), 男, 硕士生, 从事进化优化理论及应用的研究, E-mail: 1349518053@qq.com;

巩敦卫(1970—), 男, 教授, 博士生导师, 从事进化计算、智能优化和基于搜索的软件工程等研究, E-mail: dwgong@vip.163.com.