

用最近邻分类方法预测 多目标优化 d-Pareto 支配性*

尹呈¹, 曾文静², 郭观七^{3†}, 王先锋¹

(1. 湘潭大学信息工程学院, 湖南湘潭 411105; 2. 中南大学信息科学与工程学院, 长沙 410083; 3. 湖南理工学院信息与通信工程学院, 湖南岳阳 414006)

摘要: 为进一步提高预测精度, 修改候选解间原始 Pareto 支配性关系, 提出了 d-Pareto 支配性最近邻预测方法。结合多目标优化的自身特点, 给出了 d-Pareto 支配性最近邻预测框架, 并论证了 d-Pareto 支配性预测比 Pareto 支配性预测具有低平均预测错误率。同时也初步研究了 d-Pareto 支配性预测与多目标进化算法的交互作用。对几个经典多目标优化问题进行实验, 仿真结果表明 d-Pareto 支配性预测具有一定的可行性和有效性。

关键词: 多目标优化; 最近邻分类方法; d-Pareto 支配性; 计算成本

中图分类号: TP301 **文献标志码:** A **文章编号:** 1001-3695(2013)12-3571-05

doi:10.3969/j.issn.1001-3695.2013.12.013

Predicting d-Pareto dominance in multi-objective optimization using nearest neighbor classification method

YIN Cheng¹, ZENG Wen-jing², GUO Guan-qi^{3†}, WANG Xian-feng¹

(1. College of Information Engineering, Xiangtan University, Xiangtan Hunan 411105, China; 2. College of Information Science & Engineering, Central South University, Changsha 410083, China; 3. College of Information & Communication Engineering, Hunan Institute of Science & Technology, Yueyang Hunan 414006, China)

Abstract: To improve predicting accuracy further, this paper modified original Pareto dominance relation among the candidate solutions, and proposed a new method named d-Pareto dominance prediction using nearest neighbor. Combined with the characteristics of multi-objective optimization, it described the framework of d-Pareto and the conclusion that a d-Pareto dominance prediction could obtain a lower average prediction error rate comparing with Pareto demonstrated dominance prediction. Besides, it also explored the interaction between d-Pareto dominance prediction and multi-objective evolutionary algorithms. Experiments on several classic MOPs were conducted and the simulation results show that prediction of d-Pareto dominance is feasible and effective.

Key words: multi-objective optimization; nearest neighbor classification method; d-Pareto dominance; computation cost

0 引言

近年来, 进化算法已成为解决多目标优化问题 (multi-objective optimization, MO) 的主流方法^[1,2], 备受学术界关注, 涌现出大量优秀算法, 其中最具有代表性的算法有 NSGA-II^[3]、SPEA-II^[4]、PESA^[5]、PAES^[6], 它们绝大多数有两个共同的特点: a) 每次迭代都需直接计算和比较候选解间目标向量值, 确定候选解间 Pareto 支配性关系; b) 需要构造非支配集, 对种群个体进行选择、交叉、变异等操作, 产生下一代进化群体。因此, 候选解间 Pareto 支配性关系的确定以及非支配集的构造直接影响着多目标优化进化算法求解效率。

对于昂贵多目标优化问题^[7,8], 一次目标函数或约束函数的评估不再是简单的函数计算, 而是可达小时或天数量级的耗时计算过程 (简称为计算成本灾难问题)。若采用现有多目标进化算法去优化此类问题, 大量的目标向量值评估势必耗费巨

大的计算开销。因此, 如何在多目标进化算法 (multi-objective evolutionary algorithms, MOEAs) 框架中有效地克服计算成本灾难问题已成为工程实践的研究重点。

针对计算成本灾难问题, 为减少对原始目标函数评价次数, 基于代理模型的 MOEAs 已成为解决昂贵多目标优化问题的研究热点^[9-11], 但该方法在代理模型与逼近技术的选择^[12]上都需要较多先验知识且每个目标函数都需要单独的模型, 模型类型和参数精度直接影响估计的准确率, 对 MO 问题建模本身也是一种挑战, 代价高昂。为此, Guo 等人^[13]提出了用模式识别方法预测多目标优化 Pareto 支配性。对于 MO 问题, 该方法将两个候选解的决策向量看成是决定其 Pareto 支配性关系的属性, 通过模式分类方法直接对候选解间 Pareto 支配性关系进行预测。预测的结果直接用于基于 Pareto 最优性概念的多目标优化, 从根本上减少了 MOEA 对目标向量评估计算与比较的依赖, 为克服多目标计算成本灾难问题提供了有效方法。

收稿日期: 2012-04-10; **修回日期:** 2012-05-21 **基金项目:** 国家自然科学基金资助项目 (60975049); 湖南省自然科学基金重点资助项目 (11JJ2037); 湖南省高校科技创新团队支持计划资助项目 (湘教通[2012]318号)

