

基于协同进化策略的大规模昂贵优化算法

付国霞¹
FU Guoxia

摘要

随着工程或者科学问题的复杂化,优化问题的维度日益增高,导致有些问题评价一次候选解的时间很长,而进化算法在获得最优解的过程中需要进行大量的目标函数评价,因此其无法直接应用于求解大规模昂贵优化问题。代理模型辅助的进化算法可以有效地解决昂贵优化问题,但是随着问题维度的增高,训练一个准确的代理模型需要的样本也会增多,这对于大规模问题显然是难以完成的。为此,利用随机分组将大规模优化问题分成若干个低维度的子问题,通过代理模型对每个子问题进行优化,以此不断迭代搜索得到最优解。为了验证算法的有效性,在 CEC' 2013 的 15 个基准测试问题上进行了测试,实验结果表明,所提出的算法在求解大规模昂贵优化问题上效果十分显著。

关键词

大规模优化问题; 代理模型; 昂贵问题; 随机分组; 协同进化; RBFN

doi: 10.3969/j.issn.1672-9528.2024.10.019

0 引言

随着计算机科学技术的发展,工程优化问题在各个行业领域显示出越来越重要的作用。许多现实中的复杂问题,都可以抽象成大规模问题来求解^[1],其核心就是通过模拟仿真将工程问题转化为大规模实值优化问题,进而求解该问题的最优。如何有效地求解一个优化问题,是大规模优化研究中的一个热点兼难点问题。

最速下降法、拟牛顿法等传统的优化方法具有收敛速度快的特点,但是目前许多优化问题变得十分复杂。当遇到需要同时优化多个目标、优化问题的决策变量维度高以及优化目标函数没有显式表达式等问题时,传统的优化算法非常容易收敛到局部最优解。元启发式优化算法是一种随机搜索算法,因其不需要有明确的数学表达式及模型,不要求目标函数连续可微,也不需要一些先验知识和数学信息,而且因其表现出强有力的求解能力,近年来受到了越来越多的关注。一般来说,该算法具有高鲁棒性、自适应性、自学习性、并行搜索、全局搜索能力强等优点,元启发式优化算法一般包括遗传算法、差分进化算法和粒子群算法等。

当优化问题的维度超过 1000 维时,被称为大规模优化问题^[2],此时元启发式优化算法面临着超高维度带来的维度灾难,决策变量数的增加导致搜索空间呈指数倍增长,导致算法很难找到全局最优解。此外,许多大规模优化问题常常

伴随着优化目标函数评价比较费时,在评价次数有限的情况下,优化此类问题的难度急剧增加。到目前为止,学者们在求解大规模优化问题上已经取得了一定的成果,但是对于优化目标函数评价昂贵的大规模优化问题的研究仍然处于起步阶段。

1 相关理论简介

1.1 差分进化算法 (DE)

差分进化算法是一种简单且强有力的基于种群的进化算法,在连续搜索空间中能够实现有效且高效的全局优化^[3],该算法的具体步骤如下。

- (1) 在问题搜索空间内随机初始化个体。
- (2) 计算种群中所有个体的适应值。
- (3) 变异操作: 种群中个体通过变异策略产生相应的变异向量。
- (4) 交叉操作: 种群中个体和它相应的变异向量产生新的个体。
- (5) 选择操作: 通过比较当前种群中所有个体的适应值选择下一代。
- (6) 满足终止条件则退出并输出最优解,否则返回步骤 (3)。

1.2 径向基函数网络 (RBFN)

径向基函数网络是由输入层、隐含层和输出层三层组成的神经网络^[4],径向基函数网络的输出公式为:

$$y = \sum_{i=1}^n \omega_i \phi(\|x - c_i\|) + \omega_0 \quad (1)$$

1. 太原学院计算机科学与技术系 山西太原 030032

[基金项目] 山西省高等学校科技创新计划项目 (2023L177);

太原学院院级科研项目 (23TYQN10)

