

文章编号: 1000-8152(2011)05-0610-09

# 基于半监督学习的变种群规模区间适应值交互式遗传算法

孙晓燕, 任洁, 巩敦卫

(中国矿业大学 信息与电气工程学院, 江苏 徐州 221116)

**摘要:** 为了减轻用户疲劳并增强算法的搜索性能, 本文在变种群规模交互式遗传算法的基础上引入协同训练半监督学习方法, 提出基于半监督学习的变种群规模区间适应值交互式遗传算法。根据对大规模种群的聚类结果, 给出标记样本和未标记样本的获取方法; 结合半监督协同学习器逼近误差的改变, 提出高可信度未标记样本的选择策略; 采用半监督协同学习机制训练两个径向基函数(RBF)神经网络, 构造精度高泛化能力强的代理模型; 在进化过程中, 利用代理模型估计大种群规模进化个体适应值, 并根据估计偏差更新代理模型。算法的理论分析及其在服装进化设计系统中的应用结果说明了算法的有效性。

**关键词:** 交互式遗传算法; 区间适应值; 半监督学习; 代理模型; 变种群规模

中图分类号: TP273 文献标识码: A

## Interval-fitness interactive genetic algorithms with varying population size based on semi-supervised learning

SUN Xiao-yan, REN Jie, GONG Dun-wei

(School of Information and Electrical Engineering, China University of Mining & Technology,  
Xuzhou Jiangsu 221116, China)

**Abstract:** In order to alleviate user fatigue and improve the performances of interactive genetic algorithms (IGAs) in exploration, we present the interval-fitness interactive genetic algorithms with varying population size based on a co-training semi-supervised learning(CSSL). According to the clustering results of a large population, we develop the strategy for selecting unlabeled samples and labeled samples. Based on the approximation precision of two co-training learners, an efficient strategy for selecting high reliable unlabeled samples for labeling is given. Then, the CSSL mechanism is employed to train two radial basis function(RBF) neural networks in order to establish the surrogate model with high precision and good generalization ability. In the subsequent evolution, the surrogate model is used to estimate the fitness of an individual; in turn, the surrogate model is updated based on its estimation error. The proposed algorithm is analyzed and applied to a fashion evolutionary design system. The experimental results show its efficacy.

**Key words:** interactive genetic algorithms; interval fitness; semi-supervised learning; surrogate model; varying population size

## 1 引言(Introduction)

交互式遗传算法于20世纪80年代中期提出, 是解决一类难以甚至无法用明确定义的函数表示的优化问题的可行方法<sup>[1]</sup>。它将传统的进化机制与用户的智能评价相结合, 由用户通过人-机交互直接给出进化个体适应值, 代替难以显式表达的适应度函数。目前, 该算法已成功地应用于人脸识别、服装设计、乐曲创作、语音处理、音乐检索、机器人等领域<sup>[2~7]</sup>。

与传统的遗传算法相比, 交互式遗传算法最显著的特点是由用户评价进化个体适应值。频繁的人-机交互将导致用户疲劳, 使得传统的交互式遗传算法一般只能采用小种群规模和少进化代数, 这极大地

影响了算法的搜索性能, 限制了该算法在更多复杂优化问题中的应用。针对该问题, Lee提出基于 $K$ -均值聚类的大种群规模交互式遗传算法<sup>[8]</sup>。虽然该方法可以在不增加用户疲劳的条件下增强算法的搜索能力, 但算法中的关键参数 $K$ 的取值需要预先给定, 会极大地影响算法的性能。Yuan根据个体相似度是否大于设定的分类阈值对种群分类, 其分类数目不需要预先设定, 并且随着进化进程动态改变<sup>[9]</sup>。但是在该算法中, 分类的相似度阈值需预先设定, 恒定的相似度阈值会极大地影响算法的性能。针对该问题, 本文提出了一种变种群规模交互式遗传算法, 动态变化相似度阈值, 以有效改善分类效果。同时, 根据

收稿日期: 2009-12-20; 收修改稿日期: 2010-06-08。

基金项目: 国家自然科学基金资助项目(60775044); 教育部新世纪优秀人才支持计划资助项目(NCET-07-0802); 江苏省自然科学基金资助项目(BK2010186); 江苏省博士后基金资助项目(1001019C)。

进化过程中的优势个体信息动态调整种群规模。该算法有效增强了交互式遗传算法的搜索能力, 并加快了种群的收敛速度, 有效减轻了用户疲劳<sup>[10]</sup>。

然而, 在基于聚类的方法中, 用户评价的代表个体适应值均采用精确数表示, 难以体现交互式遗传算法中用户评价的不确定性<sup>[11]</sup>。此外, 在基于聚类的大种群规模交互式遗传算法中, 对大量用户未评价个体适应值的估计非常粗糙, 会误导搜索方向, 影响算法性能。因此, 有必要考虑其他的进化个体适应值估计策略。

基于用户评价的进化个体及其适应值构造用户认知代理模型, 进而可代替用户估计大量进化个体适应值。Biles和周勇等采用人工神经网络学习用户的智能评价, 并在适当时机用神经网络评价进化个体, 减少用户评价进化个体的数量<sup>[12, 13]</sup>。此外, Llora等基于支持向量机评价进化个体<sup>[14]</sup>。Ecemis等利用径向基函数(RBF)学习用户的评价, 并对金融市场建模<sup>[15]</sup>。本文通过构造两个RBF神经网络, 建立进化个体区间适应值交互式遗传算法代理模型<sup>[16]</sup>。但是, 上述研究成果都是在小种群规模的情况下, 利用监督学习机制构造代理模型, 为了获得满意的模型精度, 首先需要多次运行交互式遗传算法, 由用户评价大量的进化个体, 以获取训练数据, 这无疑会增加用户的疲劳。那么, 在大种群规模情况下, 目前基于监督学习机制构造代理模型, 进行个体适应值估计的策略不再适用, 需引入新的机器学习方法。

在大种群规模交互式遗传算法中, 需解决的一个关键问题是: 如何在不增加用户评价负担情况下, 利用少量用户评价的个体和大量未评价的个体构造精度高泛化能力强的代理模型。而近年来引起广泛关注的半监督学习方法(semi-supervised learning, SSL)恰好可以解决该问题。半监督学习是一种介于监督学习和无监督学习之间的一类机器学习方法, 学习样本包括已标记数据和未标记数据。该方法利用少量的已标记数据训练初始学习模型, 进而用大量未标记数据改进初始模型的性能, 最终达到精确学习的目的。

