

基于区间适应值交互式遗传算法的加权 多输出高斯过程代理模型

孙晓燕¹ 陈姗姗¹ 巩敦卫¹ 张勇¹

摘要 融合了用户认知和智能评价的交互式遗传算法 (Interactive genetic algorithm, IGA) 是解决一类定性性能指标优化问题的有效方法, 但是, 评价不确定性和易疲劳性极大地限制了该算法解决实际问题的能力. 基于用户已评价信息, 采用合适的机器学习方法, 构建用户认知代理模型是解决上述问题的常用方法之一. 但是, 现有研究成果均没有考虑用户评价不确定性对学习样本、代理模型的影响, 以及模型拟合不确定性对基于适应值的进化操作有效性的影响. 针对上述问题, 本文提出基于加权多输出高斯过程 (Gaussian process, GP) 代理模型的交互式遗传算法. 首先, 在区间适应值评价模式下, 提取学习样本的噪声特性, 以确定相应学习样本对代理模型的影响度权重系数, 构建两输出高斯过程代理模型; 然后, 利用代理模型提供的预测值及预测置信水平, 给出一种新的个体适应值估计方法和个体选择方法; 基于模型预测信息, 实现模型更新管理. 将所提算法分别应用于含噪函数和服装设计问题中, 所得结果表明本文算法可更好地拟合和跟踪用户认知, 减小对进化搜索的误导, 更快找到用户满意解.

关键词 遗传算法, 交互, 代理模型, 高斯过程, 加权多输出

引用格式 孙晓燕, 陈姗姗, 巩敦卫, 张勇. 基于区间适应值交互式遗传算法的加权多输出高斯过程代理模型. 自动化学报, 2014, 40(2): 172–184

DOI 10.3724/SP.J.1004.2014.00172

Weighted Multi-output Gaussian Process-based Surrogate of Interactive Genetic Algorithm with Individual's Interval Fitness

SUN Xiao-Yan¹ CHEN Shan-Shan¹ GONG Dun-Wei¹ ZHANG Yong¹

Abstract An interactive genetic algorithm (IGA), combining a user's intelligent evaluations with traditional genetic operators, is developed to optimize problems with aesthetic indicators. However, the evaluation uncertainties and burden greatly restrict the applications of IGA in complicated situations. Surrogate models constructed with appropriate machine learning methods have been successfully used to alleviate the user evaluation burden of IGAs. However, the uncertainties resulted from the user's evaluations and model's approximation are not taken into account in the existing research. To tackle such problems, a weighted multi-output Gaussian process (GP) is proposed to build a surrogate model to improve the performance of IGA. First, the evaluation noise is defined when an individual's fitness is represented as an interval. With the evaluation noise, the contribution of a training sample to construct the surrogate model is calculated, and used to train a GP with two outputs to approximate the upper and lower values of the interval fitness. A novel fitness approximation method is proposed by combining the predicted value with its associated predictive confidence. Based on the predictive confidence, the surrogate model is well managed during the evolution. The proposed algorithm is used to optimize a benchmark function and a real-world fashion design case to experimentally demonstrate that the surrogate model outperforms others in prediction fitting and tracking user's evaluations, and is beneficial to less misleading the search and faster finding the optima.

Key words Genetic algorithm (GA), interactive, surrogate, Gaussian process (GP), weighted multi-output

Citation Sun Xiao-Yan, Chen Shan-Shan, Gong Dun-Wei, Zhang Yong. Weighted multi-output Gaussian process-based surrogate of interactive genetic algorithm with individual's interval fitness. *Acta Automatica Sinica*, 2014, 40(2): 172–184

收稿日期 2012-11-30 录用日期 2013-08-13
Manuscript received November 30, 2012; accepted August 13, 2013

国家自然科学基金 (61105063), 中央高校基本科研业务费专项资金 (2012QNA58, 2013XK09), 江苏省自然科学基金 (BK2010186), 江苏省博士后基金 (1001019C) 资助

Supported by National Natural Science Foundation of China (61105063), Fundamental Research Funds for the Central Universities (2012QNA58, 2013XK09), Natural Science Foundation of Jiangsu Province (BK2010186), and Postdoctoral Foundation

基于达尔文“优胜劣汰”自然选择机制的遗传算法 (Genetic algorithm, GA) 是解决复杂优化问题的有效方法^[1]. 在该类算法中, 基于优化目标函数

of Jiangsu Province (1001019C)

本文责任编辑 侯增广

Recommended by Associate Editor HOU Zeng-Guang

1. 中国矿业大学信息与电气工程学院 徐州 221116

1. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221116

进行个体适应值的计算是模拟“优胜劣汰”过程的关键。然而,在日常生产和生活中,存在大量与人的认知、偏好、兴趣度等美学性能指标相关的优化问题,即定性性能指标优化问题,这类问题难以甚至无法用精确定义的目标函数来进行描述,那么,依据精确定义目标函数对解进行优劣比较的遗传算法将难以奏效。不难理解,此时人(用户)却非常容易根据其认知和偏好等,对优化方案进行评价,那么,将人的智能评价与遗传算法结合,则可有效解决定性性能指标优化问题。20世纪90年代初提出的交互式遗传算法(Interactive genetic algorithm, IGA)是这类结合的典型算法之一,目前已经在机器学习、服装设计、软件设计以及人脸识别等领域得到了广泛应用^[2-4]。

然而,在IGA中,用户评价进化个体适应值时,需要通过人机交互过程频繁对个体进行评价,极易疲劳,导致交互式遗传算法进化种群规模较小、进化代数较少,极大地限制了算法在复杂优化问题中的应用^[5]。其根本原因在于评价函数与用户偏好相关,较复杂,难以明确表述,而对于此类问题,构建代理模型是解决问题的有效途径之一,且该方法在复杂优化问题中已得到了广泛关注和研究^[6]。根据交互过程中用户已评价进化个体及其适应值信息,采用合适的机器学习方法,识别用户认知和偏好,并构建偏好评价模型,即认知代理模型,在模型满足精度要求时,利用该代理模型代替用户评价进化个体适应值,是解决上述问题的可行方法之一。

已有的IGA用户认知代理模型多沿用传统GA代理模型构建方法,只是单纯地对学习样本的拟合,而没有考虑IGA自身的独特性对代理模型构建和管理的影响:1)用户评价易疲劳,那么,可获得的样本数量往往较小;2)用户认知和偏好具有不确定性和主观性,使得用于构建代理模型的学习数据含有较大的噪声;3)用户给出的评价结果具有相对性,导致不同学习样本,即进化个体及其适应值,具有不同的噪声强度;4)代理模型的拟合不确定性对IGA性能的影响。目前,针对特点1),我们提出了基于半监督学习的大种群规模IGA,即将用户评价的少量进化个体和大量未评价个体作为学习样本,利用半监督学习机制构建精度较高的用户认知代理模型,可有效改善IGA的搜索性能^[7]。而关于2)~4),即IGA中代理模型训练数据的含噪特性和代理模型拟合不确定性,目前在代理模型构建和管理中尚未得到充分关注和研究。因此,本文针对IGA中代理模型应用环境的独特性,考虑训练样本含有独立不相关噪声的情况,研究含噪样本对模型训练的贡献程度,提出一种新的含噪代理模型构建方法,以有效提高代理模型在噪声环境下的拟合性能,更好地跟踪

用户认知变化;进一步利用代理模型拟合不确定性对IGA性能的影响,研究新的个体适应值估计策略和模型管理方法,减少代理模型估计偏差对进化搜索的误导,减轻用户评价负担,提高算法的搜索性能。

构建IGA用户认知代理模型,需首先确定模型类型。目前,常用神经网络和支持向量机模型,但是,上述模型的拟合不确定性不易衡量。高斯过程(Gaussian process, GP)是近年来基于统计学理论发展起来的一种模型^[8],适用于小样本学习,更重要的是,模型的输出不仅提供了待测样本的预测值(平均值),而且给出了预测的置信水平(方差),即预测不确定度,而该模型目前尚未在IGA中得以应用。鉴于此,本文考虑训练样本的含噪特性,利用高斯过程不仅提供样本的预测值,同时给出相应预测值置信水平的性质,研究区间适应值交互式遗传算法的加权高斯过程代理模型的构建和应用。

算法的基本思想是:采用区间数评价进化个体适应值,然后,利用区间分析给出不同进化个体作为训练样本的噪声水平;根据各样本的噪声水平,确定其在高斯过程训练中的权重,以控制训练样本对高斯过程预测概率分布的影响;构建不同训练样本具有不同噪声因子的两输出高斯过程模型,拟合用户评价的区间适应值;基于预测值和模型预测置信水平,估计进化个体适应值;根据预测值和预测不确定度,选择最有价值的个体呈现给用户,供用户寻找满意解或帮助实现模型更新。最后,将所提算法应用于含噪数值函数和服装设计问题中,以验证本文算法的有效性。

与已有研究成果相比,本文在代理模型构建时,深入分析交互式遗传算法的特点,考虑了训练样本的噪声特性,以及模型拟合不确定性的影响,创新点主要体现在如下四个方面:1)根据交互式遗传算法区间适应值评价特点,研究代理模型构建时训练样本的噪声衡量方法;2)从拟合区间数角度出发,研究了样本含噪情况下的改进加权多输出高斯过程代理模型的构建;3)结合高斯过程模型预测值和预测不确定性因子,给出了修正的个体适应值估计算法;4)根据预测不确定性,给出了模型的应用和管理策略。

