

文章编号: 1001-0920(2009)02-0170-06

自适应分区多代理模型交互式遗传算法

孙晓燕, 巩敦卫

(中国矿业大学 信息与电气工程学院, 江苏 徐州 221008)

摘要: 为提高交互式遗传算法的性能, 提出一种自适应分区多代理模型交互式遗传算法. 该算法基于关键维分割进化初期的搜索空间, 同时基于进化进程、逼近精度以及用户评价敏感度, 自适应地分割进化中后期的搜索空间. 在子空间上, 采用多类代理模型学习用户对进化个体评价, 并用于评价后续进化的部分或全部个体. 将该算法应用于服装进化设计系统, 实验结果表明, 算法在种群多样性、减轻用户疲劳及用户对优化结果满意度等方面均具有优越性.

关键词: 交互式遗传算法; 自适应; 分区; 多代理模型

中图分类号: TP20 **文献标识码:** A

Interactive genetic algorithms with multiple surrogate models based on adaptive space division

SUN Xiaoyan, GONG Dunwei

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221008, China. Correspondent: SUN Xiao-yan, E-mail: xysun78@126.com)

Abstract: An interactive genetic algorithm with multiple surrogate models based on adaptive space division is proposed to improve the performance of typical interactive genetic algorithms. The search space in the initial phrase is divided based on the key dimension. And the one in the posterior phrase is adaptively divided based on the progress of the evolution, the precision of approximation and the sensitivity of the user's evaluation. Multiple surrogate models built in these subspaces are adopted to learn a user's evaluation of individuals and applied to evaluate partial or all individuals in the subsequent evolution. The proposed algorithm is applied to a fashion evolutionary design system. The results show that the proposed algorithm is advantageous in maintaining the diversity of population, alleviating user fatigue, and the satisfactory degree of optimal solutions.

Key words: Interactive genetic algorithm; Adaptation; Space division; Multiple surrogate models

1 引言

传统的进化优化方法不能解决性能指标难以(或无法)显式表示的优化问题. 交互式遗传算法(IGAs)将传统的进化机制与人的智能评价相结合, 通过人给出进化个体的适应值, 可有效地解决上述问题. 该算法已在服装设计、音乐创作、图像检索、工业设计、机器人路径规划等领域得到了广泛应用^[1-3]. 但是, 人的疲劳问题导致进化种群的规模较小, 而且进化代数也较少, 这制约了该算法在复杂优化问题中的应用^[1]. 为此, 国内外提出了诸多改进方法. 其中, 利用已有数据, 构造人评价个体的适应度函数代理模型, 并在后续进化中, 代替人来评价部分

或全部个体, 是减轻人的疲劳、改进算法性能的有效方法之一^[4-7]. 然而, 采用哪些代理模型类, 如何获取生成代理模型的数据, 如何保证逼近精度, 以及如何利用代理模型等, 目前还没有成熟的结果.

针对交互式遗传算法代理模型构造问题, Biles 等^[4]采用神经网络预测进化个体适应值, 但没有给出神经网络预测和人的适应值评价之间的转换策略, 以及拟合效果的评价指标. 周勇等^[5]提出基于神经网络的个体适应值分阶段估计方法, 给出了神经网络预测与人的评价之间的转换策略以及神经网络学习效果的评价指标, 在一定程度上改善了适应值逼近精度. 但该算法在整个搜索空间中采用简单近

收稿日期: 2008-04-25; 修回日期: 2008-08-20.

基金项目: 国家自然科学基金项目(60775044); 教育部新世纪优秀人才支持计划项目(NCET-07-0802); 中国矿业大学青年基金项目(OC060994).

作者简介: 孙晓燕(1978—), 女, 江苏丰县人, 讲师, 硕士, 从事智能优化的研究; 巩敦卫(1970—), 男, 江苏铜山人, 教授, 博士生导师, 从事智能优化、软件测试等研究.

似模型估计个体适应值,仅适用于搜索空间较小且维数较低的情况.上述结果均是在整个搜索空间上采用一个代理模型逼近用户对进化个体的评价. Lee 等^[6]提出了稀疏适应度预测法,基于聚类思想,将种群分为若干子类,用子类里的一个个体的适应值预测相同子类里其他个体的适应值.该算法对空间进行了一定的分割,但没有考虑逼近精度变化,无法保证逼近性能.巩敦卫等^[7]研究了多近似模型交互式遗传算法,即依据一定的原则对搜索空间进行分割,在各分区利用神经网络建立适应值代理模型.相对于全局近似模型的方法,该算法在逼近性能上有了很大改善.但其没有考虑搜索空间随进化进程的动态分割以及生成近似模型的数据获取方法.

