

改进克里金模型辅助的双档案在线数据驱动进化算法

高娜

河北地质大学信息工程学院, 河北 石家庄

收稿日期: 2022年8月19日; 录用日期: 2022年9月16日; 发布日期: 2022年9月26日

摘要

在现实世界中, 许多进化优化问题难以找到合适的评估函数或评估代价十分昂贵, 这在进化优化算法求解现实中的优化问题时提出诸多挑战。近年来, 为了解决进化优化算法评估代价昂贵的问题, 数据驱动的进化优化应运而生。数据驱动的进化优化的基本思想, 就是通过充分利用数据的作用, 训练代理模型辅助进化优化过程。一般是将代理模型用于近似真实昂贵函数评估, 实现廉价的评估过程, 提升算法性能。根据KTA2算法, 本文提出了一种改进克里金模型辅助的双档案在线数据驱动进化算法KTA2_addModel4。在KTA2算法中, 由训练的三种克里金模型作为代理模型: 全部数据集训练的敏感模型、无较大影响点训练的不敏感模型1和无较小影响点训练的不敏感模型2。在改进的算法KTA2_addModel4中, 增加了一种同时去掉较小影响点和较大影响点训练的不敏感模型3。通过在测试函数上与KTA2算法和其他代理辅助的数据驱动进化算法对比, 证明提出的KTA2_addModel4算法改进了代理模型的质量, 提升了算法的性能。

关键词

在线数据驱动, 进化算法, 克里金模型, 双档案

Improved Kriging Model-Assisted Two-Archive Online Data-Driven Evolutionary Algorithm

Na Gao

College of Information Engineering, Hebei GEO University, Shijiazhuang Hebei

Received: Aug. 19th, 2022; accepted: Sep. 16th, 2022; published: Sep. 26th, 2022

Abstract

In the real world, many evolutionary optimization problems are difficult to find a suitable evaluation function or the evaluation cost is very expensive, which poses many challenges for evolutionary optimization algorithm to solve real optimization problems. In recent years, in order to solve the problem of expensive evaluation of evolutionary optimization algorithms, data-driven evolutionary optimization came into being. The basic idea of data-driven evolutionary optimization is to train the agent model to assist the evolutionary optimization process by making full use of the role of data. Generally, the agent model is used to approximate real expensive function evaluation, so as to realize the cheap evaluation process and improve the performance of the algorithm. According to the KTA2 algorithm, this paper proposes an improved Kriging Model-assisted two-archive online data-driven evolutionary algorithm KTA2_addModel4. In the KTA2 algorithm, three Kriging models are trained as surrogate models: the sensitive model trained by all data sets, the insensitive model 1 trained without large influence points and the insensitive model 2 trained without small influence points. In the improved algorithm KTA2_addmodel4, an insensitivity model 3 is added to remove both the small influence points and the large influence points. By comparing with KTA2 algorithm and other surrogate-assisted data-driven evolutionary algorithms in the test function, it is proved that the proposed KTA2_addmodel4 algorithm improves the quality of the surrogate model and the performance of the algorithm.

Keywords

Online Data-Driven, Evolutionary Algorithm, Kriging Model, Two-Archive

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在过去的几十年里, 进化算法已经成为一种流行的优化工具。许多已有的进化算法都假设对候选解的评估代价是廉价的, 然而, 在现实世界中, 许多优化问题很难找到合适的评估函数或评估代价十分昂贵。比如, 基于大量数据的创伤系统的一次函数评估需要处理 40,000 条事件记录[1]。为了降低进化算法中函数评估阶段的昂贵代价, 研究者进行了许多探索, 数据驱动的进化优化便是研究出的一种非常有效的解决方法。数据驱动的进化优化通过收集现实生活或者仿真实验的数据训练代理模型, 然后使用代理模型近似代替全部或部分函数评估, 从而大大减少真实昂贵函数评估的代价。在数据驱动的进化算法中已使用的代理模型有多项式回归[2]、克里金模型[3]、人工神经网络[4]和径向基函数[5]等。根据优化过程中是否可以使用新生成的数据, 将数据驱动的进化优化分为离线数据驱动的进化优化和在线数据驱动的进化优化。目前, 已经有许多研究者提出一些数据驱动的进化算法, 比如 TT-DDEA [6]、SRK-DDEA [7]、KRVEA [3]、CSEA [8]等。数据驱动是随着人工智能、机器学习兴起的一门技术, 近几年也有其他学者对数据驱动的优化算法作出研究进展, 比如 F Yu 等[9]提出了一种针对昂贵优化问题的基于多进化采样策略的数据驱动进化算法, Ashley M. Hou 等[10]提出了一种机会约束优化的数据驱动调整算法: 概率性能保证的两个步骤, Q Gu 等[11]提出了一种基于双档案的数据驱动混合整数优化改进辅助进化算法。本文基于一种在线数据驱动的进化算法 KTA2 [12]作出改进, 提出了一种改进克里金模型辅助的双档案在线