本文结构安排如下:第1节介绍相关工作,包括区间适应值交互式遗传算法和基于代理模型的交互式遗传算法;考虑IGA训练样本噪声特性,基于加权两输出高斯过程用户认知代理模型的构建在第2节给出;第3节代理模型的应用和管理,包括基于模型的个体适应值估计方法及模型管理策略。算法在含噪函数和服装设计问题中的应用在第4节给出;最后是总结。

1 相关工作

1.1 区间适应值交互式遗传算法

为了刻画用户评价的不确定性,并减轻用户评价心理负担,Gong等提出了进化个体区间适应值交互式遗传算法^[9].不失一般性,考虑如下—类定性性能指标优化问题:

$$\begin{cases} \max f(\mathbf{x}) \\ \mathbf{x} \in S \subset \mathbf{R}^d \end{cases} \quad (1)$$

其中, \mathbf{x} 为 d 维决策变量,变化范围为 S ; $f(\mathbf{x})$ 为决策变量 \mathbf{x} 的性能指标,无法用确定的数学函数表示,由用户给出,在文献[9]中,该评价值为区间数.记第 t 代进化种群的第 i 个进化个体为 $\mathbf{x}_i(t)$,其适应值 $f(\mathbf{x}_i(t))$ 表示为^[9] $f(\mathbf{x}_i(t)) = [\underline{f}(\mathbf{x}_i(t)), \bar{f}(\mathbf{x}_i(t))]$,其中, $\underline{f}(\mathbf{x}_i(t))$ 和 $\bar{f}(\mathbf{x}_i(t))$ 分别表示用户对个体 $\mathbf{x}_i(t)$ 评价的下限和上限. $f(\mathbf{x}_i(t))$ 的中点和宽度计算方法如式(2)和(3)所示:

$$c(f(\mathbf{x}_i(t))) = \frac{\bar{f}(\mathbf{x}_i(t)) + \underline{f}(\mathbf{x}_i(t))}{2} \quad (2)$$

$$w(f(\mathbf{x}_i(t))) = \bar{f}(\mathbf{x}_i(t)) - \underline{f}(\mathbf{x}_i(t)) \quad (3)$$

不难理解,区间中点 $c(f(\mathbf{x}_i(t)))$ 刻画了用户对个体 $\mathbf{x}_i(t)$ 的偏好程度,当用户比较喜欢 $\mathbf{x}_i(t)$ 时, $c(f(\mathbf{x}_i(t)))$ 较大;反之,则 $c(f(\mathbf{x}_i(t)))$ 较小;区间宽度 $w(f(\mathbf{x}_i(t)))$ 反映了用户评价个体 $\mathbf{x}_i(t)$ 时的不确定性,当用户认知比较清晰时, $w(f(\mathbf{x}_i(t)))$ 较小;反之,则 $w(f(\mathbf{x}_i(t)))$ 较大.因此,通过用户给出的进化个体区间适应值 $f(\mathbf{x}_i(t))$,可以同时反映用户评价时的偏好和不确定性.

1.2 基于代理模型的交互式遗传算法

如前所述,构建用户认知代理模型是减轻交互式遗传算法用户评价疲劳的有效方法.如针对进化个体适应值为确定数的情况,Biles等^[10]和周勇等^[11]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.Wang等^[12]将用户评价的进化个体相对适应值转换成绝对标度后,再利用支持向量机构建代理模型,有效提高了交互式遗传算法的性能.Llorà等^[13]基于用户两两比较结果,利用有向图获取进化个体间的全序比较关系,并基于该关系构造支持向量机模型,利用该模型代替用户比较,有效提高了算法性能.Ecemis等^[14]利用径向基函数(Radial basis function, RBF)学习用户的评价,并将该算法用于金融市场建模.针对进化个体适应值为不确定数,如区间数、模糊数等情况,Gong等^[15]提出利用两个RBF网络或一个两输出BP网

络逼近区间适应值下限和上限的代理模型构造方法.Wang等^[16]提出基于用户评价代理模型的交互式优化算法,并将其应用于故事创作中.这些方法都在刻画用户认知不确定性的同时,进一步减轻了用户疲劳,提高了交互式遗传算法的搜索性能^[17].但是,在已有研究成果中,构建用户认知代理模型时,均直接利用交互过程中存储的进化个体及其适应值作为学习样本,没有考虑因用户评价不确定性、相对性等带来的噪声特性,这将会极大地削弱所构建模型对用户认知的跟踪和拟合性能,进而影响基于该代理模型的后续进化优化,误导搜索方向.因此,在研究基于代理模型的交互式遗传算法时,非常有必要考虑学习样本的噪声特性及模型预测的不确定性,以减少对搜索的误导,提高模型更新的效率.下面,我们将给出基于高斯过程构建代理模型的交互式遗传算法.

2 加权多输出高斯过程的区间适应值代理模型

在IGA中,利用高斯过程构建用户认知代理模型时,首先由用户评价部分进化个体,将已评价个体及其适应值作为学习样本,然后,基于学习样本确定模型参数.而用户在评价进化个体时,往往参考其当前所见个体信息,根据个人认知和偏好,给出相对评价价值,那么,该评价价值必然存在误差和不确定性,即训练模型的学习数据是含噪的,且不同训练样本噪声强度不同.此时,传统高斯过程模型中认为样本噪声独立同分布假设不再成立,需根据用户评价,确定不同样本的噪声强度;此外,具有不同噪声强度的样本,对高斯过程模型的贡献不同,即样本权重不同.鉴于此,本节给出区间适应值评价模式下,用户评价个体适应值的噪声强度识别,以及样本对于高斯过程模型贡献程度的确定,最后,基于权重构建两输出高斯过程代理模型.

2.1 训练样本的噪声强度

记IGA中代理模型构建的训练样本集为 $T_r = \{(\mathbf{x}_i, f(\mathbf{x}_i)) | i = 1, 2, \dots, n\}$,其中, $f(\mathbf{x}_i)$ 为进化个体 \mathbf{x}_i 的适应值.一般来讲,用户对于自己特别喜欢和特别不喜欢的个体,认知相对明确,评价时比较谨慎,给出评价价值不确定程度较小,那么,这些个体适应值的噪声强度较低,其对模型的贡献也应较大.本文考虑区间适应值IGA, $f(\mathbf{x}_i)$ 为区间数,用户给出区间上下端点值后,由式(2)和(3)计算可得区间中点值 $c(f(\mathbf{x}_i))$ 和宽度值 $w(f(\mathbf{x}_i))$,如第1.1节所述,区间适应值的中点和宽度分别反映了用户的偏好和评价的不确定性,基于上述分析,我们定义如式(4)所示进化个体 \mathbf{x}_i 的评价噪声强度衡量指标:

$$I(\mathbf{x}_i) = \frac{w(f(\mathbf{x}_i))}{\left| c(f(\mathbf{x}_i)) - \frac{1}{n} \sum_{j=1}^n c(f(\mathbf{x}_j)) \right|} \quad (4)$$

从式(4)可以看出, 宽度 $w(f(\mathbf{x}_i))$ 越小, 且距离当前种群平均适应值区间中值 $\bar{c} = \frac{1}{n} \sum_{j=1}^n c(f(\mathbf{x}_j))$ 越远的个体, 即用户特别喜欢和特别不喜欢、且评价不确定度小的个体, $I(\mathbf{x}_i)$ 值越小, 表明 \mathbf{x}_i 的噪声强度较小; 对于评价区间宽度较大, 而区间中值也距离当前种群平均适应值区间中值远的个体而言, 相对于前述情况, $I(\mathbf{x}_i)$ 值会增加, 实质是此时评价不确定性增大, 因此, 相应的噪声强度亦增加; 类似地, 对于宽度大, 而区间中值距离当前种群平均适应值区间中值相对较近的个体而言, 其噪声强度较大, $I(\mathbf{x}_i)$ 值亦较大, 因此, 利用式(4)刻画评价噪声是合理的. 为了便于计算, 对 $I(\mathbf{x}_i)$ 进行归一化处理, 如式(5)所示:

$$R(\mathbf{x}_i) = \frac{I(\mathbf{x}_i) - \min_{j=1,2,\dots,n} \{I(\mathbf{x}_j)\}}{\max_{j=1,2,\dots,n} \{I(\mathbf{x}_j)\} - \min_{j=1,2,\dots,n} \{I(\mathbf{x}_j)\}} \quad (5)$$

如果某一样本的噪声是所有训练样本中最小的, 则该样本对应的噪声强度 $R(\mathbf{x}_i)$ 值为 0; 如果某一样本的噪声是所有训练样本中最大的, 则该样本的 $R(\mathbf{x}_i)$ 值为 1; 对于含噪情况介于两者之间的样本, 有 $R(\mathbf{x}_i) \in (0, 1)$.