在交互式遗传算法中,不同进化时期搜索空间的特性不同,因此传统的在整个进化周期上采用同一模型逼近用户评价的适应度函数,将难以保证代理模型的逼近精度.对此,本文给出一种基于自适应分区的多代理模型算法.根据进化进程,对搜索空间进行自适应分割,在各子空间根据其特性建立多类代理模型,并进行在线更新.在进化过程中利用代理模型,代替人来评价全部或部分个体,从而减轻用户疲劳,或者在人评价相同数量个体的情况下,增加进化代数 and 种群规模,从而改进交互式遗传算法性能.

2 训练数据与测试数据的获取

考虑如下—类隐式性能指标优化问题:

$$\begin{cases} \max f(x), \\ x = (x_1, x_2, \dots, x_D) \quad S \subseteq R^D, \\ x_d \in [a_d, b_d], \quad d = 1, 2, \dots, D. \end{cases} \quad (1)$$

其中: $f(x)$ 为被优化的隐式性能指标, x 为 D 维决策变量, $[a_d, b_d]$ 为各维变量的取值范围.采用交互式遗传算法优化上述问题,决策变量采用实数编码,在不引起混淆的情况下,记交互式遗传算法进化种群中,相应的个体为 x ,其适应值为 $f(x)$.

交互式遗传算法进化 T 代后,保存进化过程中用户评价的个体及其适应值,设共有 N 组,记为 $\text{Data} = \{(x^i, f(x^i)), i = 1, 2, \dots, N\}$.将保存集中的数据分为两类,即训练集和测试集,分别用于代理模型的构造和模型逼近性能的测试.训练集的选择会极大地影响代理模型的逼近性能,一般而言,训练集数据分布性越好,得到的代理模型的泛化能力越强.由于对称拉丁方设计算法可得到分布性较好的数据^[8],本文基于对称拉丁方设计算法选择训练数据.其思想是,首先对每一维决策变量进行 m 等分;然后求取每一维等分空间的中点,选取 m 个这些中点的排列组合作为拉丁方采样点,选择保存集中与这些采样点最近的数据作为训练数据.

现考虑第 d 维变量的第 j 个等分空间,其中点值记为 c_d^j ,可表示为

$$c_d^j = a_d + \frac{(2j - 1)(b_d - a_d)}{2m},$$

$$d = 1, 2, \dots, D, \quad j = 1, 2, \dots, m.$$

对这些中点值进行排列组合,从中选取 m 组,可得到参考采样点集,不妨记为 SP,则 SP 可表示为

$$\text{SP} = \begin{bmatrix} C^1 \\ C^2 \\ \dots \\ C^m \end{bmatrix} = \begin{bmatrix} c_1^1, c_2^1, \dots, c_D^1 \\ c_1^2, c_2^2, \dots, c_D^2 \\ \dots \dots \dots \dots \\ c_1^m, c_2^m, \dots, c_D^m \end{bmatrix}.$$

于是,训练集可表示为

$$\text{TR} = \{(x^k, f(x^k)) \mid x^k = \arg \min_{j \in \{1, 2, \dots, N\}} d(C^j, x^j), i = 1, 2, \dots, m\}, \quad (2)$$

其中 $d(C^i, x^j) = |C^i - x^j|$. 容易看出,训练集 TR 包含 m 个数据,则保存集 Data 中剩余的 $N - m$ 个数据便构成了测试集.

M 的取值直接影响代理模型的逼近性能和算法的计算复杂性.若 m 值较大,即空间分割较精细,选择的训练数据数量也随之增加,代理模型逼近精度高,相应的计算复杂性高;反之,逼近精度低,计算复杂性低.为了保证代理模型具有一定的逼近精度,并与计算复杂性相平衡,训练数据数量可依据进化进程自适应地变化,但为保证模型精度,训练数据至少不能少于测试数据.因此,本文取 $m = \lfloor (t) N \rfloor$, $0.5 \leq (t) < 1$, 其中 $\lfloor \cdot \rfloor$ 表示向下取整.

3 搜索空间自适应分割

3.1 进化初期空间分割

在进化初期,用户对评价对象的认知比较粗糙,此时所需要的代理模型的逼近精度可以低一些,因此代理模型的数量可相对少一些.此外,代理模型数量的增加将提高计算复杂性,因此代理模型的数量应尽可能的少.另一方面,不同的决策变量对用户评价的影响是不同的,本文希望在对用户影响比较大的决策变量上,空间分割更细一些,这样的决策变量称为关键维.关键维的确定,既可依据用户的主观认知,也可以基于相关系数法.所谓相关系数法,就是将进化个体适应值具有最大相关性的决策变量作为关键维.