式中： ω_i 为第*i*个输出权重， ω_0 为偏项，*n*为隐含层的节点数量， $\phi(\|\cdot\|)$ 为激活函数，**x**为训练样本， c_i 为第*i*个径向基函数的中心。

1.3 随机分组

随机分组将一个目标向量随机等分成若干个不重叠的子组，每次迭代时进化算法都会对每个子组进行优化，在完成一次迭代后会重新进行随机分组，这样会使每个变量有相同的概率被分到任意一个子组中，这便提高了不可分离变量一起优化的几率^[5]。该方法的具体步骤如下。

- (1) 将高维目标向量随机分组成若干个低维子组。
- (2) 进化算法对每个子组进行优化。
- (3) 满足终止条件则结束，否则返回步骤(1)。

2 基于协同进化策略的大规模昂贵优化算法

2.1 CC-LSEA 算法详细介绍

算法1给出了基于协同进化策略的大规模昂贵优化算法(CC-LSEA)伪代码。该算法在开始迭代之前，通过拉丁超立方体采样技术生成初始样本，并对这些样本使用昂贵目标函数评价后保存到数据库中，随即确定出当前数据库中的最优解。在对每个子组优化之前，先将原问题的*D*个决策变量随机分组为*K*个子组，每个子组分配的决策变量相互不重叠且数量均为subgroupsize个。此时，就将优化一个*D*维的问题，转换成优化*K*个subgroupsize维的子问题，对每个子问题都建立一个代理模型，并通过该代理模型来辅助相应子种群进化，进而优化相应的子问题。每个子问题优化完毕后，所有子种群个体拼接形成完整的解，再使用昂贵目标函数评价种群中的所有个体，将其全部保存到数据库中，并更新当前数据库中的最优解，随后进入下一次迭代。当满足终止条件时，输出最优解及其目标函数值。

算法 1: CC-LSEA 的框架	
输入: 问题维度 <i>D</i> , 子组数量 <i>K</i> , 子组大小 subgroupsize	
输出: 全局最优解 gbest 及其目标函数值	
1:	初始化若干个样本点进行目标函数评价后保存数据库中, 更新最优解 gbest;
2:	将原问题的 <i>D</i> 维决策变量随机分成 <i>K</i> 组, 每个子组大小为 subgroupsize;
3:	为每个子问题训练代理模型;
4:	所有子种群使用代理模型优化完成后, 子种群拼接形成原问题的解;
5:	昂贵目标函数评价种群所有个体后保存到数据库中, 更新最优解 gbest;
6:	满足终止条件进入步骤 7, 否则返回步骤 2;
7:	输出全局最优解 gbest 及其目标函数值。

2.2 代理模型的构建

每次随机分组都将原问题的决策变量分为*K*个子组，通过每个子组分配到的决策变量信息，从原始种群中进行相应提取，进而组成了*K*个子种群，也可以运用同样的方式从数据库中提取出*K*个子集。对于每个子组来说，将会从对应的子集中选取距离当前最优解 gbest 欧氏距离最近的若干个样本，作为该子组建立代理模型的训练样本，辅助对应的子种群优化，这只是一个子组构建代理模型的过程，*K*个子组代理模型的建立可以并行进行。

2.3 子种群的协同进化

在每个子种群优化之前，先从数据库中选择适应值最优的个体形成原始问题种群，随后按照随机分组策略形成子问题的子种群，之后为每个子组建立代理模型，以辅助子种群进行优化，*K*个子种群分别迭代若干次后停止进化。当所有子种群优化完成后，每个子种群以代理模型对其的估值从小到大依次排序，然后根据每个子组分配的决策变量信息对应回去，从而形成原始问题维度的一个完整种群，至此完成了一次子种群的协同进化。