因此, 本文在文献[10]的基础上, 考虑进化个体适应值为区间数的情况, 引入半监督学习方法, 构造用户认知的代理模型, 估计大量用户未评价的个体, 在不增加甚至减少用户疲劳的基础上, 研究基于半监督学习的变种群规模区间适应值交互式遗传算法。

在已有的半监督学习方法中, 协同训练算法简单直观, 在很多领域得到了成功应用, 因此, 本文采用基于协同训练的半监督学习策略。已有的关于协同训练半监督学习的研究成果, 都是针对静态数据分类或回归的<sup>[17]</sup>, 而交互式遗传算法中的数据随着进

化进程动态变化, 代理模型需动态更新, 因此, 需结合交互式遗传算法的特性, 设计高效的半监督学习方法, 以减小模型更新的计算复杂性。

本文算法思想如下: 采用变种群规模进化方法, 在初始代中用户评价每代的类中心个体, 给出区间适应值, 这些类中心个体作为已标记样本, 类中其余未评价个体作为未标记样本; 基于少量的已标记样本, 根据分类结果和流形假设设计批可信样本选择方法, 并基于该方法, 利用半监督学习构造代理模型; 在后续进化过程中, 利用满足精度要求的代理模型估计大种群规模的进化个体适应值, 同时, 用户每代选择极少量个体进行适应值修正, 以更新标记样本集; 在代理模型精度不满足要求时, 利用更新后的标记样本集和未标记样本集更新代理模型。

## 2 相关研究工作(Related work)

考虑如下一类优化问题:

$$\begin{cases} \max f(x), \\ \text{s.t. } x = (x_1, x_2, \dots, x_I) \in S, \\ S = g^1 \times g^2 \times \dots \times g^I. \end{cases} \quad (1)$$

其中:  $f(x)$ 是被优化的隐式性能指标,  $x$ 是 $I$ 维整数决策变量, 有 $x_j \in g_j (j = 1, 2, \dots, I)$ ,  $g_j$ 是第 $j$ 个变量的定义域,  $S$ 是搜索空间。在不引起混淆的情况下, 记相应的进化个体及搜索空间分别为 $x$ 和 $S$ 。

为了提高交互式遗传算法的搜索性能, 并减轻用户疲劳, 本文在文献[10]中提出了变种群规模交互式遗传算法。根据进化个体相似性, 对大规模进化种群聚类, 用户采用精确数评价类中心个体适应值, 基于该中心个体适应值, 估计同类内其余个体适应值。保留进化过程中优势个体信息, 提取建筑块信息, 利用该信息动态调整进化种群规模。该算法加快了算法的收敛速度, 在一定程度上减轻了用户疲劳。

但是, 用户评价的类中心个体适应值采用精确数表示, 难以体现交互式遗传算法中用户认知的不确定性, 因此, 有必要考虑进化个体适应值为不确定数的情况, 如区间数。此外, 基于一个类中心个体适应值估计大量未评价个体适应值精度较低。鉴于此, 本文在文献[10]的基础上, 进一步研究进化个体区间适应值变种群规模交互式遗传算法。

针对式(1)所示优化问题, 在变种群规模交互式遗传算法中, 根据基因意义单元的相似性对进化个体聚类, 记类中心为 $c_1(t), c_2(t), \dots, c_{N_c}(t)$ , 其中 $N_c$ 为分类数。根据文献[12]进化个体区间适应值表示方法, 本文类中心个体的适应值采用区间数表示, 记为 $f(c_1(t)), f(c_2(t)), \dots, f(c_{N_c}(t))$ , 有

$$f(c_k(t)) = [\underline{f}(c_k(t)), \bar{f}(c_k(t))], \quad (2)$$

其中:  $k = 1, 2, \dots, N_c$ ,  $\underline{f}(c_k(t))$ 和 $\bar{f}(c_k(t))$ 分别表

示用户对类中心进化个体 $c_k(t)$ 评价的下限和上限。

本文的贡献主要在于两个方面:一是考虑了用户认知的不确定性,进化个体适应值采用区间数表示;二是改变了个体适应值估计策略,采用半监督学习,根据用户评价的少量类中心个体的适应值构造高精度代理模型,代替用户评价进化个体适应值,以提高进化个体适应值估计精度。下面将重点介绍基于半监督学习的区间适应值代理模型构造和应用。

### 3 基于协同训练半监督学习的代理模型构造和应用(Obtaining surrogate model with cotraining SSL and its application)

利用半监督学习构造用户认知代理模型,需解决如下4个方面关键问题:用于半监督学习的标记样本和未标记样本的选择策略、半监督学习中高可信未标记样本的确定方法、代理模型的训练和应用以及代理模型的更新。前两个方面是结合交互式遗传算法特性,提高已有半监督学习的计算效率;后两个方面是将半监督学习用于交互式遗传算法中,提高算法性能。

#### 3.1 标记样本和未标记样本的选择(Selection of labeled and unlabeled samples)

半监督学习的训练数据包括标记样本和未标记样本,标记样本的选择会极大地影响学习器的性能,而已有研究成果一般都是采用随机选择的方法,从数据集中选择少部分样本由用户标记。本文将基于文献[10]的聚类原理,结合交互式遗传算法特性,给出标记样本和未标记样本的选择机制。

首先,考虑初始大规模种群中,利用半监督学习构造初始用户认知模型时训练样本的选择。设种群为 $P(0) = \{x_1, x_2, \dots, x_{N_1}\}$ ,其中 $N_1$ 为种群规模。采用文献[10]的策略,根据进化个体基因意义单元的相似性,对 $P(0)$ 聚类,类中心记为 $C(0) = \{c_1(0), c_2(0), \dots, c_{N_c}(0)\}$ ,将这些类中心个体提交给用户评价,用户对 $c_k(0)$ 评价值为 $f(c_k(0)) = [f(c_k(0)), \bar{f}(c_k(0))] (k = 1, 2, \dots, N_c)$ ,则初始标记样本集合为 $L(0) = \{(c_k(0), f(c_k(0))) | k = 1, 2, \dots, N_c\}$ ,未标记样本集合为 $U(0) = P(0) \setminus C(0)$ 。基于 $L(0)$ 和 $U(0)$ ,采用协同训练半监督学习方法,构造用户初始认知代理模型。当模型满足精度要求时,在后续进化过程中,利用该模型代替用户评价大规模种群中进化个体适应值。