设第 t 代进化种群的规模为 $n(t)$,个体 $x^i(t)$ 适应值为 $f(x^i(t))$, $i = 1, 2, \dots, n(t)$,该种群在决策变量 x_d 对应的基因位取值为 $\tilde{x}_d^i(t) = (x_d^1(t), x_d^2(t), \dots, x_d^{n(t)}(t))^T$, $d = 1, 2, \dots, D$.记 x_d 与个体适应值间的相关系数为 (f, x_d, t) ,则 (f, x_d, t) 可表示为

$$(f, x_d, t) =$$

$$\frac{1}{n(t)} \sum_{i=1}^{n(t)} \frac{(\tilde{x}_d^i(t) - \bar{x}_d(t))(f(x^i(t)) - \bar{f}(t))}{(\tilde{x}_d(t))(f(x^i(t)))}. \quad (3)$$

其中

$$\bar{x}_d(t) = \frac{1}{n(t)} \sum_{i=1}^{n(t)} x_d^i(t), \bar{f}(t) = \frac{1}{n(t)} \sum_{i=1}^{n(t)} f(x^i(t)),$$

$$(\tilde{x}_d(t)) = \sqrt{\frac{1}{N(n(t) - 1)} \sum_{i=1}^{n(t)} (\tilde{x}_d^i(t) - \bar{x}_d(t))^2},$$

$$(f(x^p(t))) = \sqrt{\frac{1}{N(n(t) - 1)} \sum_{p=1}^{n(t)} (f(x^i(t)) - \bar{f}(t))^2}.$$

由于用户评价具有主观性,偏好具有一定的波动性,不可仅依据一次交互式遗传算法的进化结果确定关键维,而应取多次运行结果的 (f, x_d, t) 的均值作为选择依据.可直接选择保存集 Data 中的数据,计算各维决策变量与适应值间的相关系数平均值 $\bar{r}(f, x_d)$,即 $\bar{r}(f, x_d) = \frac{1}{T} \sum_{t=1}^T (f, x_d, t)$.则根据关键维的定义,使得平均相关系数最大的决策变量即为关键维,如下所示:

$$x_k = \arg \max_{d=1,2,\dots,D} (\bar{r}(f, x_d)). \quad (4)$$

进化初期空间分割方法:首先,在关键维方向上,采用对称拉丁方设计方法,将搜索空间等分为 m 份;然后,根据代理模型建立条件,检验空间分割是否可行.为了在各子空间上建立代理模型,各子空间范围内应有足够多的建模数据,否则合并相邻子空间.下面给出子空间分割是否合适的检验条件.

设关键维 x_k 的第 j 等分中点分量值为 $c_k^j, j = 1, 2, \dots, m$.该子空间上的训练集为 TR^j ,若 TR^j 包含的训练数据集不满足建模条件,则在 x_k 上合并第 j 和 $j + 1$ 部分,直至子空间上训练数据集满足建模条件.本文将在第 4 节给出代理模型建模时,对训练数据集的要求.

3.2 逼近精度

逼近精度是检验代理模型逼近用户评价适应度函数的主要尺度,可根据测试数据获得各模型的逼近精度.设将搜索空间 S 分割为 L 个子空间,记为 S_1, S_2, \dots, S_L ,第 l 子空间 S_l 上有 N_l 个测试数据,满足 $N_l \geq N - m$.对于测试数据集中的个体 x^i ,用户评价适应值为 $f(x^i)$,该子空间上的代理模型估计的适应值为 $\tilde{f}(x^i), i = 1, 2, \dots, N_l$,则逼近精度定义为

$$r_l = \frac{1}{N_l} \sum_{i=1}^{N_l} |f(x^i) - \tilde{f}(x^i)|. \quad (5)$$

若 $r_l \geq r_1$,则认为精度较高;若 $r_1 < r_l < r_2$,则认为精度可接受;若 $r_l > r_2$,则认为精度较低.其中

r_1, r_2 为反映逼近精度的阈值,其取值可根据实际问题选择常值或选为进化周期 t 的减函数.阈值的选择对算法搜索性能及计算复杂性影响较大,需根据实际问题调整.

3.3 搜索空间的自适应分割

随着进化的进行,搜索空间会发生变化.为了保证逼近性能,应动态分割搜索空间,并在相应子空间上更新代理模型.