2.2 训练样本的权重确定

与 GA 代理模型构建相比, 在 IGA 中, 构建用户认知代理模型时, 训练样本具有两个明显不同的特点: 1) 不同训练样本具有不同噪声水平; 2) 来自不同进化代的训练样本反映了用户不同阶段的偏好. 那么, 对于噪声水平低的样本, 其对代理模型的贡献应较大; 最近评价的信息最能反映用户当前偏好, 同样, 这类样本对模型的贡献应较大, 相反地, 较早评价个体可能较大地偏离了用户的当前偏好, 其对模型的贡献应较小. 针对上述特点, 我们给出如下训练样本重要性权重的确定方法.

首先, 考虑样本的时效性. 为便于实现, 将训练样本分为时新样本集和过时样本集, 设置进化代数阈值 T_0 , 设在 T ($T > T_0$) 代构建代理模型, 则 T_0 至 T 进化代, 用户已评价个体及其适应值为时新样本集; T_0 代之前训练集为过时样本. 基于第 2.1 节式(5)所计算各样本噪声水平及样本时效性, 我们采用下式计算训练样本 $\mathbf{x}_i(t)$ 的权重:

$$\omega(\mathbf{x}_i(t)) = \begin{cases} Ae^{-R(\mathbf{x}_i(t))}, & T - T_0 \leq t \leq T \\ Ae^{-1}, & T - 2T_0 \leq t < T - T_0 \\ 0, & t < T - 2T_0 \end{cases} \quad (6)$$

其中, $\mathbf{x}_i(t)$ 为来自 t 代的进化个体, 为 T_r 中的元素, A 为常数, 满足 $\sum_{i=1}^n \omega(\mathbf{x}_i(t)) = 1$, 显然, 该值随着 $\mathbf{x}_i(t)$ 动态变化. 由于 $R(\mathbf{x}_i(t)) \in [0, 1]$, 所以 $\omega(\mathbf{x}_i(t)) \in [Ae^{-1}, A]$. 实质上, 该权重代表了当前所有学习样本的可信程度. 下面, 我们将给出融合样本权重两输出高斯过程的代理模型构建和应用策略, 以有效减轻用户疲劳, 提高区间适应值 IGA 性能.

2.3 加权多输出高斯过程代理模型

为了增强 IGA 的搜索性能, 本文采用大规模进化种群, 设种群规模为 N . 考虑训练样本分布对高斯过程模型预测性能的影响, 对于初始种群, 我们采用 K 均值聚类方法对大规模种群进行聚类, 然后将 K 个距离类中心最近的个体提交给用户进行评价, 将这些评价个体及其适应值作为初始学习样本. 不失一般性, 记至第 t 代时, 基于 IGA 进化过程所得训练样本集合为 T_r , 即 $T_r = \{(\mathbf{x}_i, [f(\mathbf{x}_i), \bar{f}(\mathbf{x}_i)]) \mid i = 1, 2, \dots, n\}$, 其中训练样本可能来自于不同进化代, 且各样本噪声强度不同. 在初始进化代, $n = K$.

基于训练数据 T_r , 利用高斯过程构造用户认知代理模型, 本质是拟合区间数, 即高斯过程模型需同时拟合区间的下限值和上限值. 若区间上限和下限值没有明显的相关性, 则可直接构造两个高斯过程, 分别逼近区间的两个端点值. 但是, 在 IGA 进化个体评价中, 区间端点值具有明显的相关性, 因此, 这里采用文献 [18] 所述多输出高斯过程模型 (Multi-output Gaussian process, MOGP). MOGP 模型把高斯过程看成是由高斯白噪声经核函数卷积而得, 该模型可使不同输出共享相同白噪声, 而建立各输出之间的相关性, 因此, 它能模拟不同输出之间存在的密切联系.

区间上限和下限分别对应一个随机过程, 记为

$$\begin{aligned} \hat{f}(\mathbf{x}_i) &= \hat{f}_1(\mathbf{x}_i) = U_1(\mathbf{x}_i) + \varepsilon_1(\mathbf{x}_i) \\ \underline{f}(\mathbf{x}_i) &= \hat{f}_2(\mathbf{x}_i) = U_2(\mathbf{x}_i) + \varepsilon_2(\mathbf{x}_i) \end{aligned} \quad (7)$$

其中, $\hat{f}(\mathbf{x}_i)$ 和 $\underline{f}(\mathbf{x}_i)$ 分别为对区间上限 $\bar{f}(\mathbf{x}_i)$ 和下限 $f(\mathbf{x}_i)$ 的逼近; $\varepsilon_1(\mathbf{x}_i)$ 和 $\varepsilon_2(\mathbf{x}_i)$ 分别为对应的噪声函数, 由于各样本噪声强度不同, 因此, 有 $\varepsilon_j(\mathbf{x}_i) \sim N(0, \sigma_{ji}^2)$, $j = 1, 2$; $i = 1, 2, \dots, n$; $U_1(\mathbf{x}_i)$ 为 \mathbf{x}_i 与 $\bar{f}(\mathbf{x}_i)$ 之间的映射关系, $U_2(\mathbf{x}_i)$ 为 \mathbf{x}_i 与 $f(\mathbf{x}_i)$ 之间的映射关系, 其表达式为^[18]

$$U_j(\mathbf{x}) = \sum_{m=1}^M k_{mj}(\mathbf{x}) * S_m(\mathbf{x}) = \sum_{m=1}^M \int_{\mathbf{R}^d} k_{mj}(\tau) S_m(\mathbf{x} - \tau) d\tau, \quad j = 1, 2 \quad (8)$$

其中, M 表示模型输出共享白噪声个数, 本文 $M = 2$; $k_{mj}(\mathbf{x})$ 为光滑核函数, 如下所示:

$$k_{mj}(\mathbf{x}) = \lambda_{mj} \exp \left[-\frac{1}{2}(\mathbf{x} - \mu_{mj})^T \Lambda_{mj}^{-1}(\mathbf{x} - \mu_{mj}) \right] \quad (9)$$

其中, $\lambda_{mj} \in \mathbf{R}$, $\mu_{mj} \in \mathbf{R}^d$, $\Lambda_{mj} = \begin{bmatrix} l_{mj,1}^2 & 0 & \cdots & 0 \\ 0 & l_{mj,2}^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ 0 & \cdots & 0 & l_{mj,n}^2 \end{bmatrix}$, 那么, 高斯过程模型超参数集合为 $\Theta = \{\lambda_{mj}, \mu_{mj}, \Lambda_{mj}, \sigma_{ji} | m = 1, 2; j = 1, 2; i = 1, 2, \dots, n\}$.

与单输出高斯过程类似, 此时有:

$$\hat{\mathbf{f}} = \begin{bmatrix} \hat{f}_1 \\ \hat{f}_2 \end{bmatrix} \sim N \left(\mathbf{0}, C = \begin{bmatrix} C_{11} & C_{12} \\ C_{21} & C_{22} \end{bmatrix} \right) \\ C_{pj} = C_{pj}^{U_j} + \text{diag}\{\sigma_{ji}^2\} \delta_{pj}, \\ p = 1, 2; \quad j = 1, 2; \quad i = 1, 2, \dots, n \quad (10)$$

其中, $\text{diag}\{\sigma_{ji}^2\}$ 表示由 σ_{ji}^2 为对角元素组成的矩阵;

$\delta_{pj} = \begin{cases} \mathbf{I}_{n \times n}, & p = j \\ 0_{n \times n}, & p \neq j \end{cases}$; $C_{pj}^{U_j}$ 为高斯过程 U_j 对应的协方差矩阵, 定义如下^[18]:

$$C_{pj}^{U_j}(\mathbf{x}_i, \mathbf{x}_k) = \sum_{m=1}^M \frac{(2\pi)^{\frac{d}{2}} \lambda_{mp} \lambda_{mj}}{\sqrt{|\Lambda_{mp} + \Lambda_{mj}|}} * \exp \left[-\frac{1}{2} [dx - (\mu_{mp} - \mu_{mj})]^T \Sigma [dx - (\mu_{mp} - \mu_{mj})] \right] \quad (11)$$

其中, $dx = \|\mathbf{x}_i - \mathbf{x}_k\|$.