作者简介: 尹呈 (1988-), 男, 湖南邵阳人, 硕士, 主要研究方向为进化计算; 曾文静 (1988-), 女, 安徽阜阳人, 硕士, 主要研究方向为多目标优化; 郭观七 (1963-), 男 (通信作者), 湖南岳阳人, 教授, 博士, 主要研究方向为多目标优化、进化计算 (gq.guo@163.com); 王先锋 (1988-), 男, 湖南湘潭人, 硕士, 主要研究方向为智能计算。

以类条件概率密度函数服从正态分布为假设,Guo 初步实现了基于统计学习理论的贝叶斯分类器,该分类用于 SCH^[14] 函数取得了可接受的预测精度。但对多数复杂 MO 问题,类条件概率密度函数服从正态分布的假设不一定成立,因此随着测试问题复杂程度及 Pareto 支配性类比例分布不平衡程度的增加,贝叶斯分类器势必存在明显的不足。

针对非支配集的构造,为进一步降低构造算法的时间复杂度,学者们进行了深入研究。经典多目标进化算法中被公认收敛速度最快的 NSGA-II,其采用构造非支配集方法的时间复杂度 $O(mN^2)$,其中 m 是目标的个数。尽管如此,与确定一个非支配集的时间复杂度下界 $O(mN \log N)$ 相比,仍有待改进。2003 年,Jensen^[15] 借鉴二分法思想,提出了一种时间复杂度为 $O(mN \log^{m-1} N)$ 的非支配集构造方法,该方法在低维目标能达到 $O(mN \log N)$,但当目标维数较大时,时间复杂度甚至会超过 $O(mN^2)$ 。2004 年,郑金华等人^[16] 从候选解间关系入手,提出了一种新的非支配集构造方法,通过证明,该方法所需平均时间复杂度小于 $O(mN \log N)$ 。

对昂贵多目标优化问题,为进一步提高 Pareto 支配性预测精度,本文提出用最近邻分类方法预测多目标优化 d-Pareto 支配性。值得注意的是,用该方法与 MOEAs 交互作用,构造非支配集的平均时间复杂度也能小于 $O(mN \log N)$ 。

1 Pareto 最优性描述

以最小化优化问题为例,不考虑约束条件,一个多目标优化问题可表述为

$$\begin{aligned} \min y = F(x) &= (f_1(x), f_2(x), \dots, f_m(x)) \\ \text{s. t. } x &= (x_1, x_2, \dots, x_n) \in X, y = (y_1, y_2, \dots, y_m) \in Y \end{aligned} \quad (1)$$

其中: X 为 n 维决策空间; Y 为 m 维目标空间; F 为将决策空间映射到目标空间的函数向量。

定义 1 Pareto 支配性。对任意向量 $u = (u_1, u_2, \dots, u_m) \in Y, v = (v_1, v_2, \dots, v_m) \in Y$, 当且仅当 $\forall i \in \{1, 2, \dots, m\} : u_i \leq v_i \wedge \exists j \in \{1, 2, \dots, m\} : u_j < v_j$ 为真时,称 u 支配(优于) v , 记做 $u > v$; 或称 v 被支配于(劣于) u , 记做 $v < u$; 否则,称 u 与 v 不可比,记做 $u \sim v$ 。

定义 2 Pareto 最优解。 $x \in X$ 称为 Pareto 最优解(或 Pareto 非支配解、非劣解),当且仅当 $\neg \exists x^* \in X, v = F(x^*) < u = F(x^*)$ 。

定义 3 Pareto 最优集。决策空间(X)中所有最优解的集合称为 Pareto 最优集,目标空间(Y)中与之对应的目标向量集称为 Pareto 前沿或 Pareto 最优面。

2 用最近邻分类方法预测多目标优化 d-Pareto 支配性

2.1 d-Pareto 支配性预测框架

定义 4 d-Pareto 支配性。对于决策向量 x, y , 若 $x > y$ 或 $x \sim y$, 则 $x >_d y$, 否则 $x <_d y$ 。

基于 Pareto 最优性的多目标进化算法,必先要确定候选解间 Pareto 支配性关系,再构造出进化群体的非支配集,然后才能使算法迭代搜索至优化问题的 Pareto 最优解集。郑金华等人^[16] 为提高非支配集的构造效率,对候选解间支配性关系进行修改,只要候选解间 d-Pareto 支配性关系确定,就能用快速排序的思路构造非支配集且平均时间复杂度小于 $O(mN \log N)$ 。但候选解间 d-Pareto 支配性关系的确定需要直接计算和比较目标向量值,对于复杂结构设计优化和基于种群搜索的 MOEAs,大量评估目标函数值势必带来计算成本灾难问题。