3.3.1 评价敏感度

为了衡量用户评价适应度景象的崎岖程度,需考虑用户对个体评价的敏感程度.其思想是:关键维方向上,考查搜索到的最优个体与距其最近个体的适应值差异,若差异度较大,说明在关键维方向上,决策变量的微小变化会导致剧烈的适应值变化,则表明用户评价敏感度较高.

记第 t 代 S_l 子空间上的最优个体为 $x^b(t)$,其在关键维上的变化范围为 $[a_k^l(t), b_k^l(t)]$,该子空间内,用户评价的个体适应值的变化范围为 $[f_l^{\min}(t), f_l^{\max}(t)]$.计算最优个体 $x^b(t)$ 与 S_l 子空间上其他个体 $x^p(t)$ 在关键维上的距离 $d(x_k^b(t), x_k^p(t))$.选择 $x^p(t) = \arg \min_{p \neq b} d(x_k^b(t), x_k^p(t))$,且 $f_l(x^p(t)) = f_l(x^b(t))$ 的个体作为敏感度测量点,则用户评价敏感度定义为

$$DE_l(t) = \frac{(f_l(x^b) - f_l(x^p)) / (f_l^{\max}(t) - f_l^{\min}(t))}{|x_k^b - x_k^p| / (b_k^l(t) - a_k^l(t))}. \quad (6)$$

若 $DE_l(t) > 1$,则该子空间区域内,用户评价较敏感,称之为敏感区域;若 $DE_l(t) \leq 1$,则认为该区域适应度景象较平滑.

3.3.2 搜索空间自适应分割策略

调整策略为:在较优个体所在子空间内,模型应具有较高的逼近精度,且该子空间测试数据具有较高的可信度,子空间跨度应较小.为保持种群多样性,避免算法在进化中后期陷入局部最优,还需保持其他子空间,如含较差个体子空间的特性.在不同的区域,用户评价敏感度也不同.在高敏感度区域(即适应度景象较崎岖),搜索范围应较小,逼近精度应较高;在低敏感度区域则可适当扩大搜索区域,降低逼近精度要求.综上,应考虑最优个体所在的区域、用户评价敏感度及逼近精度,自适应地调整搜索空间的分割,并在新的子空间内更新代理模型.

记第 t 代 $S_l(t)$ 子空间的训练集为 TR^l ,依据测试集数据,可得当前代理模型的逼近精度为 $r_l(t)$,基于该区域内的用户评价敏感度和逼近模型精度及调整策略,可给出如下空间自适应分割及代理模型的更新方法.记调整后的子空间为 $S_l(t + 1)$.



1) 若 $(DE_i(t) > 1 \quad i(t) < i_1) \quad (DE_i(t) < 1 \quad i(t) > i_2)$, 则 $S_i(t+1) = S_i(t)$, 且不更新代理模型.

2) 若 $(DE_i(t) < 1 \quad i(t) > i_2)$, 则 $S_i(t+1) = S_i(t)$, 利用 TR^i 更新代理模型.

3) 若 $(DE_i(t) < 1 \quad i(t) < i_1)$, 则 $S_i(t+1) = S_i(t) e^{i(t) / DE_i(t)}$, 且不更新代理模型.

4) 若 $(DE_i(t) > 1 \quad i(t) > i_1)$, 则 $S_i(t+1) = S_i(t) / DE_i(t) e^{i(t)}$, 利用 TR^i 更新代理模型.

注 1 在空间自适应分割过程中, 空间的扩充会影响原有的相邻子空间, 为保证空间的全划分, 相邻子空间要相应缩小. 当空间缩小后, 若相邻子空间不改变, 则会出现“空白区域”, 为保证空间分割的完整性, 空白区域内代理模型应与原有代理模型相同.

4 代理模型的选择及其应用

构造代理模型的常用方法主要有多项式回归^[8,9]、RBF 网络^[10,11]、高斯过程^[12,13]、支持向量机^[14]等. 在上述方法中, 大量实验研究表明, RBF 神经网络和高斯过程性能最优, 其次是多项式回归^[15]. 但由于高斯过程参数随着维数增长呈指数级增加, 计算量往往非常大. 此外, 若在整个搜索空间上仅采用一类代理模型, 在解决高维问题时, 易误导进化种群收敛至非最优解. 为保证逼近性能, 应考虑在不同搜索空间上采用不同类型的近似模型. 综上, 本文考虑两类代理模型: 多项式函数和 RBF 神经网络. 关于这两类代理模型的学习方法, 可分别参见文献^[16]和^[17], 这里不再赘述.