数据驱动进化算法 KTA2_addModel4。

2. KTA2 算法

KTA2 算法[12]是根据数据驱动进化算法的一般框架,选择克里金模型[3]训练代理模型,并结合双档案算法设计的在线数据驱动进化算法。

2.1. 代理模型的训练

在 KTA2 算法中,为了提升代理模型的质量,重点研究对模型质量影响较大的数据。在[12]中,考虑目标值较大或较小的影响点,通过设置参数控制影响点的数量,然后分别训练包含所有影响点和去除目标值较大的影响点以及去除目标值较小的影响点的模型。如图 1 所示,图 1(a)图是由全部数据训练得到敏感模型,图 1(b)图是由去除目标值较大的影响点后的数据集训练得到不敏感模型 1,图 1(c)图是由去除较小影响点后的数据集训练得到不敏感模型 2。

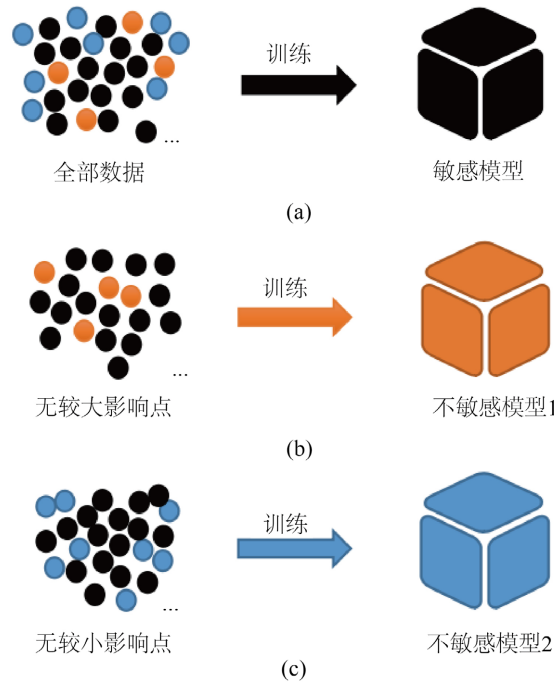


Figure 1. KTA2 algorithm model

图 1. KTA2 算法模型

2.2. 代理模型的使用

在 KTA2 算法中,一共训练了三种模型用作代理模型:所有数据集训练得到的敏感模型;按比例去掉部分最大目标值的数据集 1 训练得到的不敏感模型 1;按比例去掉部分最小目标值的数据集 2 训练得到的不敏感模型 2。在使用代理模型近似真实昂贵函数评估,即进行预测时,首先由敏感模型预测得到预测值 y_s^i ,然后比较 y_s^i 与数据集 1 目标值均值 λ 的差值 $|y_s^i - \lambda|$ 、 y_s^i 与数据集 2 目标值均值 μ 的差值 $|y_s^i - \mu|$ 的大小,选择由不敏感模型 1 或者不敏感模型 2 得到最终预测值,如图 2 所示。

2.3. 代理模型的更新

在 KTA2 算法中,代理模型的更新是根据收敛性、多样性指标完成采样的。通过判断此时是收敛性

需要阶段、多样性需要阶段或不确定性需要阶段，分别采用收敛性采样策略选择收敛性好的解提升种群的质量，采用多样性采样策略选择多样性好的解使种群更均匀地分布在 Pareto 前沿面上，采用不确定性采样策略选择不确定性解提升代理模型的全局精确度，详见[12]。