对于待评价个体 \mathbf{x}^* , 其区间适应值上限和下限估计值分别为 $\hat{\mathbf{f}}^* = \begin{bmatrix} \hat{f}^* \\ \hat{f} \end{bmatrix}$, 满足:

$$\begin{bmatrix} \hat{\mathbf{f}}^* \\ \hat{\mathbf{f}} \end{bmatrix} \sim N \left(\mathbf{0}, \begin{pmatrix} C(\hat{\mathbf{f}}^*, \hat{\mathbf{f}}^*) & C(\hat{\mathbf{f}}^*, \hat{\mathbf{f}}) \\ C(\hat{\mathbf{f}}, \hat{\mathbf{f}}^*) & C(\hat{\mathbf{f}}, \hat{\mathbf{f}}) \end{pmatrix} \right) \quad (12)$$

则有:

$$p(\hat{\mathbf{f}}^* | T_r, \mathbf{x}^*) = N(\hat{\mathbf{f}}_\mu^*, \hat{\mathbf{f}}_{\sigma^2}^*) \quad (13)$$

其中,

$$\hat{\mathbf{f}}_\mu^* = C(\hat{\mathbf{f}}, \hat{\mathbf{f}}^*)^T C(\hat{\mathbf{f}}, \hat{\mathbf{f}})^{-1} \hat{\mathbf{f}} \quad (14)$$

$$\hat{\mathbf{f}}_{\sigma^2}^* = C(\hat{\mathbf{f}}^*, \hat{\mathbf{f}}^*) - C(\hat{\mathbf{f}}, \hat{\mathbf{f}}^*)^T C(\hat{\mathbf{f}}, \hat{\mathbf{f}})^{-1} C(\hat{\mathbf{f}}, \hat{\mathbf{f}}^*) \quad (15)$$

$\hat{\mathbf{f}}_\mu^*$ 给出估计区间适应值上限和下限均值, $\hat{\mathbf{f}}_{\sigma^2}^*$ 给出相应的估计偏差. 式中, $C(\hat{\mathbf{f}}, \hat{\mathbf{f}}^*)$ 和 $C(\hat{\mathbf{f}}^*, \hat{\mathbf{f}})$ 为 $\hat{\mathbf{f}}^*$ 和 $\hat{\mathbf{f}}$ 之间的协方差矩阵, $C(\hat{\mathbf{f}}, \hat{\mathbf{f}})$ 和 $C(\hat{\mathbf{f}}^*, \hat{\mathbf{f}}^*)$ 分别为 $\hat{\mathbf{f}}$ 和 $\hat{\mathbf{f}}^*$ 自身的协方差矩阵.

基于训练样本集 T_r , 采用合适的方法可获得参数集合 $\Theta = \{\lambda_{mj}, \mu_{mj}, \Lambda_{mj}, \sigma_{ji} | m = 1, 2; j = 1, 2; i = 1, 2, \dots, n\}$ 的最优值. 如前所述, T_r 中样本噪声强度不同, 其对于模型贡献程度也应不同. 鉴于此, 我们首先利用第 2 节方法, 计算 T_r 中样本权重 $\omega(\mathbf{x}_i)$, 然后, 基于随机初始参数值, 将权重信息引入下述训练误差项中, 通过最小化该性能指标, 获得相关参数最优取值.

$$E = \frac{1}{2} \sum_{i=1}^n \omega(\mathbf{x}_i) \left[\left(\hat{f}(\mathbf{x}_i) - \bar{f}(\mathbf{x}_i) \right)^2 + \left(\hat{f}(\mathbf{x}_i) - \bar{f}(\mathbf{x}_i) \right)^2 \right] \quad (16)$$

其中, $\hat{f}(\mathbf{x}_i)$, $\bar{f}(\mathbf{x}_i)$ 为模型预测分布 $P(\hat{\mathbf{f}}_i^* | T_r^{(i)}, \mathbf{x}_i, \Theta)$ 的均值. 在式 (16) 中, 对于含噪较小的训练样本, 其在模型训练中的作用较大, 对误差调整能力较强; 反之, 含噪强度较大的样本, 其对于误差调整能力较小. 由于式 (16) 只考虑了模型预测均值, 因此无法获得合适的预测方差, 因此, 进一步地, 我们以优化后的预测均值 $\hat{\mathbf{f}}_\mu$ 为标准, 进一步优化 $\hat{\mathbf{f}}_\mu \approx \arg \max P(y | \mathbf{X}, \theta)$, 得到最后的优化超参数. 对于引入训练样本噪声的多输出高斯过程模型, 我们称该模型为加权多输出高斯过程模型 (Weighted multi-output Gaussian process, w-MOGP).

3 代理模型的应用和管理

在已有基于代理模型的 IGA 研究成果中, 由于代理模型仅提供了对于待评价进化个体的估计适应值, 而没有体现估计的不确定性, 因此, 在应用代理模型时, 直接将待评价个体信息作为模型输入, 其对应模型输出作为该个体适应值, 忽略了估计不确定性对估计适应值的影响. 而在本文中, 基于式 (14) 和式 (15) 可同时获得区间适应值的估计值, 以及区间上下限的估计不确定性, 那么, 在估计个体适应值

时, 应综合考虑上述信息, 以尽可能保持个体间正确的序关系. 此外, 在进化过程中, 代理模型和用户同时存在, 那么, 如何根据个体估计值, 选择最有价值的进化个体由用户评价, 也是提高算法搜索效率的关键.

3.1 个体适应值估计

对于进化种群中未评价进化个体 $\mathbf{x}_i(t)$, w-MOGP 代替用户估计其适应值, 得到预测均值 $\hat{f}_\mu(\mathbf{x}_i(t)) = [\hat{f}_\mu(\mathbf{x}_i(t)), \hat{f}_\mu(\mathbf{x}_i(t))]$, 及其相应的预测不确定度 $\hat{f}_{\sigma^2}(\mathbf{x}_i(t)), \hat{f}_{\sigma^2}(\mathbf{x}_i(t))$. 不难理解, 预测均值越高, 且预测不确定度越小的进化个体, 其被选择的概率应越大; 反之, 则被淘汰的可能性应越大. 结合我们所采用的文献 [9] 区间概率占优比较方法, 我们给出如下对进化个体适应值 $\hat{f}(\mathbf{x}_i(t))$ 估计方法:

$$\begin{aligned} \hat{f}(\mathbf{x}_i(t)) &= \min\{\hat{f}_\mu(\mathbf{x}_i(t)) - \hat{f}_{\sigma^2}(\mathbf{x}_i(t)), \\ &\quad \hat{f}_\mu(\mathbf{x}_i(t)) - \hat{f}_{\sigma^2}(\mathbf{x}_i(t))\} \\ \hat{f}(\mathbf{x}_i(t)) &= \max\{\hat{f}_\mu(\mathbf{x}_i(t)) + \hat{f}_{\sigma^2}(\mathbf{x}_i(t)), \\ &\quad \hat{f}_\mu(\mathbf{x}_i(t)) + \hat{f}_{\sigma^2}(\mathbf{x}_i(t))\} \end{aligned} \quad (17)$$

从式 (17) 可以看出, 与仅利用预测均值 $\hat{f}(\mathbf{x}_i(t))$ 相比, 通过引入模型预测不确定度信息, 改变了模型预测区间均值的宽度, 可使得估计更确定的个体有更多的机会被保留到下一代种群中, 从而提高子代种群质量. 对于用户评价的进化个体, 其区间适应值保持不变, 当出现预测均值与用户评价适应值相同时, 那么, 预测不确定度较大的进化个体被淘汰的概率会大于用户评价个体, 这也是符合基于代理模型的进化算法的要求的.

3.2 代理模型的管理

在基于代理模型的 IGA 的进化过程中, 模型和用户同时存在, 即模型估计进化个体适应值, 然后, 根据模型估计值, 选择部分进化个体提交给用户, 以确定是否找到满意解. 显然, 欲提高搜索效率, 由用户评价进化个体的选择至关重要. 此外, 随着进化的进行, 用户的偏好往往会发生变化, 那么, 用于拟合用户认知的模型也需要更新, 此时, 关键是选择更新模型的训练样本.

首先, 基于模型预测值和预测不确定度, 确定优势个体, 将其提交给用户进行选择. 不难理解, 预测均值较大且不确定度较小的个体, 其性能应较优. 为便于对进化个体排序, 以选择优势个体供用户评价, 我们采用文献 [19] 提出的指标, 即:

$$r(\mathbf{x}_i(t)) = \frac{c(\hat{f}(\mathbf{x}_i(t)))}{w(\hat{f}(\mathbf{x}_i(t))) + \alpha} \quad (18)$$

其中, $c(\hat{f}(\mathbf{x}_i(t)))$ 和 $w(\hat{f}(\mathbf{x}_i(t)))$ 根据式 (2)、(3) 和 (17) 计算; α 为一个小的正数, 以保证式 (18) 分母不为 0. 式 (18) 中, 预测适应值中点 $c(\hat{f}(\mathbf{x}_i(t)))$ 越大, 宽度 $w(\hat{f}(\mathbf{x}_i(t)))$ 越小的个体, 其 $r(\mathbf{x}_i(t))$ 的性能较优越. 根据 $r(\mathbf{x}_i(t))$, 选择前 K 个优势个体呈现给用户进行评价.

当用户认为当前进化个体估计适应值偏离了其偏好时, 进行代理模型的更新. 假设第 t_1 代更新了一次代理模型, 在第 $t_1 + m$ 代时需要再次更新, 保留第 t_1 代至第 $t_1 + m$ 代之间用户修正的所有进化个体及其适应值, 作为新的训练样本; 此外, 考虑到训练数据对模型性能的影响, 我们将当前代中模型预测不确定度较大, 且多样性较好的个体也提交给用户评价, 并用于更新训练样本集.

基于上述代理模型的交互式遗传算法流程如图 1 所示. 其中, 粗体字部分为用户参与遗传进化过程的交互环节, 即在没有代理模型时, 用户直接评价进化个体适应值, 在有代理模型时, 用户根据代理模型对所评价个体的适应值估计值, 修正不符合其偏好的个体适应值, 以用于后续模型的更新; 阴影部分为本文工作的创新之处.