4.1 代理模型类选择的依据

采用二次多项式进行适应度函数的逼近, 计算复杂度相对较小, 但为保证模型参数解的存在性和唯一性, 建模数据需满足如下要求^[8]:

$$\text{rank}(X_b) = m \text{ 且 } m \leq (D + 1)(D + 2) / 2. \quad (7)$$

其中: $X_b = [X^1, X^2, \dots, X^m]^T$, $X^i = [1, x_1^i, x_2^i, \dots, x_1^i, (x_1^i)^2, (x_1^i x_2^i), \dots, (x_1^i)^2]$, $i = 1, 2, \dots, m$.

RBF 神经网络具有极强的非线性局部逼近能力, 且对训练数据及其数量没有特殊要求. 因此, 根据各子空间中点的分布及数量, 建立不同的近似模型. 若第 l 个子空间中训练数据点的分布满足式(7)的要求, 则选择二次多项式构造近似模型; 否则, 选择 RBF 网络构造近似模型.

4.2 代理模型的应用

在各子空间上建立了合适的代理模型后, 根据进化进程的不同需求, 确定其应用方式. 若用户未疲劳, 为改善交互式遗传算法的性能, 增加种群多样性, 根据子空间范围的变化, 动态改变种群规模. 若子空间范围较大, 则在该空间范围内增加较多的个

体; 否则, 增加较少个体或保持不变. 考虑 $S_i(t)$ 子空间, 为减少计算量, 根据关键维的变化范围, 动态地调整种群规模. 该子空间上种群规模为

$$n_i(\text{new}) = \max \left\{ n_i(\text{old}), \left\lceil \frac{b_k^i(t) - a_k^i(t)}{b_k^i(t+1) - a_k^i(t+1)} \right\rceil \cdot W_i \right\}. \quad (8)$$

其中: W_i 为 $S_i(t)$ 子空间的搜索粒度^[18], $\lceil \cdot \rceil$ 表示向上取整. 新增个体在该子空间内均匀随机生成.

新增个体由代理模型评价, 并与用户评价个体参与竞争, 进行遗传操作; 然后将所有个体中的较优个体反馈给用户. 即扩大种群规模后, 用户评价对象是经过代理模型“筛选”后的较优个体. 保留用户评价数据, 以进一步检验模型精度, 并依据用户评价敏感度及代理模型逼近精度, 改变子空间, 更新代理模型. 若用户已疲劳, 则由代理模型代替用户评价, 获得个体适应值, 直至满足进化终止条件.

5 算法流程

算法实现可分为两个阶段: 第 1 阶段为数据保存阶段; 第 2 阶段为代理模型构造及其在交互式遗传算法中的使用阶段. 算法流程如图 1 所示.

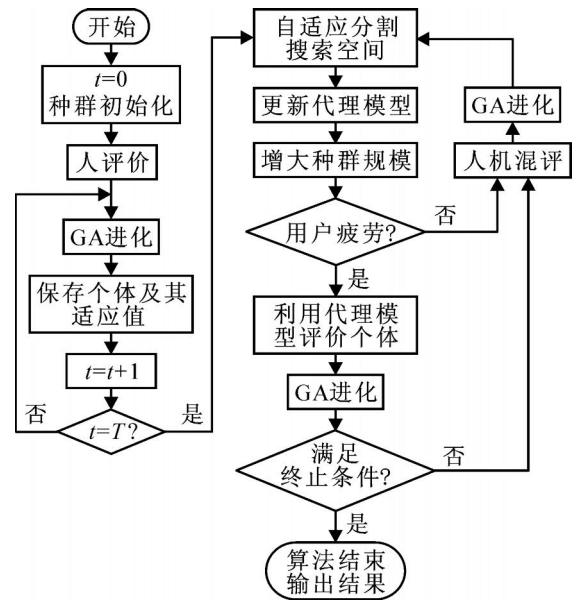


图 1 算法流程图

6 实例验证

为说明本文算法性能, 将其应用于服装进化优化设计系统. 服装优化设计的目的是通过优化给出满足用户要求的服装. 不同人具有不同的偏好, 无法用显式函数描述该类优化问题, 因此传统的遗传算法难以奏效. 而由人直接参与评价的交互式遗传算法恰恰适合. 下面将本文算法——自适应多代理交互式遗传算法 (AMSIGA) 与传统交互式遗传算法 (IGA) 及全局采用一个 RBF 神经网络代理模型的