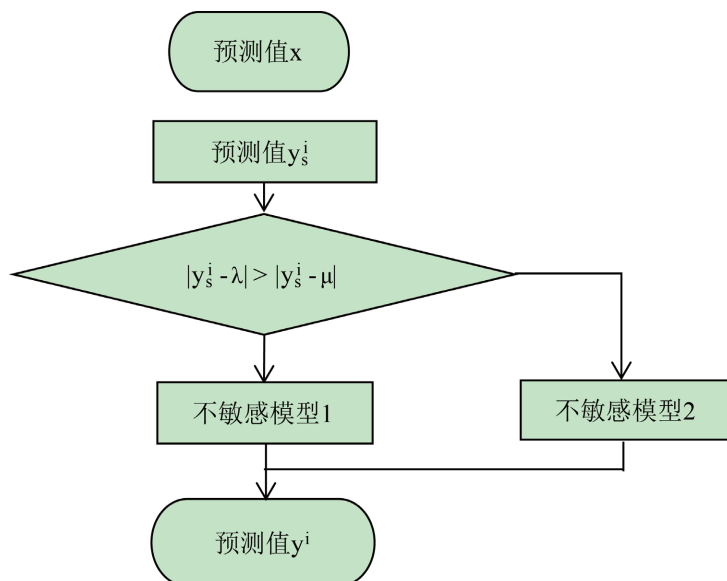


Figure 2. Model usage of KTA2 algorithm
图 2. KTA2 算法的模型使用

3. 改进的 KTA2 算法——KTA2_addModel4 算法

本文基于 Song [12]等人提出的 KTA2 算法，对代理模型的训练作出改进，针对每个目标，由原来的三种模型近似真实函数评估改进为四种模型近似真实函数评估，提出了改进的 KTA2 算法——KTA2_addModel4 算法，KTA2 算法与 KTA2_addModel4 算法都是求解评估代价昂贵的多目标优化问题的在线数据驱动进化算法。

图 3 是 KTA2_addModel4 算法框架。与 KTA2 算法相同，KTA2_addModel4 算法依然使用双档案保持种群的收敛性和多样性。其中，CA 代表收敛性档案，DA 代表多样性档案。与 KTA2 算法针对每个目标训练三种克里金模型[3]作为代理模型不同，KTA2_addModel4 算法针对每个目标训练了四种克里金模型作为代理模型：由全部个体训练的敏感模型、去掉较大影响点训练的不敏感模型 1、去掉较小影响点训练的不敏感模型 2、同时去掉较小与较大影响点训练的不敏感模型 3。由代理模型近似真实函数评估，得到适应度值。在管理代理模型时，与 KTA2 算法相同，通过自适应采样策略更新训练集，实现代理模型的更新。

3.1. 改进的代理模型

在原来 KTA2 算法中，代理模型包括由全部数据训练得到的敏感模型、去掉部分较大目标值的数据集训练得到的不敏感模型 1 和去掉部分较小目标值的数据集训练得到的不敏感模型 2。在本文中，所有去掉的个体都称为影响点。将除去的目标值较大的个体称为较大影响点，将除去的目标值较小的个体称为较小影响点。在 KTA2 算法中，之所以训练去掉这些影响点后的模型，是考虑到这些影响点对代理模型质量的影响。因为在 KTA2 算法中，代理模型的作用是近似真实昂贵函数评估，所以在使用代理模型预测适应度值时，通常会有一定的近似误差。而这些影响点的存在，可能会降低代理模型的质量，产生

较大的近似误差。

在改进的 KTA2 算法——KTA2_addModel4 算法中，对代理模型作出改进，增加了第四种模型——同时去掉部分较大目标值和部分较小目标值的数据集训练得到的不敏感模型 3。即在 KTA2_addModel4 算法中，增加训练了一种同时考虑较大影响点和较小影响点的模型。考虑影响点对代理模型的影响，可能降低训练得到的代理模型的质量，从而可能产生较大的近似误差。与传统只使用一个代理模型的数据驱动的进化算法对比，使用多个代理模型的数据驱动的进化算法的好处在于：