本文根据候选解的 d-Pareto 支配性样本数据,采用最近邻分类方法预测任意候选解间 d-Pareto 支配性。

对具体 MOPs, 任意给定两候选解 x_1, x_2 , 它们间的 Pareto 支配性关系记为 $w(x_1, x_2)$ 。根据 d-Pareto 支配性定义,可将 $w(x_1, x_2)$ 区分为两类: d 支配 ($>_d$) 和被支配 ($<$)。给定两个规模为 N 的候选解样本集 E_1 和 E_2 , 采用计算和比较目标函数向量的方法能确定任意 $w(e_i \in E_1, e_j \in E_2)$, 从而构造出规模为 $N \times N$ 的样本集 $E = \{(e_{ij}, w_{ij})\}, i, j = 1, 2, \dots, N, e_{ij} = (e_i, e_j)$ 。d-Pareto 支配性预测最近邻分类方法基本框架如下:

- a) 在决策向量定义域内,随机产生规模大小为 N 的两个候选解集 E_1, E_2 ;
- b) 计算和比较目标向量,确定 $w(e_i \in E_1, e_j \in E_2), i, j = 1, 2, \dots, N$;
- c) 从 E_1 中找出与 x_1 最相似候选解 e_1^* ;
- d) 从 E_2 中找出与 x_2 最相似候选解 e_2^* ;
- e) 令 $w(x_1, x_2) = w(e_1^*, e_2^*)$ 。

2.2 d-Pareto 支配性预测错误率分析

采用分类方法预测候选解间支配性类别,类别错分不可避免。为验证多目标优化 d-Pareto 支配性预测比多目标优化 Pareto 支配性预测具有低预测错误率,本文现从基于最小错误率的贝叶斯分类准则入手,分析并论证待测样本 x 被错分的平均错误率。

对多目标优化 Pareto 支配性预测,样本集中存在支配类 ($>$)、被支配类 ($<$) 及不可比类 (\sim) 三个类别,分别记为 $C_i (i = 1, 2, 3)$, 它们将样本特征空间划分成三个不同区域,分别记为 R_1, R_2, R_3 。分析 x 的类别被错分的来源,可由式(2)计算错分 x 类别的平均错误概率 $P(e)$ 。

$$\begin{aligned} P(e) &= [P(x \in R_2 | C_1) + P(x \in R_3 | C_1)]P(C_1) + \\ & [P(x \in R_1 | C_2) + P(x \in R_3 | C_2)]P(C_2) + \\ & [P(x \in R_1 | C_3) + P(x \in R_2 | C_3)]P(C_3) \end{aligned} \quad (2)$$

但采用式(2)直接求解 $P(e)$, 计算过于繁琐,通常将式(2)转换成 $P(e) = 1 - P(c)$, 其中 $P(c)$ 为准确分类 x 的平均概率,可由式(3)求解。

$$P(c) = \sum_{i=1}^3 P(x \in R_i | C_i)P(C_i) = \sum_{i=1}^3 \int_{R_i} p(x|C_i)P(C_i) dx \quad (3)$$

对多目标优化 d-Pareto 支配性预测,样本集中仅存在 $>_d$ 类和 $<$ 类两个类别,并记为 w_1 和 w_2 , 且 $w_2 = C_2, >_d = \{C_1 \cup C_3\}$, 它们将特征空间重新划分成两个不同区域,并记为 Ω_1 和 Ω_2 , 且 $\Omega_1 = R_1 \cup R_3, \Omega_2 = R_2$ 。分析候选解间 Pareto 支配性与 d-Pareto 支配性之间的联系 ($>$ 类和 \sim 类重新组合成 $>_d$ 类), 预测 x 的 d-Pareto 支配性类别,可避免 Pareto 支配性预测中 x 从 C_1 被错分至 C_3 或从 C_3 被错分至 C_1 。也就是说,若 x 被准确预测至 Ω_1 中,就无须预测 x 是属于 R_1 还是 R_3 。但对 Pareto 支配性预测,即使 x 被准确预测至 Ω_1 中,仍需预测 x 是属于 R_1 还是 R_3 。 x 在 Ω_1 中的类别预测如图 1 所示。

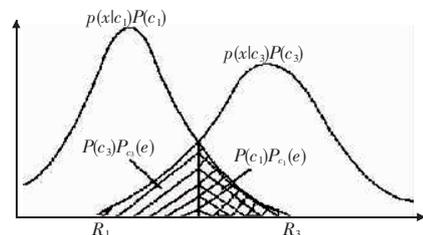


图 1 特征空间 Ω_1 中待测样本 x 类别预测错误率

结合图 1 及模式识别相关理论,可由式(4)计算 x 在 Ω_1 中类别预测的平均错误概率 P_{Ω_1} 。

$$P_{\Omega_1} = \int_{R_1} p(x|C_3)P(C_3)dx + \int_{R_3} p(x|C_1)P(C_1)dx \quad (4)$$

即 $P_{\Omega_1}(e) = P(C_1)P_{C_1}(e) + P(C_3)P_{C_3}(e)$ 。其中: $P(C_3)P_{C_3}(e)$ 为图 1 中斜线区域面积, $P(C_1)P_{C_1}(e)$ 为图 1 中纹线区域面积,两面积之和 $P_{\Omega_1}(e) > 0$ 。通过分析,不难得出

$$\int_{R_1+R_3} p(x|w_1)P(w_1)dx = \int_{R_1} p(x|C_1)P(C_1)dx + \int_{R_3} p(x|C_3)P(C_3)dx + P_{\Omega_1}(e) \quad (5)$$