随着进化的进行,用户认知不断变化,且半监督学习作用的样本集也在动态变化,代理模型精度难以满足要求,需进行动态更新。要更新模型,关键是更新训练样本集,即 $L(t)$ 和 $U(t)$ ,相应的策略将在第3.3节给出。

#### 3.2 高可信未标记样本的选择策略(Selection strategy of unlabeled samples with high reliability)

在协同训练半监督学习算法中,一个关键的问题是如何识别和选择可信度高的未标记样本进行标记,并利用其训练学习器,提高模型精度。*Zhou*基于加入未标记样本后对模型精度的影响,给出了可信样本的选择方法<sup>[17]</sup>。但由于每次只挑选一个最高可信度的样本进行标记,计算复杂性较大。本文仍采用其算法思想,基于半监督回归的流形假设和交互式遗传算法种群的聚类结果,提出批可信样本的选择策略,以提高协同训练半监督学习的效率。

算法思想是:采用文献[10]方法,对进化种群聚类,利用学习器估计每一类中所有未评价个体的适应值,然后,将该类个体及其估计值添加到该学习器的标记样本集中,重新训练该学习器,比较重新训练前后学习器在用户评价样本集上的均方误差的变化,则使得模型精度提高最多的那类数据为可信度最高的数据,将其添加到另一个学习器的标记样本集合中,并将其从未标记样本集合中删除。利用更新后的标记样本更新学习器。重复这一过程,直至模型满足精度要求或未标记数据集为空。为便于说明,首先给出学习器结构及其性能衡量准则。

本文进化个体适应值为区间数,利用协同训练半监督学习算法,构造用户认知代理模型,即是对区间数进行回归。根据文献[17]的研究成果,为了保证协同训练算法的有效性,需选择两个不同的回归器,如结构或者参数不同。RBF神经网络具有好的全局和局部逼近性能,训练方法快速且易于实现,因此,这里选用两个不同结构的RBF神经网络作为回归器,对区间数进行回归,记为 $h_1$ 和 $h_2$ 。这里区间数由区间上限和下限两个数确定,那么,为了拟合该区间数,每个RBF网络有两个输出,分别逼近区间数的上限和下限。

当 $h_1$ 和 $h_2$ 逼近性能满足要求后,可利用其输出构造代理模型,这里首先给出回归器性能的衡量方法。为便于说明,分别记 $h_1$ 和 $h_2$ 的训练样本集为 $L_1(t)$ 和 $L_2(t)$ ,其规模记为 $|L_1(t)|$ 和 $|L_2(t)|$ ,其中: $L_i(t) = \{(c_k^i(t), f(c_k^i(t))) | k = 1, 2, \dots, |L_i(t)|\}$ 。对于样本 $c_k^i$ ,学习器的输出记为 $\hat{f}_i(c_k^i(t))$ 和 $\hat{\bar{f}}_i(c_k^i(t)) (i = 1, 2)$ 。为了衡量回归器的性能,定义如式(3)所示的均方误差:

$$e_i = \frac{1}{2|L_i(t)|} \sqrt{\sum_{k=1}^{|L_i(t)|} (\underline{e}_i^2(c_k^i(t)) + \bar{e}_i^2(c_k^i(t))), \quad (3)}$$

其中: $i = 1, 2$ ,  $\underline{e}_i(c_k(t)) = (\hat{f}_i(c_k(t)) - \underline{f}(c_k(t)), \bar{e}_i(c_k(t)) = \hat{\bar{f}}_i(c_k(t)) - \bar{f}(c_k(t))$ 。当 $e_i$ 比较小时,说明

第*i*个学习器的拟合精度较高, 逼近性能较好.

基于上述性能准则, 本文的高可信样本选择策略如下: 记第*j*类用户未评价的个体集合为  $U_j = \{x_k^j\}$ , 则未标记样本集合为  $U = \bigcup_{j=1}^{N_c} U_j$ . 对于  $U_j$  中的个体  $x_k^j$ ,

两个学习器的估计值为  $\hat{f}_i(x_k^j) = [\hat{f}_i(x_k^j), \hat{\bar{f}}_i(x_k^j)]$ . 将  $\{(x_k^j, \hat{f}_i(x_k^j)) | k = 1, 2, \dots, |U_j|\}$  添加到  $L_i(t)$  中, 重新训练  $h_i$ , 记重新训练后的学习器为  $h'_i$ . 利用式(4)计算  $h_i$  和  $h'_i$  对于用户评价个体的均方误差的变化:

$$\Delta_i(U_j) = e_i - e'_i, \quad i = 1, 2, \quad (4)$$

其中  $e_i$  和  $e'_i$  采用式(3)计算.

若  $\Delta_1(U_j) > 0$ , 则表明在  $h_1$  的训练样本中加入  $U_j$  类非标记样本后  $h_1$  的精度有所提高; 同理, 若  $\Delta_2(U_j) > 0$ , 则表明在  $h_2$  的训练样本中加入  $U_j$  类非标记样本后  $h_2$  的精度有所提高. 选择使得  $\Delta_1(U_j)$  ( $\Delta_2(U_j)$ ) 最大的一类未标记样本及其在  $h_1$  ( $h_2$ ) 上的估计值, 作为可信样本添加到  $L_2(t)$  ( $L_1(t)$ ) 中, 并将其从  $U$  中删除. 利用更新后的  $L_1(t)$  和  $L_2(t)$  更新  $h_1$  和  $h_2$ , 重复上述过程, 直至模型满足精度要求或者  $U = \emptyset$ .