- 1) 由多个代理模型共同完成近似真实昂贵函数评估任务，可以综合各个代理模型的作用，提升预测准确率；
- 2) 等同于将一个代理模型细分、精确化，可以兼顾不同候选解适应度值的预测准确率。

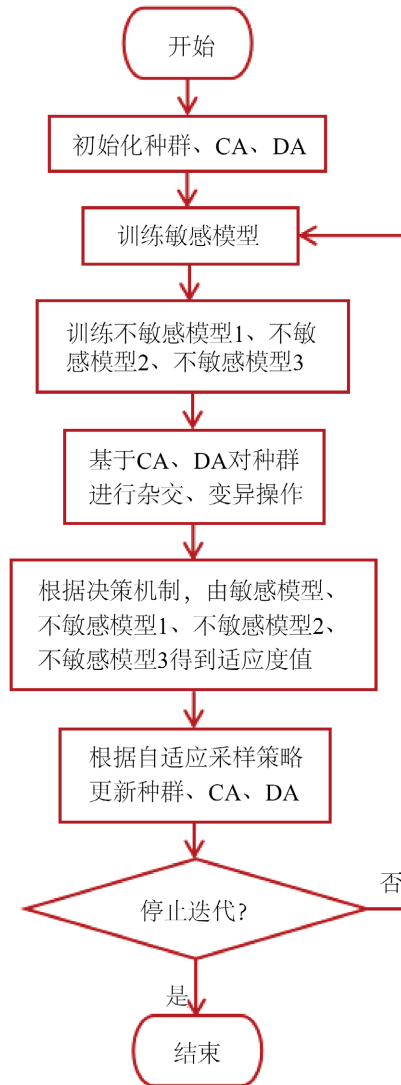


Figure 3. Flowchart of KTA2_addModel4 algorithm
图 3. KTA2_addModel4 算法流程图

在 KTA2_addModel4 算法中，种群中的个体具有多个目标，针对每个目标，训练四种克里金模型作为代理模型：包含所有影响点训练的敏感模型、除去较大影响点训练的不敏感模型 1、除去较小影响点

训练的不敏感模型 2、同时除去较大和较小影响点训练的不敏感模型 3。如图 4，由于代理模型的训练针对每个目标，KTA2_addModel4 算法中改进的代理模型描述如下：

设种群规模为 N ，种群中的个体有 m 个目标，对每个目标的所有目标值进行升序排序，则根据每个目标，得到种群的升序排列。设置控制影响点数量的参数 τ ， τ 表示取种群中训练数据的比例。针对每个目标，训练敏感模型时，取 N 个训练数据作为训练集；训练不敏感模型 1 时，取前 $\tau * N$ 个训练数据作为训练集；训练不敏感模型 2 时，取后 $\tau * N$ 个训练数据作为训练集；训练不敏感模型 3 时，取中间 $(1 - \tau) * 2 * N$ 即去掉前 $(1 - \tau) * N$ 和后 $(1 - \tau) * N$ 个训练数据作为训练集。