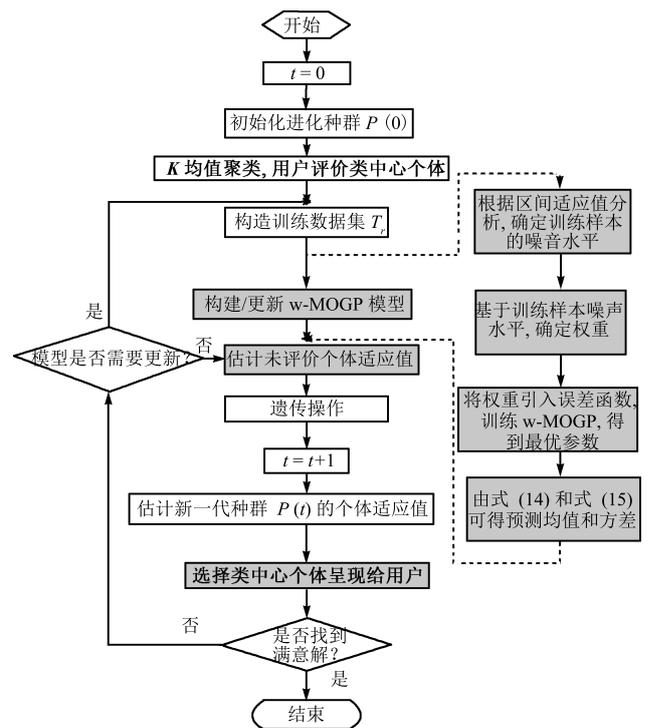


图 1 算法流程图

Fig. 1 Diagram of the proposed algorithm

4 实例验证

本文将从数值函数和服装设计两个方面,验证所提基于加权高斯过程代理模型算法 w-MOGP 的性能. 首先,基于数值函数以更客观地说明加权高斯过程模型对于区间数拟合的性能,并与径向基神经网络模型 (RBF neural network, RBFNN)、文献 [18] 的多输出高斯过程模型 (MOGP) 进行比较说明. 然后,将基于 w-MOGP 代理模型的区间适应值 IGA 应用于实际的服装设计优化问题中,验证算法性能.

4.1 数值函数实验

4.1.1 实验设置

本文算法针对区间适应值交互式遗传算法提出,然而,在实际应用中,由于用户的参与使得算法的结果往往具有很大的主观性,难以充分说明算法的有效性,鉴于此,我们首先将本文所提 w-MOGP 模型用于含噪数值函数的拟合中,以客观地说明该模型的拟合性能. 由于本文所提 w-MOGP 模型是对区间数的拟合,目前在机器学习中尚未有标准测试问题,需要构造合适的区间函数以模拟区间适应值交互式遗传算法环境. 在区间适应值交互式遗传算法中,训练数据具有如下特点: 样本输出为区间值、区间上下限值具有相关性、训练样本含有不同强度的噪声,因此,需要设计相应的含噪区间函数,具体如下:

首先,选择式 (19) 所示 Rosenbrock 函数为基函数:

$$f'(\mathbf{x}) = \sum_{i=1}^{d-1} [(x^i)^2 - x^{i+1}]^2 + (1 - x^i)^2 \quad (19)$$

为了体现区间适应值用户评价样本的特点,我们在式 (19) 精确值函数的基础上,加上扰动量 $f_n(\mathbf{x}) = B \sin(0.5 \sum_{i=1}^d x^i) + 1$, 其中, B 为振幅值,根据基函数变化范围确定. 叠加 $f_n(\mathbf{x})$ 后,构造如式 (20) 所示区间函数:

$$\begin{aligned} f(\mathbf{x}) &= \left[\underline{f}(\mathbf{x}) \quad \bar{f}(\mathbf{x}) \right] \\ \bar{f}(\mathbf{x}) &= \max\{f'(\mathbf{x}), f'(\mathbf{x}) + f_n(\mathbf{x})\} \\ \underline{f}(\mathbf{x}) &= \min\{f'(\mathbf{x}), f'(\mathbf{x}) + f_n(\mathbf{x})\} \end{aligned} \quad (20)$$

进一步,为了体现训练样本的噪声特性,即不同样本噪声强度不同,对于采样点的输出,我们在式 (20) 区间函数值的基础上添加随机噪声 $0.1 \times B \times rand \times randn$, 显然,该噪声服从均值为 0、方差为 $(0.1 \times B \times rand)^2$ 的正态分布,可模拟不同强度的噪声水平,其中, $rand$ 为位于 $[0, 1]$ 之间服从均匀

分布的随机数, $randn$ 为服从标准正态分布的随机数.

我们利用本文算法模型、RBF 神经网络模型,以及多输出高斯过程模型,拟合上述含噪区间函数,具体参数设置如下: $d = 10$; $x^i \in [-2, 2]$, $i = 1, 2, \dots, d$; $B = 45$; 在变量取值范围内随机生成 $n = 30$ 个点作为训练样本 (为了模拟交互式遗传算法中的交互环境,这里训练样本数较少),再随机生成另外 $n_T = 100$ 个点作为测试样本; RBF 神经网络模型采用一个两输出的 RBF 网络分别拟合区间的上下限,利用 Matlab 神经网络工具箱自带 *newrb* 函数建立,经过多次调试,均方误差目标 (goal) 和核函数宽度 (spread) 分别设置为 1 和 8; 多输出高斯过程模型则采用 Neil 等开发的 MULTIGP 系列工具箱^[20] 实现.

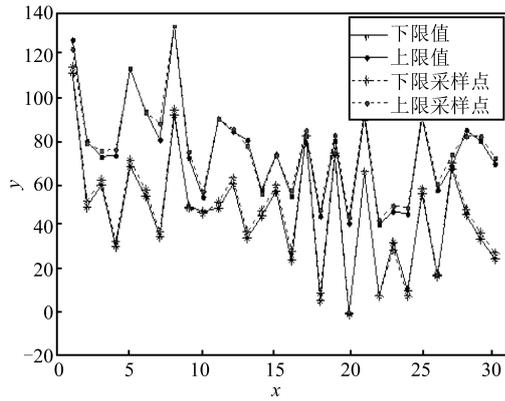
本组实验从 4 个方面说明所提 w-MOGP 模型性能: 1) 验证该数值函数噪声水平衡量方法的可行性,记录随机生成的 30 个训练样本的噪声情况,包括样本的真实噪声,以及采用第 2 节算法所计算的噪声水平,观察两者是否具有有一致性. 2) w-MOGP 的拟合性能,各算法独立运行 20 次,基于测试样本,考虑两类性能指标: a) 使得 $\bar{f}(\mathbf{x}^*) < \underline{f}(\mathbf{x}^*)$ 的测试点 \mathbf{x}^* (称为异常点) 占总测试样本的比例,以说明多输出高斯过程利用区间相关性后,对区间拟合性能的改善; b) 模拟预测误差,以说明模型的泛化性能,这里采用最大误差率: $\max \left\{ \left| \frac{\hat{f}(\mathbf{x}_i) - f(\mathbf{x}_i)}{f(\mathbf{x}_i)} \right| \mid i = 1, \dots, n_T \right\}$, 平均误差率: $\frac{1}{n_T} \sum_{i=1}^{n_T} \left| \frac{\hat{f}(\mathbf{x}_i) - f(\mathbf{x}_i)}{f(\mathbf{x}_i)} \right|$, 均方根误差: $\sqrt{\frac{1}{n_T} \sum_{i=1}^{n_T} [\hat{f}(\mathbf{x}_i) - f(\mathbf{x}_i)]^2}$ 进行比较说明. 3) 适应值估计策略的有效性,通过比较本文所提融入模型预测置信水平的适应值估计策略与基于真实适应值的 GA 方法 (Fitness function-based, F-based), 以及基于模型预测适应值的 GA 方法 (Model prediction-based, M-based) 进行比较说明. 4) 代理模型的管理,为了说明其有效性,将本文所提算法与随机个体选择和最优个体选择方法进行比较.

4.1.2 结果与分析

1) 噪声水平衡量方法的可行性

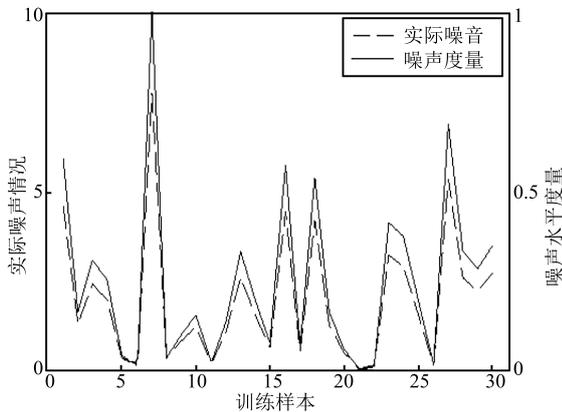
一次随机采样 30 个训练样本点,记录其对应函数区间上下限输出值,加入噪声信号前后上下限变化曲线如图 2(a) 所示,采用第 2 节式 (5) 所计算的噪声强度指标 $R(\mathbf{x})$ 以及实际噪声关系曲线如图 2(b) 所示. 从图中可以看出: a) 本文所设计的含噪函数使得不同训练样本噪声强度不同,符合本文算法的应用环境; b) 采用式 (5) 所得样本噪声强度

的变化趋势与样本实际噪声强度变化一致, 表明第 2 节所给区间数情况下噪声强度衡量指标是可行的. 下面, 进一步验证基于该噪声强度的 w-MOGP 的性能.