当上述过程结束后, 利用  $h_1$  和  $h_2$  估计所有未评价个体适应值, 对个体  $x_k \in U$ , 取  $h_1$  和  $h_2$  估计均值作为其适应值, 如式(5)所示:

$$\begin{aligned} \hat{f}(x_k) &= \frac{\hat{f}_1(x_k) + \hat{f}_2(x_k)}{2} = \\ &[\frac{\hat{f}_1(x_k) + \hat{\bar{f}}_1(x_k)}{2}, \frac{\hat{f}_1(x_k) + \hat{\bar{f}}_2(x_k)}{2}], \end{aligned} \quad (5)$$

### 3.3 代理模型的应用和更新(Application and updates of surrogate model)

对初始进化种群进行遗传操作, 生成新种群, 然后利用式(5)估计所有个体适应值. 由于该代理模型仅仅依据用户一开始评价的极少数个体获得, 而用户认知又是动态变化的, 因此, 为了避免估计值与用户认知相差过大, 用户仍需参与后续进化过程, 但只需选择极少部分估计适应值偏离其偏好的个体进行评价即可, 且为了跟踪用户偏好的变化, 根据用户新评价的数据动态更新代理模型. 本文需要解决两个问题, 一是何时更新代理模型; 二是用哪些数据更新代理模型.

首先, 仍采用文献[10]的策略, 对进化种群进行聚类, 并将类中心及其估计适应值呈现给用户, 用户浏览所有个体后, 若个体的估计适应值偏离其偏好, 则修正这些个体的适应值. 设用户每代修正  $Q$  个个体的适应值, 记被修正的类中心个体为  $c_r(t)$  ( $r = 1, 2, \dots, Q$ ), 修正后的适应值为  $f(c_r(t)) = [\underline{f}(c_r(t)), \bar{f}(c_r(t))]$ . 当用户对进化个体的修正值与代理模型估计的适应值差别较大时, 说明代理模型的估计偏

离了用户的认知, 不再满足逼近精度要求, 需更新该代理模型. 即当式(6)满足时, 更新代理模型:

$$\frac{1}{Q} \sqrt{\sum_{r=1}^Q (\underline{f}(c_r(t)) - \hat{f}(c_r(t)))^2 + (\bar{f}(c_r(t)) - \hat{\bar{f}}(c_r(t)))^2} > f^0, \quad (6)$$

其中  $f^0$  为更新阈值.

由于用户在每代中都对少量个体的适应值进行了修正, 这些个体及其适应值代表了用户的最新认知, 应充分利用这些数据. 因此, 本文利用这些数据来更新标记样本, 即

$L(t) = L(t-1) \cup \{(c_r(t), f(c_r(t))) | r = 1, 2, \dots, Q\}$ , 进而更新代理模型. 假设进化至  $T$  代时式(6)满足, 需更新代理模型, 则此时标记样本集合为  $L(T)$ , 当前代未评价个体构成未标记样本集  $U(T)$ , 基于  $L(T)$  和  $U(T)$ , 采用半监督学习策略更新代理模型.

## 4 算法性能分析及实现(Performance analysis and implementation)

本文在文献[10]的基础上, 引入半监督学习, 构造用户认知代理模型, 利用该模型估计大规模种群进化个体适应值, 目的是获得比监督学习更好的代理模型, 增强算法的搜索性能, 并有效减轻用户疲劳. 本文与文献[16], 即基于监督学习的区间适应值神经网络代理模型构建算法(individuals' interval fitness with surrogate models, IIFSM), 以及文献[10]的变种群规模交互式遗传算法(IGAs with variational population size, VPS)进行比较, 说明本文算法(简记为VPS-SSL)的性能.

首先, 考虑在相同的用户评价负担下, 即用户评价相同数量的进化个体数量下, 本文算法和IIFSM算法代理模型的精度. 显然, 在相同的标记样本训练数据集作用下, 半监督学习的机制将使得本文代理模型的精度大大提高, 详见文献[17]说明, 这里不再赘述.

其次, 关于用户评价疲劳, 为便于说明, 本文算法和VPS算法均不考虑变种群规模策略, 比较在相同的进化代数下, 用户参与评价的进化个体数. 记相同的进化代数为  $T_g$ , 本文算法用户参与评价的进化个体数为  $N_{SSL}^U$ , VPS 算法为  $N_{VPS}^U$ . 那么, 采用本文算法有  $N_{SSL}^U = N_c(0) + T_g Q$ , 采用VPS算法有  $N_{VPS}^U = \sum_{t=0}^{T_g} N_c(t)$ , 由于  $N_c(0)$  相同, 而  $N_c(t) \geq Q$ , 因此,  $N_{SSL}^U \leq N_{VPS}^U$ , 即本文算法可减轻用户评价负担.

进一步的, 本文考虑在相同的用户评价负担下, 即用户评价相同的进化个体数量条件下, 三类算法的搜索性能. 不失一般性, 假设算法搜索到的个体都是互异的. 记用户评价的总进化个体数为  $N_U$ , 本文算法总进化代数为  $T_{SSL}$ , 搜索到的互异进化个体数

为 $N_{SSL}$ . 根据本文算法思想, 有 $T_{SSL} = \frac{N_U - N_c(0)}{Q} + 1$ , 搜索到的总进化个体数为 $N_{SSL} = N_1 T_{SSL}$ ; 对于VPS算法, 记其总进化代数为 $T_{VPS}$ , 搜索到的进化个体数为 $N_{VPS}$ . 根据文献[10]算法思想, 则有

$$\sum_{t=1}^{T_{VPS}} N_c(t) = \sum_{t=1}^{T_{SSL}} Q = N_U - N_c(0).$$

由于 $N_c(t) > Q$ , 可知,  $T_{VPS} \leq T_{SSL}$ , 则其搜索到的总进化个体数 $N_{VPS} = N_1 T_{VPS}$ 不多于本文算法. 而在实际问题中,  $N_c(t)$ 均大于 $Q$ , 因此,  $T_{VPS} < T_{SSL}$ . 同理, 分析IIFSM搜索到的互异进化个体数, 根据文献[16]算法思想, 本文假设用户每代参与评价 $Q$ 个个体, 则其总的进化代数与 $T_{SSL}$ 相同, 记该算法进化种群规模为 $N_{IIFSM}$ , 则算法搜索到的总的进化个体数为 $N_{IIFSM} = N_{IIFSM} T_{SSL}$ , 这里有 $N_{IIFSM} = N_c(0)$ , 由于 $N_c(0) \ll N_1$ , 因此 $N_{IIFSM} \ll N_{SSL}$ .