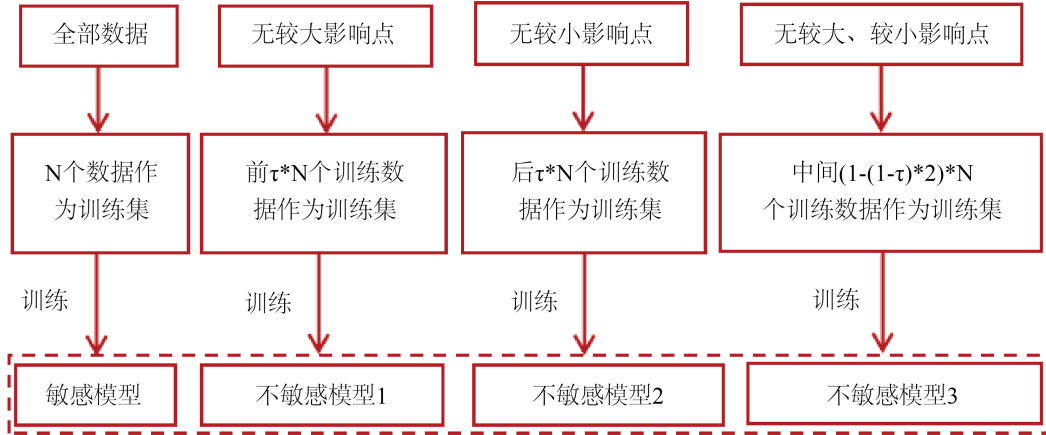


Figure 4. Agent model of KTA2_addModel4 algorithm

图 4. KTA2_addModel4 算法的代理模型

3.2. 改进代理模型的使用

在 KTA2 算法中，通过某种决策机制，使用敏感模型、不敏感模型 1、不敏感模型 2 得到候选解的适应度值。在 KTA2_addModel4 算法中，由于增加了不敏感模型 3，因此代理模型的使用也要发生改变。但是，代理模型的使用原理，即决策机制未作出改变。KTA2_addModel4 中代理模型的使用如下：

设种群规模为 N ，目标个数为 m 。首先由敏感模型预测得到预测值 y_s^i ，然后分别计算训练不敏感模型 1、不敏感模型 2、不敏感模型 3 的训练数据集的均值 λ 、 μ 、 σ ，最后比较 y_s^i 与 λ 、 μ 、 σ 差值的绝对值，根据最小值选择对应的模型作为最终选择的预测模型，如图 5 所示。

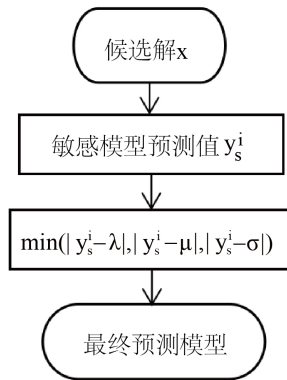


Figure 5. Use of KTA2_addModel4 algorithm agent model

图 5. KTA2_addModel4 算法代理模型的使用

3.3. 改进代理模型的更新

在 KTA2_addModel4 算法中, 由于增加了不敏感模型 3, 所以代理模型的更新也要作出相应的调整。但是, 代理模型的更新策略与 KTA2 算法中更新策略相同。如 KTA2_addModel4 算法流程图图 3 所示, 如果没有满足停止条件, 更新后的种群进入新一轮迭代, 然后会按照 3.1 节的图 4 所示, 从新一代种群中, 得到全部数据集、无较大影响点的数据集、无较小影响点的数据集和无较大、较小影响点的数据集, 依次更新敏感模型、不敏感模型 1、不敏感模型 2 和不敏感模型 3。

4. 实验结果及分析

为了验证改进的 KTA2 算法——KTA2_addModel4 算法的性能, 本节首先将 KTA2_addModel4 算法与 KTA2 算法在 11 个测试函数 CDTLZ2、DTLZ1、IDTLZ1、IDTLZ2、SDTLZ1、SDTLZ2、WFG1、WFG3、WFG5、WFG7、WFG9 上作对比, 然后再将 KTA2_addModel4 算法与 4 个代理模型辅助的昂贵多目标进化算法 ABSAEA 算法、CSEA 算法、KRVEA 算法、MOEADEGO 算法在这 11 个测试函数上作对比。本文所有测试函数及对比算法参数均设置为默认值, KTA2_addModel4 算法参数设置与 KTA2 算法默认值一致。CDTLZ2、DTLZ1、IDTLZ1、IDTLZ2、SDTLZ1、SDTLZ2、WFG1、WFG3、WFG5、WFG7、WFG9 均为 3 目标测试函数。种群规模均设置为 100, 最大函数评估次数 maxFE 均设置为 300。

本文实验选取反转世代距离 IGD [13] (Inverted Generational Distance, IGD) 作为评价指标, IGD 由真实 Pareto 前沿 [13] 中的个体到实验所求得的 Pareto 解集的平均距离表示, 反映算法求得的 Pareto 解集逼近真实 Pareto 前沿的情况。算法求得的 Pareto 解集越逼近真实 Pareto 前沿说明算法的性能越好, 即 IGD 值越小算法的性能越好。