(a) 训练样本的采样情况

(a) Fitness landscapes of 30 noisy training samples



(b) 训练样本实际噪声与噪声强度衡量指标

(b) Real noise and noise intensity of 30 training samples

图 2 训练样本噪声情况

Fig. 2 Noise measure of 30 training samples

2) w-MOGP 性能

基于上述采样含噪训练样本, 分别采用三类模

型 (本文 w-MOGP 模型、RBFNN、MOGP) 拟合本文所定义含噪区间函数. 根据测试样本集, 统计模型预测异常点占总测试样本的比例情况; 计算模型测试误差, 包括最大测试误差率、平均测试误差率和均方根测试误差. 进一步地, 针对测试误差, 我们采用 t 检验法说明模型拟合性能的差异性, 这里原假设为“本文算法的测试误差大于或等于其他模型”, 即本文所提模型劣于其他两类, 置信水平 $\alpha = 0.05$, 计算原假设为真的概率, 当该概率值大于 0.05 时, 接受原假设, 否则, 备择假设成立, 即本文算法模型优于其他算法. 统计结果如表 1 所列.

由表 1 可以看出: a) 无论是 MOGP 还是 w-MOGP, 模型估计异常点, 即使得 $\hat{f}(\mathbf{x}^*) < \hat{f}(\mathbf{x}^*)$ 的测试点的数量远远小于采用神经网络的情况, 这是由于多输出高斯过程拟合区间上下限时, 互相利用了对方的信息, 因此能够得到更好的模型预测性能. b) 根据最大误差率、平均误差率和均方根误差三方面的比较, w-MOGP 模型的测试误差和统计方差均小于 MOGP 和 RBFNN, 结合三类算法 t 检验的概率值, 可以发现相应值均小于检验水平 0.05, 这说明本文所提 w-MOGP 模型比 MOGP 和 RBFNN 能更好地拟合含不同噪声强度的区间函数, 预测精度更高且算法稳定性更好.

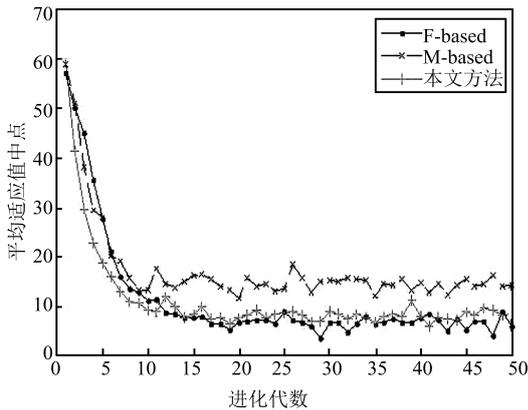
3) 适应值估计策略的有效性

在本组实验中, 为了说明所比较方法的性能, 需运行 GA 算法优化式 (20) 所示区间函数, 设置如下: 对于 F-based 传统 GA, 采用式 (20) 计算个体适应值; 对于 M-based 的 GA, 利用 RBFNN 构建代理模型, 其输出作为个体适应值 (M-based); 对于本文算法, 由式 (17) 估计个体适应值. 训练样本规模为 100, 以确保代理模型精度. 针对同一进化初始种群, 设种群规模 N 为 200, 采用规模为 2 的联赛选择算子, 单点交叉概率为 0.8, 变异概率为 0.3, 分别采用上述 3 种设置运行 GA, 记录前 50 代每代种群的平均适应值变化情况, 包括中点值 $\bar{c}(f(\mathbf{x}_i(t))) = \frac{1}{N} \sum_{i=1}^N c(f(\mathbf{x}_i(t)))$ 和宽度值

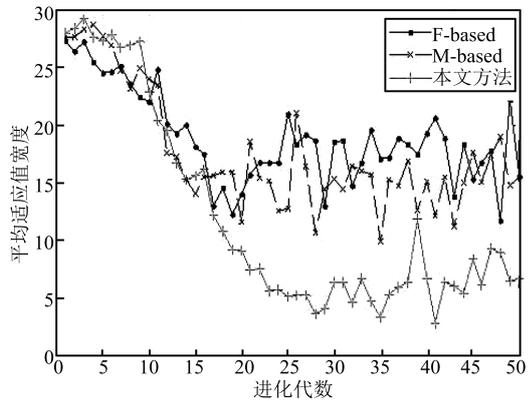
表 1 三类模型拟合误差比较结果
Table 1 Test errors of three models

| 测试误差 | 异常点比例 | | 最大误差率 | | 平均误差率 | | 均方根误差 | |
|---------------|------------------|----------------|----------------|-----------------|---------------|---------------|----------------|----------------|
| | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 |
| RBFNN | 0.1315 | 0.0128 | 153.6687 | 57 174.16 | 1.5789 | 1.7951 | 41.7092 | 172.5875 |
| MOGP | 0.005 | 0.0001 | 56.3958 | 3 210.263 | 0.9128 | 0.1357 | 34.1087 | 32.3618 |
| w-MOGP | 0.0015 | 4.28E-5 | 31.4710 | 762.2965 | 0.7332 | 0.0510 | 30.5799 | 28.5520 |
| t 检验 | w-MOGP vs. MOGP | | 0.0479 | | 0.0398 | | 0.0280 | |
| | w-MOGP vs. RBFNN | | 0.0195 | | 0.0067 | | 0.0011 | |

$\bar{w}(f(\mathbf{x}_i(t))) = \frac{1}{N} \sum_{i=1}^N w(f(\mathbf{x}_i(t)))$, 以说明随着进化过程的进行, 种群质量改善情况, 验证个体适应值估计方法的有效性, 结果如图 3 所示.



(a) 平均区间适应值中点变化曲线
(a) Average center of interval fitness



(b) 平均区间适应值宽度变化曲线
(b) Average width of interval fitness

图 3 GAs 进化种群平均适应值变化情况

Fig. 3 The changes of the average fitness of each generation in GAs

从图 3 中可以看出: a) 对于三种算法, 随着进化过程的进行, 种群平均适应值中点、宽度不断减小, 种群质量得到不断改善. b) 将模型预测置信水平融入进化个体适应值估计中, 相比于仅利用模型

预测值的个体适应值估计方法, 提高了基于适应值的进化选择操作有效性, 增加了算法找到满意解的概率. c) 采用本文适应值估计方法, 可以获得与基于适应值函数计算的 GA 算法相当的优化解质量.

4) 代理模型管理的有效性

为了客观说明本文所提模型管理方法的有效性, 我们采用基于区间函数的 GA, 但是, 在数值实验中, 由于缺少实际的用户交互环节, 因此, 这里直接采用式 (20) 模拟用户评价过程. 采用与上节相同的遗传算子和参数设置, 初始训练样本规模为 30, 在进化过程中, 每代选择 30 个个体提交给用户 (这里为式 (20) 的适应度函数), 然后, 从中选择当前代最优个体, 并将其作为测试样本, 确定模型更新时机, 这里我们采用均方根误差衡量模型性能, 设定更新阈值为 15. 为便于比较, 我们设定, 当解中点大于 -8, 且宽度小于 10 时, 算法结束. 比较在找到该满意解时所需要的进化代数, 模型更新次数和首次模型更新前后模型精度, 20 次实验的统计结果见表 2.

从表 2 中可以看出: a) 采用随机选择进化个体的方法比其他两种方法需要更多的进化代数才能找到满意解. 随机方法需要进化代数平均为 31.6 代, 而最优个体选择和本文方法仅需要 9.45 代和 8.65 代, 这是由于采用随机方法, 挑选出的个体不一定是当前代种群较优个体, 需要更多的进化代数才能从中发现满意解. b) 采用本文模型管理方法, 模型更新次数最少, 且更新后模型性能改善程度最大. 本文方法模型更新次数仅需 1.5 次, 且更新后模型精度较之前提高了 43.15%, 而随机选择和最优选择方法分别提高了 25.57% 和 33.11%, 这是由于本文在考虑模型更新时, 选择模型估计不确定度大的个体更新训练样本, 有利于模型性能的改善.