式(5)左边表示多目标优化 d-Pareto 支配性预测时 x 被正确预测至 Ω_1 的概率,右边表示多目标优化 Pareto 支配性预测时 x 被正确预测至 R_1 、 R_3 的概率与被错分成 R_1 、 R_3 的概率之和。与 Pareto 支配性预测平均错误率计算方法一样,预测 x 的 d-Pareto 支配性的平均错误率 $P_d(e) = 1 - P_d(c)$,其中:

$$P_d(c) = \sum_{i=1}^2 P(x \in \Omega_i | w_i) P(w_i) = \sum_{i=1}^2 \int_{\Omega_i} p(x|w_i)P(w_i)dx = \int_{R_1+R_3} p(x|w_1)P(w_1)dx + \int_{R_2} p(x|w_2)P(w_2)dx \quad (6)$$

综合上述分析,现将多目标优化 Pareto 支配性预测的平均错误率要大于多目标优化 d-Pareto 支配性预测的平均错误率(即证明 $P(e) > P_d(e)$)论证如下。

证明 根据上文分析易知,要证明 $P(e) > P_d(e)$,必先证明 $P(c) < P_d(c)$ 。因为

$$\int_{R_1+R_3} p(x|w_1)P(w_1)dx = \int_{R_1} p(x|C_1)P(C_1)dx + \int_{R_3} p(x|C_3)P(C_3)dx + P_{\Omega_1}(e)$$

且 $P_{\Omega_1}(e) > 0$,所以

$$\int_{R_1+R_3} p(x|w_1)P(w_1)dx > \int_{R_1} p(x|C_1)P(C_1)dx + \int_{R_3} p(x|C_3)P(C_3)dx$$

故 $(\int_{R_1+R_3} p(x|w_1)P(w_1)dx + \int_{R_2} p(x|w_2)P(w_2)dx) > (\int_{R_1} p(x|C_1)P(C_1)dx + \int_{R_3} p(x|C_3)P(C_3)dx + \int_{R_2} p(x|C_2)P(C_2)dx)$

所以 $P_d(c) > P(c)$, $P(e) > P_d(e)$ 。

因此多目标优化 Pareto 支配性预测的平均错误率要大于多目标优化 d-Pareto 支配性预测的平均错误率的结论成立。

尽管上述证明分析过程均是基于贝叶斯分类准则的,但结论对最近邻分类方法来预测多目标优化支配性仍然正确。文献[17]早已对最近邻分类错误率与贝叶斯分类错误率存在的关系进行了论证,因此,用最近邻分类方法预测多目标优化 d-Pareto 支配性的准确率高于预测多目标优化 Pareto 支配性的准确率。

3 预测多目标优化 d-Pareto 支配性测试实验

测试实验主要有如下两个目的:

a) 验证预测多目标优化 d-Pareto 支配性的准确率要高于预测多目标优化 Pareto 支配性的准确率。

b) 在 Pareto 支配性类比例分布不平衡的情况下,验证用最近邻分类方法(NNC)预测多目标优化 Pareto 支配性和 d-Pareto 支配性的准确率均优于基于类条件概率密度服从高斯分布的贝叶斯分类方法(BYS)。

针对上述实验目的,本文选择了常用的多目标优化测试问题 POL^[18] ($n=2, m=2$, 定义域为 $[-\pi, \pi]$)、VTN1^[19] ($n=2, m=3$, 定义域为 $[-2, 2]$) 和 ZDT6^[20] ($n=10, m=2$, 定义域为

$[0, 1]$) 进行实验。实验中,对每个测试问题均在决策变量定义域内随机产生两个规模为 100 的候选解集 ($E_1 = 100, E_2 = 100$),计算并比较其所对应的目标向量,构造规模为 100×100 的样本集,结合分类算法预测随机产生的规模为 40×40 的待测样本集中候选解间支配性,分别对每个测试问题进行 100 次实验,每次实验都重新产生样本集,待测样本集保持不变,样本集 Pareto 支配性类分布 100 次实验的平均类比例及待测样本集各类平均预测准确率及总平均预测准确率记录于表中。

实验说明,在下文涉及比较预测多目标优化 d-Pareto 支配性平均准确率时,为了更好地分析比较数据,本文对表中数据作如下处理:a) 样本的类平均分布比例数据为 Pareto 支配性平均类比例分布数据;b) 取多目标优化 Pareto 支配性预测中 $>$ 类和 \sim 类两类的预测总平均准确率作为 Pareto 支配性的 $>$ 类的预测平均准确率;c) 用 A 记录预测的总平均准确率。此外,由于 ZDT6 中 Pareto 支配性类比例分布不平衡程度不够明显,故在设计有关与贝叶斯分类方法比较的实验时,对该函数不作比较。