4.1. 与 KTA2 算法对比

本节使用 IGD 作为算法的性能评价指标, 表 1 是 KTA2_addModel4 算法与 KTA2 算法在 CDTLZ2、DTLZ1、IDTLZ1、IDTLZ2、SDTLZ1、SDTLZ2、WFG1、WFG3、WFG5、WFG7、WFG9 测试函数上的 IGD 性能对比结果。为了保证算法的真实性和公平性, 在每个测试函数上, 每个算法独立运行 30 次。表中每个算法在每个测试函数上的 IGD 结果数据有两个, 第一个是算法独立运行 30 次后的 IGD 平均值, 第二个是 IGD 标准差值。每个测试函数上的性能最优算法加粗表示。从表 1 中可以看出, KTA2_addModel4 算法在 11 个测试函数上与 KTA2 算法对比, 在 CDTLZ2、DTLZ1、IDTLZ2、SDTLZ1、WFG1、WFG3、WFG7 这 7 个测试函数上的 IGD 均值都比较小。在 IGD 均值更小的这 7 个测试函数上, IGD 标准差值只有在 WFG1 和 WFG3 两个测试函数上稍微大于 KTA2 算法, 在其他 5 个测试函数的 IGD 标准差值均小于 KTA2 算法。总体来看, KTA2_addModel4 算法在 11 个测试函数中, 在 7 个测试函数上性能优于 KTA2 算法。

Table 1. Comparison between KTA2_addModel4 algorithm and KTA2 algorithm

表 1. KTA2_addModel4 算法与 KTA2 算法对比

| 测试函数 | 对比算法 | KTA2 | KTA2_addModel4 |
|--------|------|----------------------------|----------------------------|
| CDTLZ2 | | 1.1856e-1 (4.10e-2) | 1.0873e-1 (2.70e-2) |
| DTLZ1 | | 1.5963e+1 (8.74e+0) | 1.3202e+1 (6.49e+0) |
| IDTLZ1 | | 1.7703e+1 (8.46e+0) | 1.8327e+1 (9.16e+0) |
| IDTLZ2 | | 1.4518e-1 (2.37e-2) | 1.3784e-1 (2.29e-2) |

Continued

| | | |
|--------|----------------------------|----------------------------|
| SDTLZ1 | 3.4559e+1 (1.92e+1) | 3.1951e+1 (1.92e+1) |
| SDTLZ2 | 1.6093e-1 (1.39e-2) | 1.6689e-1 (1.96e-2) |
| WFG1 | 1.8930e+0 (1.32e-1) | 1.8800e+0 (1.38e-1) |
| WFG3 | 3.7705e-1 (6.79e-2) | 3.7324e-1 (6.69e-2) |
| WFG5 | 2.8824e-1 (5.60e-2) | 3.1999e-1 (9.36e-2) |
| WFG7 | 6.0479e-1 (3.06e-2) | 5.9838e-1 (3.27e-2) |
| WFG9 | 6.5777e-1 (7.06e-2) | 6.6039e-1 (7.51e-2) |

4.2. 与其他算法对比

本节仍使用 IGD 作为算法的性能评价指标,将 KTA2_addModel4 算法与 ABSAEA、CSEA、KRVEA、MOEADEGO 四个代理模型辅助的昂贵多目标进化算法在 CDTLZ2、DTLZ1、IDTLZ1、IDTLZ2、SDTLZ1、SDTLZ2、WFG1、WFG3、WFG5、WFG7、WFG9 测试函数上作对比。表 2 是 KTA2_addModel4 算法与 ABSAEA、CSEA、KRVEA、MOEADEGO 四个算法的 IGD 性能对比结果。为了保证实验结果的可靠性,在每个测试函数上,每个算法独立运行 30 次。表中每个算法在每个测试函数上的 IGD 结果数据有两个,括号外的是算法独立运行 30 次后的 IGD 均值,括号内的是 IGD 标准差值。性能更好的 IGD 值加粗表示。如表 2 所示,KTA2_addModel4 算法在 9 个测试函数 CDTLZ2、DTLZ1、IDTLZ1、SDTLZ1、SDTLZ2、WFG3、WFG5、WFG7、WFG9 上的 IGD 均值都最小,虽然有少数几个 IGD 标准差值大于其他算法,但是相差很小。因此,KTA2_addModel4 算法在这 9 个测试函数上的性能基本优于其他对比算法。