综上所述, 衡量含噪区间函数中的噪声强度是可行的; 针对含有不同噪声强度的训练样本, 考虑对模型训练的影响, 采用本文方法构建的加权多输出高斯过程模型, 可以进一步提高模型拟合性能和预测精度; 基于预测均值和不确定度的适应值估计策略, 以及模型管理方法, 可有效提高基于代理模型的 GA 的搜索效率. 基于上述结果, 我们利用本文 w-MOGP 构建交互式遗传算法中用户认知代理模

表 2 模型管理方法的比较结果

Table 2 Compared results of three model management methods

| | 进化代数 | | 更新次数 | | 更新前模型精度 | | 更新后模型精度 | |
|------|-------------|-------------|------------|-------------|--------------|--------------|--------------|--------------|
| | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 |
| 随机选择 | 31.6 | 9349.94 | 5.05 | 57174.16 | 25.34 | 24.16 | 18.86 | 13.39 |
| 最优选择 | 8.65 | 7.13 | 2.65 | 2.63 | 25.34 | 17.64 | 16.95 | 9.88 |
| 本文方法 | 9.45 | 7.45 | 1.5 | 0.25 | 20.76 | 19.20 | 11.79 | 21.34 |

型, 通过在服装设计系统中的应用, 进一步验证融合 w-MOGP 的交互式遗传算法性能。

4.2 在服装设计系统中的应用

服装设计系统是交互式遗传算法的典型应用平台^[4], 因此, 本文采用该平台验证所提算法的有效性。将本文所提基于加权多输出高斯过程模型的交互式遗传算法 (IGA-wMOGP) 与进化个体区间适应值交互式遗传算法 (IGA-IF)、基于径向基神经网络构造代理模型的进化个体区间适应值交互式遗传算法 (IGA-RBFNN), 以及基于文献 [18] 的多输出高斯过程构造代理模型的交互式遗传算法 (IGA-MOGP) 比较, 说明本文算法在找到满意解和减轻用户疲劳方面的性能。

在本组实验中, 考虑算法如下两个方面的性能:

1) 本文所提加权两输出高斯过程模型对用户认知的拟合性能; 2) 所构建代理模型对区间适应值交互式遗传算法性能的影响。为了尽可能消除一人评价带来的主观性影响, 本实验由 10 人参与, 这些人只需根据实验要求 (如搜索到指定的服装) 对进化服装进行评价, 驱动算法运行即可; 交互式遗传算法与遗传算法类似, 优化过程存在大量不确定性, 考虑参与者评价的易疲劳性, 算法不易运行过多次数, 因此, 这里各算法独立运行 10 次, 统计运行结果。

4.2.1 实验设置及操作界面

本文讨论的服装设计系统主要是面向非服装设计专业的用户, 以帮助其尽快找到喜欢的服装, 系统相对简单。系统的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, 则总的搜索空间包含 $32 \times 32 \times 16 \times 16 = 262144$ 个解。进化个体编码方式为: 上衣和裙子款式采用 5 位二进制编码, 其颜色采用 4 位二进制编码。系统采用 Visual Basic 6.0 编程实现。

四类算法均采用相同的遗传算子及操作参数: 采用规模为 2 的联赛选择算子; 单点交叉, 交叉概率为 0.6; 单点变异, 变异概率为 0.02; IGA-IF 种群规模为 10, 本文算法和 IGA-RBFNN、IGA-MOGP 种群规模为 200, 用户每代参与评价的个体最多为 10 个, 即 K 均值聚类的 $K = 10$; 进化个体适应值变化范围设为 $[0, 1000]$ 。此外, IGA-RBFNN 中, 经多次调试后, *newrb* 函数的参数 *goal* 和 *spread* 分别为 0.001 和 0.6; 用户在进化过程中, 一般经过 3~4 代后, 其之前评价的信息已遗忘较多, 因此, 本文算法的时效性阈值 T_0 取 4。

系统交互界面如图 4 所示, 可分为 3 个模块。界面最左侧为统计信息区域, 显示进化到当前代为止, 用户参与评价的互异个体数、当前进化代数、当代

用户评价耗时、当前最优进化个体的表现型及其适应值, 给用户关于进化过程中的一些最直观的信息。界面的中间部分是用户评价区域, 呈现给用户 10 个进化个体的表现型 (这里即完整的服装信息), 用户通过拖拽每个进化个体下面的滚动条给个体赋予适应值, 这里进化个体适应值采用区间表示, 因此, 每个进化个体下方有两个滚动条。最后, 是系统所需的控制按钮部分, 位于界面的最下方, 包括初始化、代理模型构建和更新, 以及进化控制按钮等。当算法结束时, 用户可选择“退出”按钮, 结束进化过程, 系统将当前得到的如图 5 所示最优进化个体表现型呈现给用户。



图 4 系统交互界面

Fig. 4 Interface of human-computer interaction



图 5 优化结果

Fig. 5 Optimal result

4.2.2 结果与分析

1) 代理模型对用户认知的拟合性能

运行服装进化设计系统, 在每次点击“建模”按钮后, 基于相同训练样本集, 分别采用 w-MOGP、RBFNN 和 MOGP 构建代理模型, 比较三类模型的均方拟合误差, 图 6 给出了 10 次运行过程中随机记录的 20 次建模结果, 其均值、方差和 t 测

试值如表 3 所示.

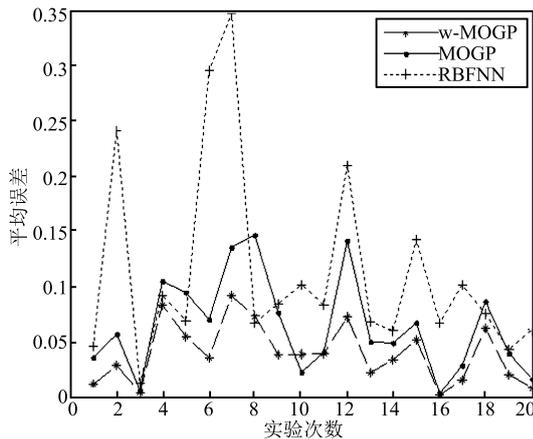


图 6 相同训练样本下模型拟合误差

Fig. 6 Approximate errors of three models

表 3 相同训练样本下模型拟合误差统计结果

Table 3 Statistical results of three models

| | 均值 | 方差 | <i>t</i> 检验 |
|--------|---------------|---------------|-------------|
| w-MOGP | 0.0392 | 0.0007 | — |
| MOGP | 0.0633 | 0.0018 | 0.0218 |
| RBFNN | 0.1135 | 0.0077 | 0.0009 |

从图 6 可以看出, 对于相同训练样本, 在 20 次建模过程中, 采用本文所提 w-MOGP 算法所得代理模型拟合误差只有在第 10 次时略高于 MOGP, 在第 8 次时略高于 RBFNN, 其余建模过程中, w-MOGP 拟合误差均小于上述两种算法, 表明该模型可以更好地拟合用户认知. 表 3 数据进一步验证了上述结论, 采用本文算法, 模型平均误差为 0.0392, 方差为 0.0007, 均小于 MOGP 模型的 0.0633 和 0.0018, RBFNN 模型的 0.1135 和 0.0077; 进一步地, 我们采用 *t* 检验, 检验本文所提模型拟合误差相比于其他两种方法是否具有显著性改善. 可得, w-MOGP vs. MOGP, *t* 检验概率值为 0.0218, 而 w-MOGP

vs. RBFNN, 概率值为 0.0009, 两个概率值均小于检验水平 0.05, 说明本文所提 w-MOGP 明显优于 MOGP 和 RBFNN, 与第 4.1 节基于函数的实验结论一致.

2) 融合 w-MOGP 模型的 IGA 性能

本文的目的是结合交互式遗传算法适应值评价的特性, 提出 w-MOGP 模型以拟合用户认知, 并利用其代替用户评价部分进化个体, 以减轻用户疲劳, 增强算法搜索性能. 针对此, 这里设定在找到如图 5 所示满意服装或与该服装相似度大于 75% 的服装前提下, 从用户参与评价的总互异进化个体数、用户耗时、总进化代数、模型更新次数等方面, 比较本文算法与 IGA-IF、IGA-RBFNN、IGA-MOGP 的差异, 以说明本文所提算法的有效性. 其中, 用户评价个体数 (指在找到固定满意解时, 用户参与评价的个体总数) 和评价耗时反映了用户评价负担; 进化代数列刻画算法的收敛特性; 模型更新次数可反映算法整体计算复杂性, 以及代理模型对用户认知的拟合和泛化性能. 所有算法独立运行 10 次, 统计结果如表 4 所列.

从表 4 可以看出, 对于用户评价负担, 本文算法用户评价了 34.5 个个体, 而 IGA-IF 评价了 349 个, 约为本文算法的 10 倍, IGA-RBFNN 用户评价 114.8 个个体, 是本文算法的 3 倍多, IGA-MOGP 用户评价 44.8 个个体, 也明显高于本文算法; 从用户评价耗时上看, 本文算法用了 5'28", 远低于 IGA-IF 的 18'50", 也少于 IGA-RBFNN 和 IGA-MOGP. 这些数据说明, 采用本文算法大大减轻了用户的评价负担, 有效减小了评价疲劳. 从算法收敛角度来看, IGA-IF 和 IGA-RBFNN 分别运行了 60.5 代和 41.6 代, 明显多于 IGA-MOGP 的 18 代和 IGA-wMOGP 的 16.7 代, 其中, 本文算法收敛最快. 由于 IGA-MOGP 和 IGA-wMOGP 种群规模较大, 因此, 增加了算法找到满意解的概率, 可使得算法收敛速度加快, 此外, 本文所提 w-MOGP 对用户认知具有更强的拟合性能, 这将减小对进化搜索的误导作用, 也有利于加快算法收敛. 而这一结论也