表 1 记录了 NNC 和 BYS 对测试问题 POL 和 VTN1 的 Pareto 支配性各类平均预测准确率,表 2 记录了 NNC 和 BYS 对测试问题 POL 和 VTN1 的 d-Pareto 支配性各类平均预测准确率及总平均预测准确率,且表 1、2 中每一行分别对应测试问题 POL、VTN1。在表 1 中,NNC 对 POL 和 VTN1 的 Pareto 支配性各类平均预测准确率均能达到 80% 以上,而 BYS 对 Pareto 支配性各类间平均预测准确率极其不平衡,对样本分布平均比例少的类,BYS 的平均预测准确率仅能达到 20% ~ 30%。而在表 2 中,BYS 对 d-Pareto 支配性各类间平均预测准确率差距更大,对样本类分布平均比例少的类,得到的平均预测准确率竟不到 20%。由此可容易得出在 Pareto 支配性类比例分布不平衡的情况下,用最近邻分类方法预测多目标优化 Pareto 支配性和 d-Pareto 支配性平均准确率均优于基于类条件概率密度服从高斯分布的贝叶斯分类方法。

表 1 NNC 和 BYS 的 Pareto 支配性类平均预测准确率

样本的类分布 平均比例/%			NNC 类预测 平均预测准确率/%			BYS 类预测 平均预测准确率/%		
C_1	C_2	C_3	C_1	C_2	C_3	C_1	C_2	C_3
14.65	15.50	69.85	88.73	78.66	87.19	20.67	22.22	94.76
15.08	15.14	69.79	91.02	81.18	89.82	33.95	30.40	98.79

表 2 NNC 和 BYS 的 d-Pareto 支配性类平均预测准确率及总平均预测准确率

样本的类分布 平均比例/%			NNC 类预测 平均预测准确率/%			BYS 类预测 平均预测准确率/%		
C_1	C_2	C_3	w_1	w_2	A	w_1	w_2	A
15.06	15.12	69.83	95.72	79.27	92.55	97.92	17.87	89.26
15.10	15.00	69.80	97.12	81.20	95.03	99.90	16.76	89.87

表 3 记录了 NNC 对测试问题 POL、VTN1、ZDT6 的 Pareto 支配性预测及 d-Pareto 支配性预测的各类平均预测准确率及总平均预测准确率,表中的每一行分别对应测试函数 POL、VTN1、ZDT6。对 POL 和 VTN1 测试函数,尽管 NNC 在 Pareto 支配性预测及 d-Pareto 支配性预测上各类的平均预测准确率均能达到 80% 左右,但对 d-Pareto 支配性 w_1 类平均预测准确率及总平均预测准确率均高于对 Pareto 支配性预测相应的准确率。而对类比例分布较均衡和高维决策空间的测试问题 ZDT6,采用 NNC 对其进行 d-Pareto 支配性预测所获得的总平均准确率要远高于 Pareto 支配性预测的总平均准确率。因此,不难得出预测多目标优化 d-Pareto 支配性的准确率要高于预

测多目标优化 Pareto 支配性的准确率。

表 3 NNC 的 Pareto 支配性和 d-Pareto 支配性的类平均预测准确率及总平均预测准确率

样本的类分布 平均比例/%			预测 Pareto 支配性 平均预测准确率/%			预测 d-Pareto 支配性 平均预测准确率/%		
C_1	C_2	C_3	w_1	w_2	A	w_1	w_2	A
14.52	15.51	69.98	88.73	78.66	87.19	95.32	76.33	91.78
15.34	15.10	69.56	91.02	81.18	89.82	96.00	72.88	92.24
23.42	24.86	51.72	50.01	43.90	47.95	83.15	38.04	74.98

4 多目标优化 d-Pareto 支配性预测与 MOEAs 交互测试

为进一步验证具有低预测错误率的 d-Pareto 支配性预测与 MOEAs 交互利于算法的最终性能,本文对两个经典多目标优化测试问题 SCH ($n = 1, m = 2, [-10^5, 10^5]$) 和 FON ($n = 3, m = 2, \text{定义域}[-4, 4]$)^[21] 进行测试,比较了基于 d-Pareto 支配性预测的 MOEAs(DPMOEAs)与基于 Pareto 支配性预测的 MOEAs(PMOEAs)的性能指标 IGD^[22]。