综上所述, 与VPS和IIFSM算法相比, 采用本文算法, 可有效提高代理模型精度, 减轻用户疲劳, 并增强算法搜索性能.

算法实现步骤如下:

**Step 1**  $t = 1$ , 确定操作参数, 随机初始化进化种群;

**Step 2** 对初始种群聚类, 用户评价类中心进化个体, 并给出适应值, 获取标记样本集 $L(0)$ 和未标记样本集 $U(0)$ ;

**Step 3** 利用 $L(t)$ 训练RBF回归器 $h_1, h_2$ ;

**Step 4** 根据3.2节方法, 分别计算未标记样本类的可信度, 选择高可信度的未标记样本类, 加入对方的标记样本中, 并从未标记样本集中删除, 再次训练回归器, 重复该过程, 直到 $U(t) = \emptyset$ ;

**Step 5** 综合两个回归器的结果, 得到所有未评价个体适应值的估计值;

**Step 6** 利用变种群规模进化方法生成新种群;

**Step 7** 利用代理模型评价所有个体适应值, 用户评价修正 $Q$ 个进化个体适应值, 若找到满意解, 则转Step 8; 否则更新, 若式(6)满足, 转Step 3; 否则转Step 6;

**Step 8** 算法结束, 输出满意解.

## 5 在服装进化设计系统中的应用(Application in fashion evolutionary design system)

### 5.1 背景描述(Background)

服装设计极富个性, 不同的人对服装的品味不同, 因此在服装进化设计中无法通过定义明确的适

应度函数来评价一件服装的优劣, 而交互式遗传算法恰好可以胜任, 因此该类优化问题已成为交互式遗传算法的典型验证平台. 首先, 为了验证本文算法(VPS-SSL)采用半监督学习的合理性和有效性, 将其应用于服装进化设计系统中, 并将其与基于监督学习构造代理模型的进化个体区间适应值交互式遗传算法(IIFSM)<sup>[16]</sup>进行比较; 其次, 为了说明本文算法在搜索和减轻用户疲劳方面的性能, 在找到用户满意解的条件下, 将本文算法与进化个体区间适应值的神经网络代理模型(IIFSM)、变种群规模交互式遗传算法(VPS)<sup>[10]</sup>分别进行比较. 为了尽可能的消除偶然因素的影响, 每组实验均独立运行20次, 统计20次实验结果的均值和方差, 并计算每次实验数据和均值之间的偏差, 结果以图形形式给出, 其中, 每次实验的偏差用与 $y$ 轴平行的直线段表示, 则直线段越长, 表示该次实验数据偏离均值程度越大.

### 5.2 参数设置(Parameters setting)

本文中3种算法选用相同的遗传操作参数, 交叉概率为0.6, 变异概率为0.02, 联赛选择规模为2; 进化个体区间适应值的下限为0, 上限为1000; VPS-SSL和VPS算法初始种群规模为200, 每代呈现给用户的个体数根据文献[10]算法确定; IIFSM种群规模为10, 即每代呈现给用户的进化个体数为10. 由于优化对象为女式裙装, 由上衣款式、裙子款式及各自颜色搭配组合而成, 上衣款式和裙子款式各有32套, 各部分颜色各有16种, 则总的搜索空间为 $32 \times 32 \times 16 \times 16 = 262144$ . 本文算法中 $Q = 2$ , 考虑计算复杂性和代理模型精度的平衡, 设置更新阈值 $f^0 = 150$ (即当估计误差大于0.15时, 更新代理模型); 两个RBF回归器的选择采用MATLAB中自带的newrb函数进行建立, 通过多次实验, 两个回归器取相同的训练误差0.05, 扩展系数分别取0.3和0.6来保证两个回归器的差异性.

### 5.3 操作界面与个体评价(Interface and individual evaluation)

本文算法操作界面如图1所示, 包括3个主要部分: 左边为统计信息区域, 包括用户评价个体数、进化代数以及用户评价耗时, 左下方是当前最优个体及其适应值; 界面的下方是相关命令按钮, 包括初始化、进化控制按钮等; 其余部分为用户评价区域, 包括10个进化个体的表现型, 即组合而成的服装, 用户通过滚动条对不同的进化个体打分. 分值为一个区间, 第1个滚动条为分值的下限, 第2个滚动条为上限.

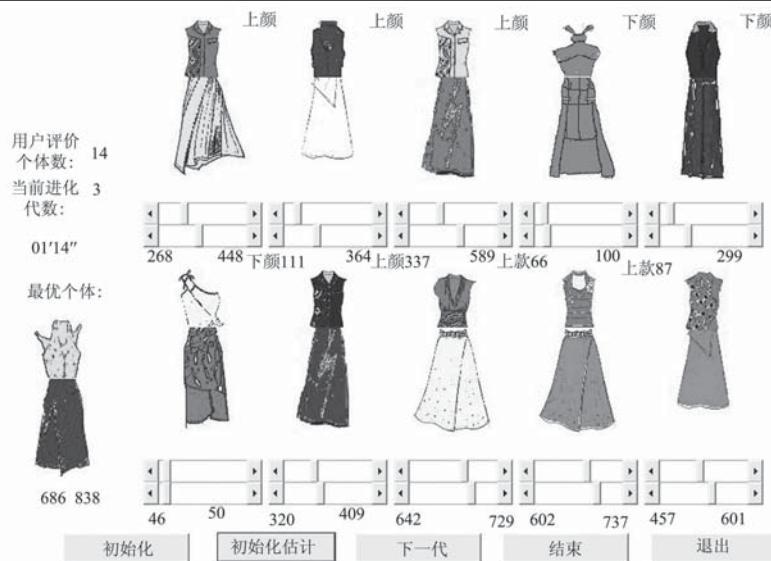


图1 操作界面

Fig. 1 Evolutionary interface

操作过程为: 单击“初始化”按钮, 系统自动生成大种群规模初始进化种群, 并将聚类后类中心个体的表现型提交给用户。用户根据偏好评价这些进化个体后, 单击“初始化估计”按钮, 开始进行半监督学习, 构建代理模型, 并利用代理模型对初始种群未评价的个体进行适应值估计。值得注意的是, 这个按钮只在初始代和更新时处于激活状态。然后, 单击“下一代”按钮, 种群进行遗传操作, 生成子代种群, 并且代理模型自动对子种群适应值进行估计, 将下一代的类中心个体及其适应值呈现给用户, 用户选择两个个体进行适应值修正。重复上述过程, 直至找到满意的进化个体, 用户选择“退出”按钮, 获得如图2所示的最终优化结果。