3 实验设计及结果分析

3.1 测试算法及其设置

在 CEC' 2013^[6]大规模优化的 15 个单目标基准问题上，对 CC-LSEA 算法的效果进行测试，其函数特征信息如表 1 所示。在所有对比实验中，所有算法的终止条件均为达到最大的真实评价次数，该算法中设置为 11×*D*，其中*D*为问题维度大小。所有的算法全部独立运行 25 次，并且通过显著性水平为 0.05 且带有 Bonferroni 校验的 Wilcoxon 秩和检验方法^[7]对所有结果进行显著性统计检验。

表 1 CEC' 2013 基准测试问题的函数特性

类型	函数	特征
完全可分函数	F_1	单峰, 可分, 偏移
	F_2 、 F_3	多峰, 可分, 偏移
部分可分函数	F_4 、 F_8 、 F_{11}	单峰, 部分可分, 偏移
	F_5 、 F_6 、 F_7 、 F_9 、 F_{10}	多峰, 部分可分, 偏移
重叠函数	F_{12}	多峰, 可分, 偏移
	F_{13}	单峰, 不可分, 重叠, 偏移
	F_{14}	单峰, 不可分, 冲突子部分, 偏移
不可分函数	F_{15}	单峰, 完全不可分, 偏移

CC-LSEA 算法使用 RBFN 模型来评估子种群个体的适应值，因 RBFN 模型在处理 100 维的问题上仍然可以取得很好的效果，所以子组维度大小设置为 100，初始样本数设置为 200，训练 RBFN 模型的训练样本数设置为 200。进化优

化算法选择 DE，种群的大小设置为 50，每次随机分组后的种群迭代 1 次，变异策略设置为 DE/rand/1，交叉策略设置为二项式交叉，变异因子设置为 0.5，交叉概率设置为 0.3。

3.2 实验结果及分析

表 2 给出了求解 CEC' 2013 的 15 个基准测试问题时 CC-LSEA 与 CSO^[8]、SL-PSO^[9]、采用不同模型的 SACC^[10] 算法之间的统计结果，其中的 GP、QPA、RBFN 和 SVR 分别是使用了不同的代理模型的 SACC 算法。表 2 中数值表示算法获得最优解的适应值，加粗表示该算法在对应的基准测试问题上获得了最优解，其中符号“+”“≈”和“-”分别表示 CC-LSEA 算法相比于对比算法显著性优、没有显著性差异和显著性差。

表 2 实验统计结果 median

函数	CSO	SL-PSO	SACC-GP	SACC-QPA	SACC-RBFN	SACC-SVR	CC-LSEA
F_1	8.34E+10 (+)	6.32E+10 (+)	9.74E+08 (-)	3.34E+09 (-)	2.09E+09 (-)	1.35E+09 (-)	5.58E+09
F_2	3.99E+04 (+)	3.78E+04 (+)	9.13E+03 (-)	1.15E+04 (-)	9.47E+03 (-)	7.73E+03 (-)	1.273E+04
F_3	2.16E+01 (+)	2.16E+01 (+)	2.06E+01 (-)	2.05E+01 (-)	2.06E+01 (-)	2.06E+01 (-)	2.07E+01
F_4	3.29E+12 (+)	3.67E+12 (+)	5.41E+12 (+)	8.48E+12 (+)	4.99E+12 (+)	6.78E+12 (+)	6.88E+11
F_5	1.55E+07 (+)	1.47E+07 (+)	2.72E+07 (+)	2.80E+07 (+)	2.58E+07 (+)	2.80E+07 (+)	9.85E+06
F_6	1.07E+06 (≈)	1.07E+06 (≈)	1.07E+06 (≈)	1.07E+06 (+)	1.07E+06 (≈)	1.07E+06 (≈)	1.07E+06
F_7	1.57E+12 (+)	1.03E+12 (+)	3.54E+10 (+)	2.95E+11 (+)	2.95E+10 (+)	2.73E+10 (+)	8.46E+09
F_8	8.70E+16 (+)	1.27E+17 (+)	3.39E+17 (+)	4.49E+17 (+)	3.48E+17 (+)	2.90E+17 (+)	1.99E+16
F_9	1.21E+09 (+)	1.16E+09 (+)	2.35E+12 (+)	9.91E+12 (+)	2.25E+12 (+)	1.76E+12(+)	7.47E+08
F_{10}	9.52E+07 (≈)	9.55E+07 (+)	9.58E+07 (+)	9.61E+07 (+)	9.57E+07 (+)	9.57E+07 (+)	9.51E+07
F_{11}	3.01E+14 (+)	2.05E+14 (+)	1.02E+13 (+)	2.98E+13 (+)	8.58E+12 (+)	6.30E+12 (+)	8.68E+11
F_{12}	2.04E+12 (+)	1.63E+12 (+)	2.86E+10 (-)	5.99E+10 (-)	2.69E+10 (-)	8.31E+09 (-)	2.38E+11
F_{13}	1.04E+12 (+)	1.60E+14 (+)	7.43E+11 (+)	2.67E+13 (+)	9.83E+11 (+)	4.78E+11 (+)	2.06E+11
F_{14}	7.78E+12 (+)	2.55E+14 (+)	4.34E+12 (+)	2.72E+13 (+)	4.12E+12 (+)	2.93E+12 (+)	2.37E+12
F_{15}	5.73E+14 (+)	3.89E+14 (+)	4.06E+09 (-)	1.16E+10 (-)	3.39E+09 (-)	3.70E+09 (-)	4.92E+12
+/-/≈	13/2/0	14/1/0	9/1/5	10/0/5	9/1/5	9/1/5	NAN