交互式遗传算法(GSIGA)进行比较。

6.1 实验背景及参数设置

Kim等^[19,20]将交互式遗传算法应用于服装设计问题,建立了基于交互式遗传算法的服装优化设计系统。本文的服装优化设计系统借鉴了Kim的服装设计模型,主要考虑裙装的优化设计。服装由上衣款式、裙子款式及其颜色搭配组合而成,对各部分采用二进制编码形成进化个体,以图片形式提交给用户进行评价。上衣和裙子的款式各32套,分别采用5位二进制串表示,颜色采用RGB值组合上色,各值分别采用3位二进制码表示,则解的搜索空间大小为 $2^5 \times 2^5 \times 2^9 \times 2^9 = 2^{28}$ 。服装进化设计系统即根据用户偏好,从上述解空间中选择用户“最满意的设计方案”呈现给用户。

受计算机交互界面的影响,显示给用户的个体数量,即初始种群规模一般较小,本文设置为 $N = 8$ 。3类算法进化优化过程均采用遗传算法,操作算子均采用规模为2的锦标赛选择,2点交叉,单点变异,交叉变异概率由用户给出。各类算法进化终止代数均为200,在两类基于代理的交互式遗传算法中,当用户评价3代后即开始利用存储数据建立代理模型。若用户评价若干代后不再参与评价,完全由机器完成,则当连续3代不再出现新个体时,算法结束。经多次调试后本文算法其他参数设置如下:训练数

据个数 $m = (t) N = \frac{1}{1 + e^{-0.5(t-1)}} N$, 训练数据所占比例逐渐增加;逼近精度阈值 $\epsilon_1 = e^{-0.5(t-1)} + 0.3$, $\epsilon_2 = e^{-0.6(t-1)} + 0.2$,即认为在10代左右时,用户认知较清晰,逼近精度基本不再变化;搜索粒度 $W_i = 2$ 。此外,关键维为服装颜色空间。

6.2 界面设计

实验平台采用Visual Basic 6.0编程。界面设计如图2所示,包括8幅服装图片,“初始化”等若干控制按钮及当前最优个体显示部分,适应度取值范围为(0,100],用户通过拖动滚动条给出评价。在IGA中,若用户疲劳,不愿再评价,则选择“退出”,



图2 服装设计优化系统界面

算法终止。在其余两类算法中,若用户疲劳,则选择“自动设计”按钮,算法转入代理模型构造及基于代理模型的优化阶段。若用户再次参与,则用户选择“打分评价”按钮,由用户继续评价机器提交的个体,其余个体则由代理模型评价。若用户认为已找到满意解,则选择“结束”,退出优化。

6.3 结果及性能分析

比较3种算法在种群规模、种群多样性变化、用户疲劳度及用户对最终结果的满意度等方面的差异,各类算法运行20次,取平均值。由于GSIGA不对空间进行分割,当建立了全局代理模型后,将种群规模增大至200。

3类算法种群规模变化如图3所示,为清晰起见,仅给出进化前30代结果。由于在IGA中受交互界面限制,种群规模固定为8,不发生变化。在GSIGA中,当开始由代理模型参与时,直接增大种群规模至200,直至算法结束。在本文算法中,种群规模从第3代(即开始构建代理模型时)开始发生变化。根据式(8),当空间大小发生变化时,种群规模作相应调整。从图3可以看出,本文算法的种群规模不断变化,说明各子空间的大小在进化过程中有所变化,即空间分割是动态变化的。




图3 种群规模变化

此外,图3中A和B两段曲线增长趋势比其他部分缓慢,其对应进化代数分别是7.2~10.1和13.8~19.8之间,原因是在20次运行过程中,用户基本上在7~10代左右时感觉有些疲劳,选择了“暂停”,而完全由机器参与评价,此时,空间不再发生变化,因而种群规模变化较小。而当用户稍微休息后再次重新参与进化,则空间分割继续发生变化,从而导致种群规模再次发生较大变化,而用户再次疲劳后将后续优化交给机器完成,直至找到满意解,终止算法。

种群多样性的变化,由每代出现新个体所占比率的变化来衡量,结果如图4所示,也仅给出前20代结果。从图4可以看出,采用IGA,在进化到8代左右时,算法已收敛。此时有两种可能性:一是用户已找到满意解,算法真正收敛;二是用户已疲劳,即

使得到的解不十分满意,也不愿再继续评价.而 GSIGA 算法中,当种群规模急剧增大到 200 时,多样性也大大提高,但随着进化进行,种群多样性呈整体下降趋势,即使有所起伏,也维持较短时间.采用本文算法,由于种群规模随着进化进行而动态变化,且当种群规模增大时随机产生部分个体,种群多样性较好.在用户不参与评价的若干代中,种群多样性有所减小,但随着代理模型的再次投入使用,种群多样性再次增加,这样有利于扩大搜索空间,使得提供给用户更多隐含满意解的几率大大增加.