表 4 四种交互式遗传算法比较结果

Table 4 Compared results of four algorithms

| | 用户评价修正个体数 | | 用户耗时 | | 进化代数 | | 模型更新次数 | |
|------------------|-------------|-------------|--------------|--------------|-------------|------------|------------|------------|
| | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 | 均值 | 方差 |
| IGA-IF | 349 | 108.78 | 18'50" | 13'40" | 60.5 | 20.68 | — | — |
| IGA-RBFNN | 114.8 | 31.96 | 8'41" | 2'54" | 41.6 | 16.14 | 7.7 | 2.1 |
| IGA-MOGP | 44.8 | 7.22 | 6'32" | 1'01" | 18 | 3.49 | 5.8 | 1.47 |
| IGA-wMOGP | 34.5 | 7.68 | 5'28" | 0'41" | 16.7 | 2.1 | 3.9 | 1.3 |

可从模型更新次数方面看出, 对于本文算法, 在平均 16.7 代中, 模型更新次数平均为 3.9, 均小于其他两类基于代理模型的交互式遗传算法, 说明本文所提代理模型具有更好的拟合性能和泛化性能, 这也与本节第 1 组实验结论一致。

综上所述, 本文算法通过设计加权多输出高斯过程回归模型构建用户评价代理模型, 可有效改善模型预测性能, 更好地拟合和跟踪用户认知, 减少对进化搜索的误导, 从而有效减轻用户疲劳、增加算法找到满意解的概率、提高交互式遗传算法搜索性能。

5 结论

本文针对基于代理模型减轻用户疲劳的交互式遗传算法, 考虑用户评价不确定性对代理模型训练样本的影响, 提出加权多输出高斯过程代理模型构建机制. 采用区间适应值评价模式刻画用户评价的不确定性, 进而提取学习样本噪声特性; 根据噪声水平, 设置各样本相应权重系数, 以反映各样本对于代理模型的贡献程度, 构建两输出高斯过程模型拟合用户评价的区间适应值; 充分利用预测均值和预测不确定度, 给出了适应值估计策略, 以及优势个体选择方法和模型管理. 算法在含噪区间函数中的应用, 验证了本文所提加权多输出高斯过程模型的可行性和有效性; 在服装设计系统中的应用, 表明该算法可有效减轻用户疲劳, 增强交互式遗传算法的搜索性能, 这将为交互式遗传算法在更多复杂领域的应用提供技术保障。

在基于代理模型的交互式遗传算法中, 除了需要确定 GA 操作的参数外, 还需要确定模型训练参数和样本时效性分割阈值等, 这些都会影响算法性能, 是需要进一步考虑的问题。

References

- Holland J H. *Adaptation in Natural and Artificial Systems*. Michigan, USA: The University of Michigan Press, 1975
- Kim H S, Cho S B. Application of interactive genetic algorithm to fashion design. *Engineering Applications of Artificial Intelligence*, 2000, **13**(6): 635–644
- Simons C L, Parmee I C. Elegant object-oriented software design via interactive, evolutionary computation. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 2012, **42**(6): 1797–1805
- Solomon C J, Gibson S J, Mist J J. Interactive evolutionary generation of facial composites for locating suspects in criminal investigations. *Applied Soft Computing*, 2013, **13**(7): 3298–3306
- Takagi H. Interactive evolutionary computation: fusion of the capabilities of EC optimization and human evaluation. *Proceedings of the IEEE*, 2001, **89**(9): 1275–1296
- Liu Xiao-Lu, Chen Ying-Guo, He Ren-Jie, Chen Ying-Wu. Application of Kriging surrogate model to optimization of earth observation satellite system. *Acta Automatica Sinica*, 2012, **38**(1): 120–127
(刘晓路, 陈盈果, 贺仁杰, 陈英武. Kriging 代理模型在对地观测卫星系统优化中的应用. *自动化学报*, 2012, **38**(1): 120–127)
- Sun Xiao-Yan, Ren Jie, Gong Dun-Wei. Interval-fitness interactive genetic algorithms with varying population size based on semi-supervised learning. *Control Theory and Applications*, 2011, **28**(5): 610–618
(孙晓燕, 任洁, 巩敦卫. 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. *控制理论与应用*, 2011, **28**(5): 610–618)
- Li Hong-Wei, Liu Yang, Lu Han-Qing, Fang Yi-Kai. Gaussian processes classification combined with semi-supervised kernels. *Acta Automatica Sinica*, 2009, **35**(7): 888–895
(李宏伟, 刘扬, 卢汉清, 方亦凯. 结合半监督核的高斯过程分类. *自动化学报*, 2009, **35**(7): 888–895)
- Gong D W, Guo G S. Interactive genetic algorithms with interval fitness of evolutionary individuals. *Dynamics of Continuous. Discrete and Impulsive Systems, Series B*, 2007, **14**(S2): 446–450
- Biles J A, Anderson P G, Loggi L W. Neural network fitness functions for a musical IGA. In: *Proceedings of the 1996 International Symposium on Intelligent Industrial Automation and Soft Computing*. Berlin, Germany: Springer, 1996. 39–44
- Zhou Yong, Gong Dun-Wei, Hao Guo-Sheng, Guo Yi-Nan, Sun Xiao-Yan. Neural network based phase estimation of individual fitness in interactive genetic algorithm. *Control and Decision*, 2005, **20**(2): 234–236, 240
(周勇, 巩敦卫, 郝国生, 郭一楠, 孙晓燕. 交互式遗传算法基于 NN 的个体适应度分阶段估计. *控制与决策*, 2005, **20**(2): 234–236, 240)
- Wang S F, Wang X F, Takagi H. User fatigue reduction by an absolute rating data-trained predictor in IEC. In: *Proceedings of the 2006 IEEE Congress on Evolutionary Computation*. Vancouver, B. C., Canada: IEEE, 2006. 2195–2200
- Llorà X, Sastry K, Goldberg D E, Gupta A, Lakshmi L. Combating user fatigue in iGAs: Partial ordering, support vector machines, and synthetic fitness. In: *Proceedings of the 2005 Conference on Genetic and Evolutionary Computation*. Washington DC: IEEE, 2005. 1363–1370
- Ecemis I, Bonabeau E, Ashburn T. Interactive estimation of agent-based financial markets models: modularity and learning. In: *Proceedings of the 2005 Genetic and Evolutionary Computation Conference*. New York: ACM, 2005. 1897–1904
- Gong Dun-Wei, Ren Jie, Sun Xiao-Yan. Neural network surrogate models of interactive genetic algorithms with individual's interval fitness. *Control and Decision*, 2009, **24**(10): 1522–1525, 1530
(巩敦卫, 任洁, 孙晓燕. 区间适应值交互式遗传算法神经网络代理模型. *控制与决策*, 2009, **24**(10): 1522–1525, 1530)

- 16 Wang K, Bui V, Petraki E, Abbass H A. Evolving story narrative using surrogate models of human judgement. *Advances in Intelligent Systems and Computing*, 2013, **208**(1): 653–661
- 17 Sun X Y, Gong D W, Ma X P. Directed fuzzy graph-based surrogate model-assisted interactive genetic algorithms with uncertain individual's fitness. In: *Proceedings of the 2009 IEEE Congress on Evolutionary Computation*. Trondheim: IEEE, 2009. 2395–2402
- 18 Boyle P, Frean M. Multiple Output Gaussian Process Regression. Technical Report CS-TR-05/2, School of Mathematical and Computing Sciences, Victoria University of Wellington, Wellington, New Zealand, 2005
- 19 Sun X Y, Gong D W, Jin Y C, Chen S S. A new surrogate-assisted interactive genetic algorithm with weighted semisupervised learning. *IEEE Transactions on System, Man, and Cybernetics: Part B*, 2013, **43**(2): 685–698
- 20 Multi-output Gaussian Process, Matlab Software [Online], available: <http://staffwww.dcs.shef.ac.uk/people/N.Lawrence/multigp/>, March 25, 2013



孙晓燕 中国矿业大学信息与电气工程学院教授. 主要研究方向为交互式进化计算, 多目标优化.

E-mail: xysun78@126.com

(**SUN Xiao-Yan** Professor at the School of Information and Electrical Engineering, China University of Mining and Technology. Her research interest covers interactive evolutionary algorithm and multi-objective optimization.)

interest covers interactive evolutionary algorithm and multi-objective optimization.)



陈姗姗 中国矿业大学控制理论与控制工程专业硕士研究生. 主要研究方向为交互式进化优化理论及其应用. 本文通信作者.

E-mail: chenshanshan218@163.com

(**CHEN Shan-Shan** Master student in control theory and control engineering at China University of Mining and Technology. Her research interest covers interactive evolutionary optimization and its applications. Corresponding author of this paper.)

ing and Technology. Her research interest covers interactive evolutionary optimization and its applications. Corresponding author of this paper.)



巩敦卫 中国矿业大学信息与电气工程学院教授. 主要研究方向为智能优化, 软件工程. E-mail: dwgong@vip.163.com

(**GONG Dun-Wei** Professor at the School of Information and Electrical Engineering, China University of Mining and Technology. His research interest covers intelligence optimization and software engineering and interactive evolutionary multi-objective optimization.)

software engineering and interactive evolutionary multi-objective optimization.)



张勇 中国矿业大学信息与电气工程学院副教授. 主要研究方向为特征选择, 微粒群优化算法.

E-mail: yongzhang401@126.com

(**ZHANG Yong** Associate professor at the School of Information and Electrical Engineering, China University of Mining and Technology. His research interest covers feature selection and particle swarm intelligence.)

interest covers feature selection and particle swarm intelligence.)