图2 优化结果  
Fig. 2 Optimized result

#### 5.4 实验结果与分析(Experimental results and analysis)

本文算法是在基于聚类的变种群规模交互式遗传算法的基础上进一步考虑用户评价的不确

定性, 采用区间数表示进化个体适应值, 引入半监督学习机制构造用户认知的代理模型, 并结合交互式遗传算法的特性, 提出半监督学习的新的可信样本的选择策略, 其目的是希望获得精度高泛化能力强的代理模型, 在不增加甚至减小用户评价负担的情况下, 构建具有大种群规模的交互式遗传算法, 改进传统小种群规模交互式遗传算法的搜索性能。因此, 本文从两个方面说明本文算法的性能, 一是与IIFSM进行比较, 考虑在用户评价相同的进化个体数下, 两类算法所构造的代理模型的精度, 以及在获取相同的代理模型精度情况下, 用户参与评价的个体数, 以说明半监督学习策略和可信样本选择策略的可行性; 二是与VPS和IIFSM算法进行比较, 说明本文算法在减轻用户疲劳以及增强算法搜索能力方面的有效性。

首先, 在用户评价相同进化个体数的情况下, 这里设为50, 比较IIFSM与本文算法所构造代理模型的训练误差, 本文算法代理模型的误差取两个学习器误差的均值。误差越小, 则说明代理模型精度越高。20次实验的对比结果如图3所示, 其中, 点虚线为本文算法, 实线为IIFSM算法, 与纵轴平行的直线段表示每次实验数据与均值的距离。

从图3可以看出, 在相同的用户评价负担下, 20次实验中, 采用本文算法构造代理模型时, 其拟合精度仅有5次略高于IIFSM, 其余均大大低于IIFSM。考虑20次实验的均值和方差, 采用本文的训练算法, 学习器平均拟合误差为0.0180, 20次实验的方差为0.0043, IIFSM算法的学习器平均拟合误差为0.0276, 20次实验的方差为0.0102。显然,

本文算法平均误差比IIFSM降低了约35%, 而方差仅为为其 $1/3$ . 进一步的, 本文采用 $t$ 测试法, 检验两种方法获得代理模型精度是否存在显著性差异, 当设定显著性差异水平为10%时,  $|t| = 28.6 > t_{1-\frac{0.05}{2}(20-1)} = 2.1$ , 即两者差异性显著, 说明基于半监督学习和本文提出的可信样本选择策略可以有效提高代理模型的逼近性能.

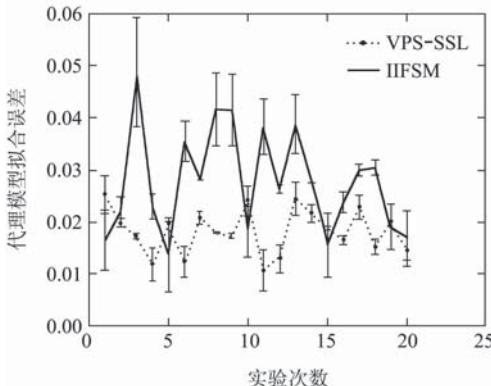


图3 相同用户评价个体数下代理模型拟合误差

Fig. 3 Fitting errors of surrogate model under the same number of individuals evaluated by the user

然后, 在获得相同精度代理模型的情况下, 比较VPS-SSL和IIFSM两类算法所需用户评价个体数的差异, 即用户评价负担的差异. 由于两种方法构造的代理模型精度难以达到绝对的一致, 所以这里定义相同的精度条件为: 两类模型训练误差均大约为0.03, 且利用本文算法构造的代理模型拟合误差小于或等于IIFSM的代理模型拟合误差(即要求本文算法代理模型精度更高). 20次实验结果如图4所示, 其中点虚线为本文算法结果, 实线为IIFSM算法结果.

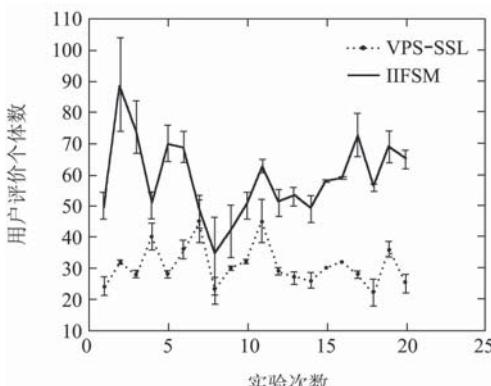


图4 相同拟合误差下用户评价个体数

Fig. 4 The number of individuals evaluated by the user under the same fitting error

从图4可以看出, 在20次实验过程中, 采用本文算法, 用户评价的进化个体数均少于IIFM. 对于本文算法, 在平均拟合误差为0.0227情况下, 用

户评价的进化个体总数平均为30.90, 方差为6.61; 在IIFSM算法中, 在平均拟合误差为0.0261(大于本文拟合误差)情况下, 用户评价的进化个体总数平均为58.65, 方差为12.99. 这说明在得到相同精度的代理模型情况下, 利用本文算法可以减少用户评价个体数, 从而减轻用户疲劳.

综上所述, 与采用监督学习构造代理模型的交互式遗传算法相比, 采用半监督学习和本文提出的可信样本选择策略, 可以在不增加甚至减少用户评价负担的情况下获得满足精度要求的代理模型, 说明了本文算法的可行性.

再次, 在每次找到固定优化目标, 这里为如图2所示用户满意服装的前提条件下, 比较本文算法与VPS, IIFSM在用户评价个体数、用户评价耗时和进化代数3个方面的差异, 以说明本文算法在减轻用户疲劳方面的性能, 结果如图5(a)(b)(c)和表1所示. 在图5中, 点虚线表示本文算法, 实线表示IIFSM算法, 点实线表示VPS算法.

从图5可以看出, 采用本文算法, 在20次实验中, 反映用户疲劳的两个指标, 即用户评价个体数和耗时均明显小于VPS, 进化代数略高于VPS, 此外, 本文算法的数据偏差变化幅度亦较小.