实验中,基于支配性预测的 MOEAs 基本框架如下所示,算法均采用实数编码,交叉概率为 0.9,变异概率为 $1/n$ (n 为决策变量个数),交叉分布系数为 20,变异分布系数为 20,进化种群规模为 100,评价次数为 1 000,样本种群规模为 200 ($E_1 = 100, E_2 = 100$,可构造规模为 10 000 的样本集),每隔 10 代重构样本集,本文表中实验结果都是 30 次独立运行的数据统计平均值,而图则为随机抽取某次运行的结果。对测试函数 FON 和 SCH 进行测试的结果如图 2、3 所示。基于支配性预测的 MOEAs 基本框架如下:

a) 初始化规模大小为 $2N$ 样本种群 sample 及进化群体 pop = \emptyset , 设置进化总代数 GEN,当前进化代数 gen = 1 及其他相关参数。

b) 对 sample 进行精确的目标函数值评价,并采用相应的样本构造策略,形成规模为 N^2 的样本集 set 且对各样本赋上类标号 w ,从 sample 中随机选取 N 个个体初始化 pop,采用相应分层策略对 pop 进行分层。

c) 对 pop 进行进化操作(选择、交叉、变异),形成规模大小为 N 的子代群体 offSpring。

d) 合并 pop 和 offSpring,并记合并后的种群为 mixedPop,判断 $gen \% 10 = 0$? 若为真,令 sample = mixedPop,进行精确目标函数值评价及比较,对 mixedPop 分层并对 sample 所形成的样本集 set 赋上类标号 w ;否则,根据 Set 及其所对应的类标号,预测 mixedPop 个体间的支配性关系(d-Pareto 或 Pareto 支配性),并对 mixedPop 分层。

e) 根据环境选择策略及拥挤个体修剪算法,从 mixedPop 中选出 N 个优秀个体作为新一代进化群体 pop, $gen = gen + 1$ 。

f) 判断 $gen > GEN$? 若为真,结束算法,否则转 c)。

在图 2 和 3 中,十字表示 DPMOEAs 获得的近似 Pareto 前沿,圆圈表示 PMOEAs 获得的近似 Pareto 前沿,实线表示优化问题的真实 Pareto 前沿。为更清晰地对比实验结果,图 2、3 分别对比了 DPMOEAs 获得结果与真实 Pareto 前沿、PMOEAs 获得结果与真实 Pareto 前沿以及两种算法获得结果在同坐标系中与真实 Pareto 前沿。算法获得结果与真实 Pareto 前沿越逼近,覆盖越广,算法性能越优,反之亦然。对比图 2 和 3,在本实验条件下,DPMOEAs 在优化问题的寻优性能上要优于 PMOEAs。IGD 评价指标属于算法分布性和收敛性评价的综合

指标,其值越小,说明算法具有的分布性和收敛性越好,反之亦然。表 4 为基于支配性预测的 MOEAs 的 IGD 性能评价指标。对比表 4 中的数据,DPMOEAs 的性能指标 IGD 的数值要明显小于 PMOEAs 的性能指标数值,因此 DPMOEAs 所具有的收敛性和分布性均要优于 PMOEAs,同时也验证了具有低预测错误率的 d-Pareto 支配性预测与 MOEAs 交互利于 MOEAs 的最终性能。

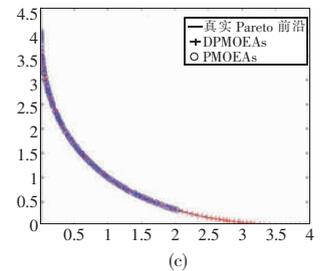
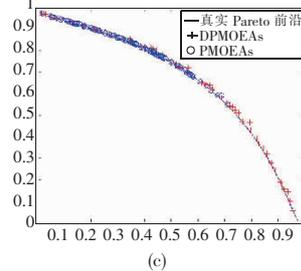
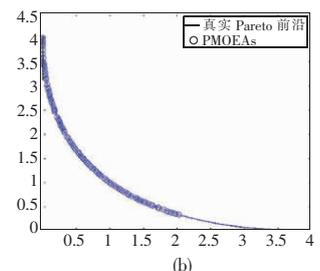
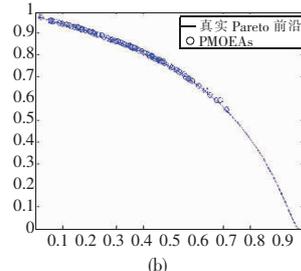
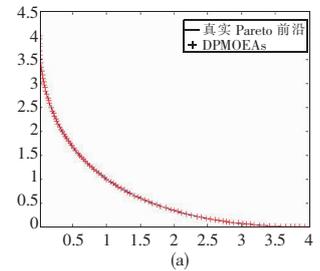
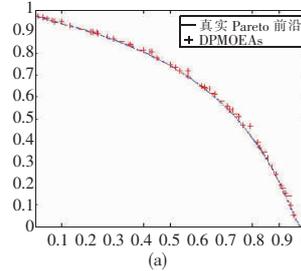