通过比较 CC-LSEA 在与两个基于非分解的大规模优化算法 CSO 和 SL-PSO 的统计结果可知，CC-LSEA 在测试问题 F_6 和 F_{10} 上与 CSO 没有显著性差异，在测试问题 F_6 上与 SL-PSO 没有显著性差异，除此之外都要显著性优于两个非分解的大规模优化算法。CC-LSEA 在测试问题 F_1 、 F_2 、 F_3 、 F_{12} 和 F_{15} 上要比 SACC 使用四种代理模型的算法显著性差，说明 CC-LSEA 的分解策略在完全可分问题、多峰重叠问题和完全不可分问题上效果不是很理想。CC-LSEA 在测试问题 F_6 上和 SACC-SVR 没有显著性差异，但要显著性优于 SACC-GP、SACC-QPA 和 SACC-RBFN。CC-LSEA 在测试问题 F_4 、 F_5 、 F_7 、 F_8 、 F_9 、 F_{10} 、 F_{11} 、 F_{13} 和 F_{14} 上都要显著性优于基于分解的大规模优化算法 SACC，由此可见该算法在处理部分可分离问题和重叠问题上极具竞争力的。从整体上来看，CC-LSEA 算法在计算资源有限的情况下，可以获得比以上几种算法更优的可行解。

4 总结

基于协同进化策略的大规模昂贵优化算法（CC-LSEA）采用“分而治之”的策略，通过随机分组将大规模昂贵问题划分成多个中低维子问题，在子问题上建模，通过模型辅助优化并进行预筛，模型预筛后得到的各个子问题种群（简称子种群）中的个体依次拼接，形成原始大规模问题的解，然后使用真实昂贵适应度函数对其进行评估，以探索搜索区域。为了验证 CC-LSEA 算法的有效性，与近年来提出的几个大规模算法在 CEC'2013 测试集上进行了测试对比。实验结果显示，该算法在求解大规模昂贵问题上相比于其他算法具有较好的优化性能，尤其是在处理部分可分的问题上表现较佳。

参考文献：

- [1]MAHDAVI S, SHIRI M E, RAHNAMAYAN S. Metaheuristics in large-scale global continues optimization: a survey [J]. Information sciences, 2015, 295:407-428.
- [2]TANG K, YAO X, SUGANTHAN P N, et al.Benchmark functions for the CEC'2008 special session and competition on large scale global optimization [J].Nature inspired computation, 2007, 24: 1-18.
- [3]STORN R, PRICE K.Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces[J].Journal of global optimization, 1997,11(4):341-359.
- [4]GUTMANN H M. A radial basis function method for global optimization[J].Journal of global optimization, 2001, 19(3): 201-227.