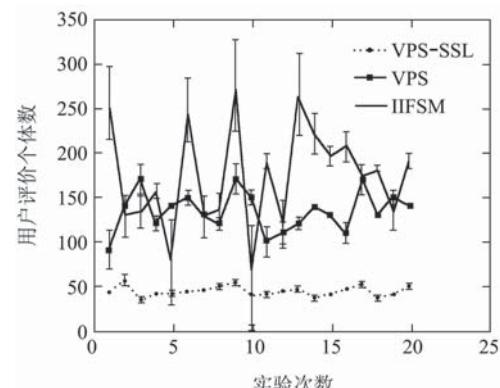


图5(a) 用户评价个体数

Fig. 5(a) The number of individuals evaluated by the user

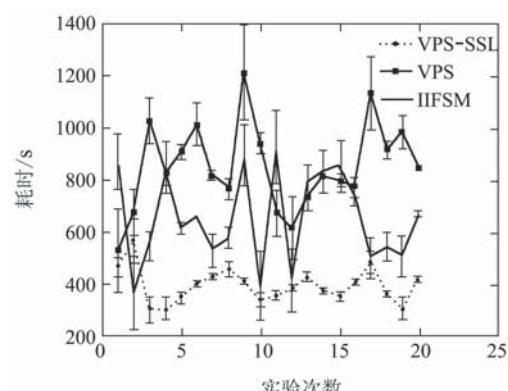


图5(b) 用户评价耗时

Fig. 5(b) Time-consuming of the user evaluation

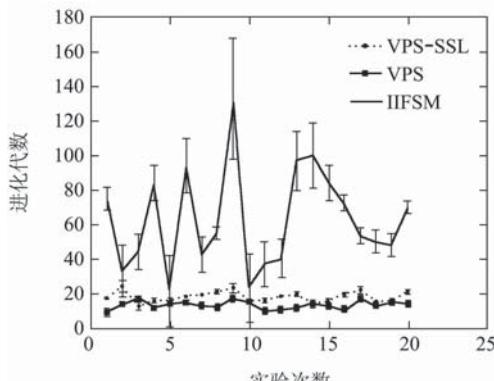


图 5(c) 进化代数

Fig. 5(c) Evolutionary generations

根据表1, 从所需用户评价的进化个体平均数量上看, 采用本文算法, 该值为43.90; 采用VPS算法, 该值为134.00, 约本文算法的3倍; 采用IIFSM算法, 该值为174.15, 约本文算法的4倍。这些数据说明, 在找到相同满意解的条件下, 采用本文算法可以大大减少用户评价的进化个体数量, 从而有效减轻用户评价疲劳。主要原因在于, 利用半监督学习训练用户认知的代理模型, 避免了VPS算法中认为类中心为该类最优个体的假设, 从而有效抑制了适应值估计偏差对进化搜索的误导作用, 所以, 在用户评价相对少量进化个体的情况下可以找到满意解。从20次实验结果的方差来看, 本文算法方差为6.21; VPS方差为22.57, 是本文算法的3.5倍; IIFSM方差为60.67, 几乎是本文算法的10倍。方差数据表明, 本文算法的稳定性较好。

表 1 用户评价疲劳统计结果

Table 1 Statistical results of user fatigue

算法	用户评价个体数	耗时/s	进化代数
VPS-SSL	43.90	394.70	17.95
均值	VPS	134.00	849.00
IIFSM	174.15	654.30	62.75
VPS-SSL	6.21	66.65	3.10
方差	VPS	22.57	171.29
IIFSM	60.67	179.52	29.35

从用户评价耗时上看, 本文算法的用户评价耗时平均为394.7 s, 方差为66.65; 采用VPS算法, 其用户评价耗时为849.00 s, 方差为171.29, 都是本文算法的2倍; 采用IIFSM算法, 其用户评价耗时为654.30 s, 为本文算法的1.5倍多, 方差为179.52, 约为本文算法的3倍。原因在于, 用户采用VPS-SSL方法, 在找到目标解的情况下需要用户评价的个体数较少, 而且用户给出一个区间适应值的耗时, 要小于给出一个精确适应值的耗时, 因此, 与其他

两种算法相比, 用户评价耗时大大减小, 这也说明本文算法可有效减轻用户疲劳。

从进化代数上看, 本文算法的进化代数平均为17.95, 略大于VPS的13.40, 其方差也略大, 这主要是提高代理模型估计精度时需要额外的计算代价, 但结合用户评价进化个体数来看, 这并没有增加用户的评价负担。但是, 与IIFSM算法相比, 其所需进化代数为62.75, 方差为29.35, 均远大于本文算法。原因在于, 采用半监督学习构造用户认知代理模型, 大大提高了传统的基于监督学习的模型精度, 在一定程度上减弱了基于代理模型的适应值估计对搜索造成的误导。

综上所述, 采用本文算法构造代理模型, 可以改善VPS和IIFSM的不足, 有效减小用户的评价负担, 减轻用户疲劳, 与第4节理论分析结论一致; 从统计方差结果看, 本文算法稳定性亦较好。

最后, 同样在找到如图2所示优化目标的条件下, 本文把VPS-SSL与IIFSM进行比较, 从搜索到的互异个体数方面说明本文算法的搜索性能, 结果如图6所示, 其中点虚线表示本文算法, 实线表示IIFSM算法。

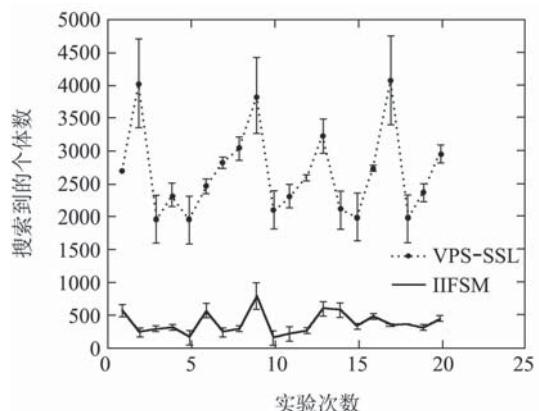


图 6 VPS-SSL与IIFSM搜索性能的比较

Fig. 6 Searching performance comparisons between VPS-SSL and IIFSM

从图6可以看出, 采用本文算法, 每次实验中, 算法搜索到的互异进化个体数均远大于IIFSM算法。进一步, 根据统计的方差和均值, 本文算法搜索的互异进化个体数平均为2667.80, 而IIFSM为375.85, 仅为本文算法的1/7。结合表1数据, 说明本文算法在有效减轻用户评价疲劳的同时, 大大增强了交互式遗传算法的搜索性能。