图 4 种群多样性变化

用户疲劳度由用户实际参与评价代数衡量,用户疲劳度及满意度结果见表 1.由表 1 可以看出,在传统交互式遗传算法中,用户参与评价次数最少,但满意度也最低,其根本原因是用户在评价了 8 代左右时已相当疲劳,即使对得到的解的满意度不高,也选择终止优化.采用 GSIGA 和本文算法时,当用户疲劳时,可退出评价过程,进行短暂休息后再次参与评价,因此相对评价次数较多,相应的对优化解的满意度较高.在构造代理模型的过程中,同时根据搜索空间的变化动态调整种群规模,从而使得种群多样性维持较好,使用户获得满意解的概率增加,因此采用本文算法获得的最终优化解满意度最高.

表 1 用户疲劳度及满意度

算 法	用户评价次数	满意度 / %
IGA	8.9	67.2
GSIGA	14.3	75.3
AMSIGA	12.1	89.6

7 结 论

交互式遗传算法由于受用户评价疲劳影响,种群规模和进化时间均较小,使得算法搜索性能难以保证.对此,本文给出了基于空间自适应分割、建立多类代理模型的适应度近似方法,以有效减轻用户疲劳,改进算法性能.在定义用户评价敏感度的同时,结合模型逼近精度和搜索性能,给出了搜索空间自适应分割方法;根据已有大量工作实验结果,选择了二次多项式及 RBF 神经网络构造代理模型,并给出代理模型使用原则;最后采用服装进化优化系统验证了算法的有效性.结果表明,本文算法在保持种

群多样性、减轻用户疲劳及用户对优化结果的满意度等方面均具有优越性,可有效改进交互式遗传算法的性能,从而可进一步扩大其在更复杂领域的应用.其他建模数据选择方法及算法复杂性分析尚需进一步深入研究.

参考文献(References)

- [1] Takagi H. Interactive evolutionary computation: Fusion of the capabilities of EC optimization and human evaluation[J]. Proc of the IEEE, 2001, 89(9): 1275-1296.
- [2] Cho S B. Towards creative evolutionary systems with interactive genetic algorithm[J]. Applied Intelligence, 2002, 16(2): 129-138.
- [3] Tokumaru M, Muranaka N, Imanishi S. Virtual stylist project: Examination of adapting clothing search system to user's subjectivity with interactive genetic algorithms [C]. Proc of the 2003 Congress on Evolutionary Computation. Canberra: IEEE, 2003: 1036-1043.
- [4] Biles J A, Anderson P G, Loggi L W. Neural network fitness functions for a musical IGA [C]. Int ICSC Symposia on Intelligent Industrial Automation and Soft Computing. Reading, 1996: B39-44.
- [5] 周勇, 巩敦卫, 郝国生, 等. 交互式遗传算法基于 NN 的个体适应度分阶段估计[J]. 控制与决策, 2005, 20(2): 234-236.
(Zhou Y, Gong D W, Hao G S, et al. Neural network based phase estimation of individual fitness in interactive genetic algorithm[J]. Control and Decision, 2005, 20(2): 234-236.)
- [6] Lee Joo-Young, Cho Sung-Bae. Sparse fitness evaluation for reducing user burden in interactive algorithm[C]. Proc of 1999 IEEE Int Fuzzy Systems Conf. Korea:IEEE, 1999: 998-1003.
- [7] 巩敦卫, 周勇, 郭一楠, 基于多近似模型的交互式遗传算法[J]. 控制理论与应用, 2008, 25(3): 434-438.
(Gong D W, Zhou Y, Guo Y N. Interactive genetic algorithms based on multiple approximation models[J]. Control Theory and Applications, 2008, 25(3): 434-438.)
- [8] Rommel G R, Christine A Shoemaker. Local function approximation in evolutionary algorithms for the optimization of costly functions [J]. IEEE Trans on Evolutionary Computation, 2004, 8(5): 490-505.
- [9] Zhou Z, Ong Y S, Nguyen M H. A study on polynomial regression and gaussian process global surrogate model in hierarchical surrogate-assisted evolutionary algorithm [C]. IEEE Congress on Evolutionary Computation. Edinburgh, 2005: 2832-2839.

(下转第 180 页)

一般控制系统的实时性要求. 该算法对冗余机器人逆运动学求解及实时控制具有一定的借鉴作用.