Table 2. Comparison between KTA2_addModel4 algorithm and other algorithms

表 2. KTA2_addModel4 算法与其他算法对比

| 测试函数 \ 对比算法 | KTA2_addModel4 | ABSAEA | CSEA | KRVEA | MOEADEGO |
|-------------|----------------------------|----------------------------|----------------------------|---------------------|---------------------|
| CDTLZ2 | 1.0873e-1 (2.70e-2) | 2.5619e-1 (6.29e-2) | 2.4089e-1 (5.45e-2) | 5.8825e-1 (1.63e-1) | 3.6800e-1 (1.11e-1) |
| DTLZ1 | 1.3202e+1 (6.49e+0) | 2.9548e+1 (1.06e+1) | 2.1249e+1 (7.74e+0) | 3.4763e+1 (1.03e+1) | 4.0893e+1 (8.70e+0) |
| IDTLZ1 | 1.8327e+1 (9.16e+0) | 2.7088e+1 (1.12e+1) | 3.6999e+1 (1.39e+1) | 3.2202e+1 (1.27e+1) | 5.9617e+1 (1.15e+1) |
| IDTLZ2 | 1.3784e-1 (2.29e-2) | 8.9130e-2 (7.31e-3) | 1.6793e-1 (2.45e-2) | 1.1573e-1 (1.88e-2) | 2.5052e-1 (2.79e-2) |
| SDTLZ1 | 3.1951e+1 (1.92e+1) | 6.7352e+1 (2.63e+1) | 3.5097e+1 (1.08e+1) | 6.2300e+1 (1.56e+1) | 5.8105e+1 (1.57e+1) |
| SDTLZ2 | 1.6689e-1 (1.96e-2) | 3.9016e-1 (7.03e-2) | 6.0868e-1 (6.72e-2) | 6.3025e-1 (8.52e-2) | 9.1488e-1 (7.88e-2) |
| WFG1 | 1.8800e+0 (1.38e-1) | 1.8002e+0 (1.21e-1) | 1.7534e+0 (1.15e-1) | 1.8183e+0 (9.56e-2) | 2.1854e+0 (8.90e-2) |
| WFG3 | 3.7324e-1 (6.69e-2) | 4.5523e-1 (6.83e-2) | 5.5233e-1 (4.02e-2) | 5.8827e-1 (4.52e-2) | 6.5171e-1 (2.74e-2) |

Continued

| | | | | | |
|------|-------------------------------|------------------------|------------------------|------------------------|------------------------|
| WFG5 | 3.1999e-1 (9.36e-2) | 4.7047e-1 (5.62e-2) | 5.9048e-1 (2.80e-2) | 4.0829e-1 (4.11e-2) | 6.0900e-1 (4.26e-2) |
| WFG7 | 5.9838e-1 (3.27e-2) | 6.0103e-1 (3.09e-2) | 6.0473e-1 (2.57e-2) | 6.6574e-1 (2.16e-2) | 6.7161e-1 (2.54e-2) |
| WFG9 | 6.6039e-1 (7.51e-2) | 7.1066e-1 (7.32e-2) | 7.3447e-1 (6.81e-2) | 7.6751e-1 (5.29e-2) | 7.9993e-1 (4.50e-2) |

5. 总结与展望

数据驱动的进化优化算法是近年来研究者针对昂贵进化优化问题提出的一种有效的解决方法。本文对在线数据驱动的进化优化算法 KTA2 进行改进, 通过研究提升代理模型的质量以提升算法的性能。本文对代理模型作出的改进在一些测试问题上取得较好的效果, 但是在其他测试问题上的性能仍有待提升。由于增加了不敏感模型 3, 降低敏感点对模型质量影响的同时, 也增加了模型预测的不准确性, 关于如何进一步解决这一问题, 使其在更多测试问题上取得优良效果, 仍有待研究。