综上所述, 本文算法可以在减轻用户评价疲劳的情况下, 大大增强基于聚类的变种群规模交互式遗传算法, 以及基于监督学习构造代理模型的区间适应值交互式遗传算法的搜索能力, 即增强

了算法找到最优解的概率;实验方差数据表明,本文算法具有更好的稳定性。

## 6 结论(Conclusion)

针对变种群规模交互式遗传算法中类中心适应值是区间数的情况,引入半监督学习策略,并结合交互式遗传算法的特性,给出了标记样本和未标记样本的选择方法;为了提高半监督学习效率,根据进化种群的聚类结果,提出了一种新的批可信样本选择策略;采用协同训练半监督学习策略,训练区间数回归器并构造代理模型;在模型满足精度要求时,代替用户估计个体适应值;在后续进化过程中,用户每代参与修正一定量的进化个体适应值,组成新的标记样本,并根据用户修正个体适应值与估计值之间的偏差,确定代理模型更新的时机。算法在服装进化设计系统中的应用结果表明,本文方法可以有效改进基于聚类的变种群规模和基于监督学习构造代理模型的区间适应值交互式遗传算法的搜索能力,大大减轻用户疲劳,且具有较好的稳定性,可应用于更多复杂的优化问题中。

从对算法性能影响角度出发,给出合理的参数取值方法,以及进化个体适应值为其他不确定数时的基于半监督学习的代理模型构造等,将是进一步要研究的问题。

## 参考文献(References):

- [1] DAWKINS R. *The Blind Watchmaker*[M]. Essex, UK: Longman, 1986.
- [2] CALDWELL C, JOHNSTON V S. Tracking a criminal suspect through ‘face-space’ with a genetic algorithm[C] //Proceedings of the 4th International Conference on Genetic Algorithms. San Diego CA, USA: Morgan Kaufmann, 1991: 416 – 421.
- [3] KIM H S, CHO S B. Application of interactive genetic algorithm to fashion design[J]. *Engineering Applications of Artificial Intelligence*, 2000, 13(6): 635 – 644.
- [4] TOKUI N, IBA H. Evolutionary interactive music composition[C] //Proceedings of the Genetic and Evolutionary Computation Conference. Las Vegas, Nevada, USA: Morgan Kaufmann, 2000: 215 – 226.
- [5] FORMIGA L, ALIAS F. Extracting user preferences by GTM for AiGA weight tuning in unit selection text-to-speech synthesis[C] //Proceedings of the 9th International Work Conference on Artificial Neural Networks. Heidelberg, Germany: Springer-Verlag, 2007: 654 – 661.
- [6] RHO S M, HWANG E J, KIM M K. Music information retrieval using a GA-based relevance feedback[C] //Proceedings of 2007 International Conference on Multimedia and Ubiquitous Engineering. Piscataway, NJ, USA: IEEE, 2007: 739 – 744.
- [7] KUBOTA N, NOJIMA Y, KOJIMA F, et al. Multiple fuzzy state-value functions for human evaluation through interactive trajectory planning of a partner robot[J]. *Soft Computing*, 2006, 10(10): 891 – 901.
- [8] LEE J Y, CHO S B. Sparse fitness evaluation for reducing user burden in interactive algorithm[C] //Proceedings of 1999 IEEE International Fuzzy Systems Conference. Piscataway, NJ, USA: IEEE, 1999: 998 – 1003.
- [9] GONG D W, YUAN J, MA X P. Interactive genetic algorithms with large population size[C] //Proceedings of the 2008 IEEE Congress on Evolutionary Computation. Piscataway, NJ, USA: IEEE, 2008: 1678 – 1685.
- [10] RRN J, GONG D W. Interactive genetic algorithms with variational population size[C] //Proceedings of 5th International Conference on Intelligent Computing. Berlin, Germany: Springer-Verlag, 2009, 5755: 64 – 73.
- [11] GONG D W, GUO G S. Interactive genetic algorithms with interval fitness of evolutionary individuals, dynamics of continuous[J]. *Discrete and Impulsive Systems, Series B*, 2007, 14(S): 446 – 450.
- [12] BILES J A, ANDERSON P G, LOGGI L W. Neural network fitness functions for a musical IGA[C] //Proceedings of the International Symposium on Intelligent Industrial Automation and Soft Computing. Millet, Alta., Canada: Int. Comput. Sci. Conventions, 1996: 39 – 44.
- [13] 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 Yong, GONG Dunwei, HAO Guosheng, et al. Neural network based phase estimation of individual fitness in interactive genetic algorithm[J]. *Control and Decision*, 2005, 20(2): 234 – 236.)
- [14] LORA X, SASTRY K, GOLDBERG D E, et al. Combating user fatigue in igas: partial ordering, support vector machines, and synthetic fitness[C] //Proceedings of the Genetic and Evolutionary Computation Conference. Washington, USA: ACM, 2005: 1363 – 1370.
- [15] ECEMIS I, BONABEAU E, ASHBURN T. Interactive estimation of agent-based financial markets models: modularity and learning[C] //Proceedings of Genetic and Evolutionary Computation Conference. USA: ACM, 2005: 1897 – 1904.
- [16] GONG D W, SUN X Y. Surrogate models based on individual’s interval fitness in interactive genetic algorithms[J]. *Chinese Journal of Electronics*, 2009, 18(4): 689 – 694.
- [17] ZHOU Z H, LI M. Semi-supervised regression with co-training style algorithms[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2007, 19(11): 1479 – 1493.

## 作者简介:

孙晓燕 (1978—), 女, 博士, 副教授, 目前研究方向为智能优化与控制, E-mail:xysun78@126.com;

任洁 (1985—), 女, 硕士, 目前研究方向为进化计算, E-mail:renjie19850210@sina.com;

巩敦卫 (1970—), 男, 博士, 教授, 博士生导师, 目前研究方向为智能优化与控制, E-mail: dwgong@vip.163.com.