图 2 基于支配性预测模型的 MOEAs 优化 FON 函数

图 3 基于支配性预测模型的 MOEAs 优化 SCH 函数

表 4 基于支配性预测的 MOEAs 的 IGD 性能评价指标

Problem	DPMOEAs	PMOEAs
SCH	0.097 0	0.152 5
FON	0.062 1	0.132 7

5 结束语

针对昂贵多目标优化问题,采用预测多目标优化的 Pareto 支配性方法可从根本上缓解计算成本灾难问题,但现有的预测方法在预测精度上仍存在不足。为进一步提高预测精度,本文提出了多目标优化的 d-Pareto 支配性最近邻预测方法,理论及实验均证实了多目标优化 d-Pareto 支配性预测模型具有较高的预测精度。采用基于支配性预测的 MOEAs 对测试问题 SCH 和 FON 进行测试,仿真结果表明,多目标优化 d-Pareto 支配性预测与 MOEAs 交互作用具有较好的性能。但支配性预测与 MOEAs 交互作用仍处于探索阶段,如何有效地将预测模型嵌入 MOEAs 仍有待进一步深入研究。

参考文献:

[1] DEB K. Multi-objective optimization using evolutionary algorithms: an introduction, KanGAL Report Number 2011003 [R]. [S. l.]: Indian Institute of Technology Kanpur, 2011.

[2] ZHOU Ai-min, QU Bo-yang, LI Hui, et al. Multiobjective evolutionary algorithm; a survey of the state of the art [J]. Swarm and Evolutio-

- nary Computation, 2011, 1(1):32-49.
- [3] DEB K, PRATAP A, AGARWAL S, *et al.* A fast and elitist multi-objective genetic algorithm: NSGA-II [J]. *IEEE Trans on Evolutionary Computation*, 2002, 6(2):182-197.
- [4] ZITZLER E, LAUMANN S, THIELE L. SPEA2: improving the strength Pareto evolutionary algorithm [C]//Proc of Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems. Berlin: Springer-Verlag, 2002:95-100.
- [5] CORNE D W, KNOWLES J D, OATES M J. The Pareto envelope-based selection algorithm for multi-objective optimization [C]//Proc of Parallel Problem Solving from Nature-PPSN VI. 2000:839-848.
- [6] KNOWLES J D, CORNE D W. The Pareto archived evolutionary strategy: a new baseline algorithm for Pareto multiobjective optimization [C]//Proc of Congress on Evolutionary Computation. Piscataway, NJ: IEEE Press, 1999: 98-105.
- [7] NAIN P K S, DEB K. A multi-objective search and optimization procedure with successive approximate models, KanGAL Report 2004012 [R]. [S. l.]: Indian Institute of Technology Kanpur, 2004.
- [8] JIN Yao-chu, SENDOFF B. A systems approach to evolutionary multi-objective structural optimization and beyond [J]. *IEEE Computational Intelligence Magazine*, 2009, 4(3):62-76.
- [9] SHI L, RASHEED K. A survey of fitness approximation methods applied in evolutionary algorithms [C]//Proc of Computational Intelligence in Expensive Optimization Problems. 2010:3-28.
- [10] JIN Yao-chu. Surrogate-assisted evolutionary computation: recent advances and future challenges [J]. *Swarm and Evolutionary Computation*, 2011, 1(2):61-70.
- [11] LIM D, JIN Yao-chu, ONG Y S, *et al.* Generalizing surrogate-assisted evolutionary computation [J]. *IEEE Trans on Evolutionary Computation*, 2010, 14(3):329-355.
- [12] LIM D, ONG Y S, JIN Yao-chu, *et al.* A study on meta-modeling techniques, ensembles, and multi-surrogates in evolutionary computation [C]//Proc of the 9th Annual Conference on Genetic and Evolutionary Computation. London: ACM Press, 2007:1288-1295.
- [13] GUO Guan-qi, LI Wu, YANG Bo, *et al.* Predicting Pareto dominance in multi-objective optimization using pattern recognition [C]//Proc of the 2nd International Conference on Intelligent System Design and Engineering Application. 2012:456-459.
- [14] SCHAFFER J D. Multiple objective optimization with vector evaluated genetic algorithms [C]//Proc of the 1st International Conference Genetic Algorithms. New Jersey: Lawrence Erlbaum, 1987:93-100.
- [15] JENSEN M T. Reducing the run-time complexity of multiobjective EAs: the NSGA-II and other algorithm [J]. *IEEE Trans on Evolutionary Computation*, 2003, 7(5):503-515.
- [16] 郑金华, 史忠植, 谢勇. 基于聚类的快速多目标遗传算法 [J]. *计算研究与发展*, 2004, 41(7):1081-1087.
- [17] SERGIOS T, KONSTANTINOS K. Pattern recognition [M]. 4th ed. Beijing: Machine Press, 2010.
- [18] POLONI C. Hybrid GA for multi-objective aerodynamic shape optimization [C]//Proc of Genetic Algorithms in Engineering and Computer Science. New York: Wiley, 1997:397-414.
- [19] VIENNET R. Multi-criteria optimization using a genetic algorithm for determining a Pareto set [J]. *International Journal of Systems Science*, 1996, 27(2):255-260.
- [20] ZITZLER E, DEB K, THIELE L. Comparison of multi-objective evolutionary algorithm: empirical results [J]. *Evolutionary Computation*, 2000, 8(2):173-195.
- [21] FONSECA C M, FLEMING P J. Multi-objective optimization and multiple constraint handling with evolutionary algorithms—Pareto II: application example [J]. *IEEE Trans on Systems, Man, and Cybernetics: Part A: Systems and Humans*, 1998, 28:26-37.
- [22] BOSMAN P A N, THIERENS D. The balance between proximity and diversity in multi-objective evolutionary algorithms [J]. *IEEE Trans on Evolutionary Computation*, 2003, 7(2):174-188.