参考文献(References)

- [1] Marnni G, Kim J, Yuh J, et al. Algorithmic singularities avoidance in task-priority based controller for redundant manipulators [C]. IEEE Int Conf on Intelligent Robots and Systems. Las Vegas, 2003: 3570-3574.
- [2] Zhang Y N, Wang J. Obstacle avoidance of redundant manipulators using a dual neural network[C]. IEEE Int Conf on Robotics and Automation. Taipei, 2003: 2747-2752.
- [3] Dubey R V, Euler J A, Babcock S M. An efficient gradient optimization scheme for a seven-degree-of-freedom redundant robot with spherical wrist[C]. IEEE Int Conf on Robotics and Automation. Philadelphia, 1988, 1: 28-36.
- [4] 祖迪, 吴镇炜, 谈大龙. 一种冗余机器人逆运动学求解的有效方法[J]. 机械工程学报, 2005, 41(6): 71-75.
(Zu D, Wu Z W, Tan D L. Efficient inverse kinematic solution for redundant manipulators[J]. Chinese J of Mechanical Engineering, 2005, 41(6): 71-75.)
- [5] Chen W H, Yang M M, Yu S Q. A hybrid algorithm for the kinematic control of redundant manipulators[C]. IEEE Int Conf on Systems, Man and Cybernetics. 2004: 4438-4443.
- [6] Lee K K, Buss M. Redundancy resolution with multiple criteria[C]. IEEE Int Conf on Intelligent Robots and Systems. Beijing, 2006: 598-603.
- [7] 孙奎, 谢宗武, 刘宏, 等. 梯度投影法多性能准则优化的应用研究[J]. 控制与决策, 2007, 22(12): 1433-1436.
(Sun K, Xie Z W, Liu H, et al. Application of gradient projection method based on multiple performance criteria optimization[J]. Control and decision, 2007, 22(12): 1433-1436.)
- [8] 王连圭, 马保离. 冗余机器人系统的自运动控制[J]. 控制与决策, 2003, 18(2): 199-202.
(Wang L G, Ma B L. Self-motion Control of redundant manipulators[J]. Control and Decision, 2003, 18(2): 199-202.)
- [9] Zhao J W, Sun L N, Du Z J. Self-motion analysis on a redundant robot with a parallel/series hybrid configuration [C]. IEEE Int Conf on Control, Automation, Robotics and Vision. Singapore, 2006: 2239-2244.
- [10] Fu Y L, Pan B, Li K, et al. Laparoscopic robot design and kinematic validation [C]. IEEE Int Conf on Robotics and Biomimetics. Kunming, 2006: 1426-1431.
- [10] Björkman M, Holmström K. Global optimization of costly nonconvex functions using radial basis functions [J]. Optimization of Engineering, 2000, 1(4): 373-397.
- [11] Gutmann H M. Radial basis function methods for global optimization [D]. Cambridge: University of Cambridge, 2001.
- [12] Jones D. A taxonomy of global optimization methods based on response surfaces [J]. J of Global Optimization, 2001, 21(4): 345-383.
- [13] Jones D R, Schonlau M, Welch W J. Efficient global optimization of expensive black-box functions[J]. J of Global Optimization, 1998, 13(4): 455-492.
- [14] An J L, Wang Z O, Yang Q X. A SVM function approximation approach with good performances in interpolation and extrapolation[C]. Proc of the 4th Int Conf on Machine Learning and Cybernetics. Guangzhou, 2005: 1648-1653.
- [15] Paenke I, Branke J, Jin Y C. Efficient search for robust solutions by means of evolutionary algorithms and fitness approximation [J]. IEEE Trans on Evolutionary Computation, 2006, 10(4): 405-420.
- [16] Ong Y S, Nair P B, Lum K Y. Max-min surrogate-assisted evolutionary algorithm for robust design [J]. IEEE Trans on Evolutionary Computation, 2006, 10(4): 392-404.
- [17] Zhou Z Z, Ong Y S, Nair P B, et al. Combining global and local surrogate models to accelerate evolutionary optimization [J]. IEEE Trans on Systems, Man and Cybernetics—Part C, 2007, 37(1): 66-76.
- [18] 孙晓燕, 巩敦卫. 变种群规模合作型协同进化遗传算法及其在优化中的应用 [J]. 控制与决策, 2004, 19(12): 1437-1440.
(Sun X Y, Gong D W. Varying population size cooperative coevolutionary genetic algorithm and its application in optimization [J]. Control and Decision, 2004, 19(12): 1437-1440.)
- [19] Kim H, Cho S. Development of an IGA-based fashion design aid system with domain specific knowledge [C]. Proc of IEEE SMC '99. Tokyo, 1999: 663-668.
- [20] Kim H, Cho S. Application of interactive genetic algorithm to fashion design [J]. Engineering Applications of Artificial Intelligence, 2000, 13(6): 635-644.

(上接第 175 页)