基于 GCN 模型的 DDoS 攻击检测技术研究

姜舒颖¹ 黄迎春¹

JIANG Shuying HUANG Yingchun

摘要

如何高效检测出分布式拒绝服务（distributed denial of service, DDoS）攻击是目前互联网领域中存在的一个亟待解决的问题。在 DDoS 攻击检测领域，考虑到固有的复杂性，尤其是系统包含的网络节点间复杂的交互，为了捕捉和建模这些节点间的关系，提出了一种基于图注意力机制的图卷积神经网络（graph convolutional network, GCN）DDoS 攻击检测模型。通过图注意力机制，模型能够自适应地为不同节点之间的关系分配重要性权重，从而更准确地识别出潜在的 DDoS 攻击行为。将 DDoS 攻击视为一个图结构，网络节点表示网络设备或主机，边表示节点之间的连接关系，能够从节点和边的特征中提取有用的信息，利用节点的邻居信息来推断节点特征，更好地捕捉 DDoS 攻击的上下文信息。实验结果证明，所设计的模型的精度极其出色，不仅提高了检测的准确性，还有助于人们更深入地理解 DDoS 攻击在网络中的传播和演变规律。

关键词

分布式拒绝服务；图卷积神经网络；图注意力机制；网络节点；图结构的建模

doi: 10.3969/j.issn.1672-9528.2024.10.020

0 引言

分布式拒绝服务攻击是一种针对计算机系统或网络的攻击行为，利用客户/服务器架构，集结多计算机资源成攻击网络，对目标系统协同攻击，导致其资源耗尽、服务中断，从而增强攻击的威力^[1]。DDoS 颠覆了传统的点对点攻击方式，展现了一种无显著统计特征的攻击方式。此类攻击利用了广泛存在的协议和服务作为掩护，使得仅凭协议/服务的

类型来区分攻击行为与正常网络活动变得极具挑战性，导致分布式拒绝服务攻击不易检测^[2]。DDoS 攻击技术的持续升级，导致防御工作变得艰巨且有挑战性。那么如何提高 DDoS 攻击检测在实际网络中应用的准确率和精确度，则有非常重要的价值和意义^[3]。

GCN 算法是图卷积神经网络研究领域的一个热点，深入研究了使用图卷积网络^[4]进行 DDoS 攻击检测，主要专注于处理由节点和边组成的网络结构，即图数据。本文提出将融入了图注意力机制的 GCN 模型应用于 DDoS 攻击检测领域，

1. 沈阳理工大学信息科学与工程学院 辽宁沈阳 110159

[5] YANG Z, TANG K, YAO X. Large scale evolutionary optimization using cooperative coevolution[J]. Information sciences, 2008, 178(15):2985-2999.

[6] LI X, TANG K, OMIDVAR M N, et al. Benchmark functions for the CEC 2013 special session and competition on large-scale global optimization [J]. Gene, 2013, 7(33):1-23.

[7] HENLEY S. Principles and procedure of statistics: a biometrical approach[J]. Computers & geosciences, 1983, 9(2):275.

[8] CHENG R, JIN Y. A competitive swarm optimizer for large scale optimization[J]. IEEE transactions on cybernetics, 2015, 45(2): 191-204.

[9] CHENG R, JIN Y. A social learning particle swarm optimization algorithm for scalable optimization[J]. Information sciences, 2015, 291:43-60.

[10] FALCO I D, CIOPPA A D, TRUNFIO G A. Investigating surrogate-assisted cooperative coevolution for large-scale global optimization[J]. Information sciences, 2019, 482:1-26.

【作者简介】

付国霞（1995—），女，山西原平人，硕士，助教，研究方向：进化算法、智能计算。

(收稿日期：2024-07-08)