参考文献

- [1] Wang, H., Jin, Y. and Jansen, J.O. (2016) Data-Driven Surrogate-Assisted Multiobjective Evolutionary Optimization of a Trauma System. *IEEE Transactions on Evolutionary Computation*, **20**, 939-952. <https://doi.org/10.1109/TEVC.2016.2555315>
- [2] Zhou, Z., Ong, Y.S., Nguyen, M.H. and Lim, D. (2005) A Study on Polynomial Regression and Gaussian Process Global Surrogate Model in Hierarchical Surrogate-Assisted Evolutionary Algorithm. 2005 *IEEE Congress on Evolutionary Computation*, Vol. 3, Edinburgh, 2-5 September 2005, 2832-2839. <https://doi.org/10.1109/CEC.2005.1555050>
- [3] Chugh, T., Jin, Y., Miettinen, K., Hakanen, J. and Sindhya, K. (2018) A Surrogate-Assisted Reference Vector Guided Evolutionary Algorithm for Computationally Expensive Many-Objective Optimization. *IEEE Transactions on Evolutionary Computation*, **22**, 129-142. <https://doi.org/10.1109/TEVC.2016.2622301>
- [4] Jin, Y., Olhofer, M. and Sendhoff, B. (2002) A Framework for Evolutionary Optimization with Approximate Fitness Functions. *IEEE Transactions on Evolutionary Computation*, **6**, 481-494. <https://doi.org/10.1109/TEVC.2002.800884>
- [5] Zapotecas Martínez, S. and Coello Coello, C.A. (2013) MOEA/D Assisted by RBF Networks for Expensive Multi-Objective Optimization Problems. *Proceedings of the 15th Annual Conference on Genetic and Evolutionary Computation*, Amsterdam, 6-10 July 2013, 1405-1412. <https://doi.org/10.1145/2463372.2465805>
- [6] Huang, P.F., Wang, H.D. and Jin, Y.C. (2021) Offline Data-Driven Evolutionary Optimization Based on Tri-Training. *Swarm and Evolutionary Computation*, **60**, Article ID: 100800. <https://doi.org/10.1016/j.swevo.2020.100800>
- [7] Huang, P., Wang, H. and Ma, W. (2019) Stochastic Ranking for Offline Data-Driven Evolutionary Optimization Using Radial Basis Function Networks with Multiple Kernels. 2019 *IEEE Symposium Series on Computational Intelligence (SSCI)*, Xiamen, 6-9 December 2019, 2050-2057. <https://doi.org/10.1109/SSCI44817.2019.9002961>
- [8] Pan, L., He, C., Tian, Y., Wang, H., Zhang, X. and Jin, Y. (2018) A Classification-Based Surrogate-Assisted Evolutionary Algorithm for Expensive Many-Objective Optimization. *IEEE Transactions on Evolutionary Computation*, **23**, 74-88. <https://doi.org/10.1109/TEVC.2018.2802784>
- [9] Yu, F., Gong, W. and Zhen, H. (2022) A Data-Driven Evolutionary Algorithm with Multi-Evolutionary Sampling Strategy for Expensive Optimization. *Knowledge-Based Systems*, **242**, Article ID: 108436. <https://doi.org/10.1016/j.knsys.2022.108436>
- [10] Hou, A.M. and Roald, L.A. (2022) Data-Driven Tuning for Chance-Constrained Optimization: Two Steps towards Probabilistic Performance Guarantees. *IEEE Control Systems Letters*, **6**, 1400-1405. <https://doi.org/10.1109/LCSYS.2021.3096826>
- [11] Gu, Q.H., Wang, D.N., Jiang, S., Xiong, N.X. and Jin, Y. (2021) An Improved Assisted Evolutionary Algorithm for Data-Driven Mixed Integer Optimization Based on Two_Arch. *Computers & Industrial Engineering*, **159**, Article ID: 107463. <https://doi.org/10.1016/j.cie.2021.107463>
- [12] Song, Z., Wang, H., He, C. and Jin, Y. (2021) A Kriging-Assisted Two-Archive Evolutionary Algorithm for Expensive

Many-Objective Optimization. *IEEE Transactions on Evolutionary Computation*, **25**, 1013-1027.
<https://doi.org/10.1109/TEVC.2021.3073648>

- [13] 郑金华, 邹娟. 多目标进化优化[M]. 北京: 科学出版社, 2017.