(上接第 3545 页)新用户由于没有打分信息或者有很少的打分信息(即不活跃用户),协同过滤无法为其产生推荐,这就是一直困扰推荐系统领域的冷启动问题^[16]。然而本文发现与传统协同过滤算法相比,考虑负相关性信息的协同过滤算法由于将负相关用户集成到推荐过程中,能大幅度提高对不活跃用户的推荐准确性,因此负相关性有助于解决推荐系统中的冷启动问题。

5 结束语

本文深入研究了负相关性对协同过滤算法的影响,提出了考虑负相关性信息的协同过滤算法,该算法分别选取正相关用户和负相关用户作为最近和最远邻居,然后使用参数调节最近邻居和最远邻居在推荐过程中的作用,最后根据预测出的评分产生推荐列表。MovieLens 实验表明负相关性可以同时提高推荐准确性和推荐列表多样性,说明负相关性有助于解决准确性和多样性两难问题。进一步分析发现,与活跃用户相比,负相关性能大幅度提高不活跃用户的推荐准确度。与传统协同过滤算法相比,本文算法对不活跃用户的 MAE 提高比例可以达到 3.01%,这表明负相关性有助于解决冷启动问题。

参考文献:

- [1] GOLDBERG D, NICHOLS D, OKI B M, *et al.* Using collaborative filtering to weave an information tapestry [J]. *Communications of the ACM*, 1992, 35(12):61-70.
- [2] ADOMAVICIUS G, TUZHILIN A. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions [J]. *IEEE Trans on Knowledge and Data Engineering*, 2005, 17(6):734-749.
- [3] 刘建国, 周涛, 汪秉宏. 个性化推荐系统的研究进展 [J]. *自然科学进展*, 2009, 19(1):1-15.
- [4] BREESE J S, HECKERMAN D, KADIE C. Empirical analysis of predictive algorithms for collaborative filtering [C]//Proc of the 14th Conference on Uncertainty in Artificial Intelligence. San Francisco: Morgan Kaufmann Publishers Inc, 1998:43-52.
- [5] 朱丽中, 徐秀娟, 刘宇. 基于项目和信任的协同过滤推荐算法 [J]. *计算机工程*, 2013, 39(1):58-63.
- [6] WANG Jing, YIN Jian. Enhancing accuracy of user-based collaborative filtering recommendation algorithm in social network [C]//Proc of the 3rd International Conference on System Science, Engineering Design and Manufacturing Informatization. 2012:142-145.
- [7] 邓爱林, 朱扬勇, 施伯乐. 基于项目评分预测的协同过滤推荐算法 [J]. *软件学报*, 2003, 14(9):1621-1628.
- [8] 孙小华, 陈洪, 孔繁胜. 在协同过滤中结合奇异值分解与最近邻方法 [J]. *计算机应用研究*, 2006, 23(9):206-208.
- [9] 石珂瑞, 刘建国, 郭强, 等. 有向相似性对协同过滤推荐系统的影响研究 [J]. *复杂系统与复杂性科学*, 2012, 9(3):46-49.
- [10] 邹永贵, 望靖, 刘兆宏, 等. 基于项目之间相似性的兴趣点推荐方法 [J]. *计算机应用研究*, 2012, 29(1):116-118.
- [11] 罗辛, 欧阳元新, 熊璋, 等. 通过相似度支持度优化基于 K 近邻的协同过滤算法 [J]. *计算机学报*, 2010, 33(8):1437-1445.
- [12] 黄创光, 印鉴, 汪静, 等. 不确定近邻的协同过滤推荐算法 [J]. *计算机学报*, 2010, 33(8):1369-1377.
- [13] 张尧, 冯玉强. 协同过滤推荐中基于用户分类的邻居选择方法 [J]. *计算机应用研究*, 2012, 29(11):4216-4219.
- [14] ZENG Wei, SHANG Ming-sheng, ZHANG Qian-ming, *et al.* Can dissimilar users contribute to accuracy and diversity of personalized recommendation [J]. *International Journal of Modern Physics C*, 2010, 21(10):1217-1227.
- [15] 刘建国, 周涛, 郭强, 等. 个性化推荐系统评价方法综述 [J]. *复杂系统与复杂性科学*, 2009, 6(3):1-10.
- [16] 周涛. 个性化推荐技术的十大挑战 [J]. *程序员*, 2012(6):107-111.