

文章编号: 1001-0920(2009)10-1522-04

区间适应值交互式遗传算法神经网络代理模型

巩敦卫, 任 洁, 孙晓燕

(中国矿业大学 信息与电气工程学院, 江苏 徐州 221008)

摘 要: 为了解决交互式遗传算法的用户疲劳问题, 提出区间适应值交互式遗传算法神经网络代理模型. 首先, 对用户已评价个体的基因型及其适应值进行采样以训练神经网络, 使其逼近区间适应值的上下限; 然后, 利用神经网络代理模型, 评价后续的部分进化个体, 并不断更新训练数据和代理模型, 以保证逼近精度; 最后, 对算法性能进行了定量分析, 并将其应用于服装进化设计系统. 分析结果表明, 所提算法在减轻用户疲劳的前提下, 具有更多找到满意解的机会.

关键词: 遗传算法; 交互; 区间适应值; 神经网络; 代理模型

中图分类号: TP18

文献标识码: A

Neural network surrogate models of interactive genetic algorithms with individual's interval fitness

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

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou 221008, China. Correspondent: REN Jie, E-mail: renjie19850210@sina.com)

Abstract: This paper presents a neural network surrogate model of interactive genetic algorithms with an individual's interval fitness in order to solve the problem of user fatigue. The genotype and the fitness of individuals evaluated by the user are sampled to train a neural network to approximate the upper limit and the lower limit of an individual's interval fitness. The trained surrogate model is applied to evaluate individuals in the subsequent evolutions. The training data and the surrogate model are continuously updated during the evolutions to guarantee the performance in precision of the surrogate model. In addition, the performance of the proposed algorithm is quantitatively analyzed, which is applied to a fashion evolutionary design system. The results show that the proposed algorithm has more opportunities to look for satisfactory solutions on the condition of alleviating user fatigue.

Key words: Genetic algorithms; Interaction; Interval fitness; Neural network; Surrogate model

1 引 言

交互式遗传算法(IGAs)是 20 世纪 80 年代中期提出的解决隐式性能指标优化问题的有效方法^[1]. 它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, 该算法已成功应用于人脸识别、服装设计、乐曲创作、助听器设计等领域^[2-5].

在交互式遗传算法中, 进化个体对性能指标的满足程度由用户评价. 长时间的用户评价导致其疲劳, 因此, 用户疲劳问题成为交互式遗传算法的核心问题. 已有研究表明, 采用合适的代理模型代替用户估计进化个体的适应值是一种有效减轻用户疲劳的

方法. 如文献[6]根据待评价进化个体与最优个体的距离和角度, 采用模糊推理估计进化个体适应值; [7]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, 减少了用户评价进化个体的数量; [8]基于支持向量机评价进化个体; [9]提出在交互式遗传算法中, 利用径向基函数(RBF)学习用户的评价, 并对金融市场建模. 但已有的交互式遗传算法代理模型均针对进化个体适应值为精确数的情况, 并没有考虑交互式遗传算法中存在的不确定性.

实际中, 人的认知过程具有模糊性和渐进性, 相应的, 人对进化个体的评价也具有模糊性和渐进性.

收稿日期: 2008-11-15; 修回日期: 2009-01-07.

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).

作者简介: 巩敦卫(1970—), 男, 江苏徐州人, 教授, 博士生导师, 从事智能优化与控制的研究; 任洁(1985—), 女, 河北张家口人, 硕士生, 从事遗传算法的研究.

因此,采用精确数值表示进化个体适应值难以反映上述特性,而采用不确定数则可较好地解决上述问题.对此,人们已经提出了进化个体区间适应值交互式遗传算法(IGA-IIF)^[10].采用区间表示进化个体适应值会带来一系列问题:1) 基于区间的个体优劣比较与传统基于精确适应值的交互式遗传算法完全不同,文献[10]提出了区间概率占优方法;2) 如何从进化个体区间适应值中提取反映种群进化的信息,并用于指导后续的种群进化,文献[11]给出了基于进化个体区间适应值的自适应交叉和变异概率;3) 如何减少用户评价进化个体的数量,从而减轻用户疲劳,本文将给出解决该问题的方法.

2 进化个体区间适应值交互式遗传算法

不失一般性,本文考虑如下优化问题:

$$\begin{aligned} & \max f(x), \\ & \text{s. t. } x = (x_1, x_2, \dots, x_l) \in S \in R^l. \end{aligned} \quad (1)$$

其中: $f(x)$ 是被优化的隐式性能指标, x 是 l 维决策变量, S 是其取值范围.在不引起混淆的情况下,仍将相应的进化个体及搜索空间分别记为 x 和 S .

采用交互式遗传算法解决问题(1).记 $X(t)$ 为第 t 代进化种群,规模为 N_t , $x^k(t)$ 为第 k 个进化个体, $k = 1, 2, \dots, N_t$.由于用户对 $x^k(t)$ 的认知具有模糊性,以致难以准确地确定 $x^k(t)$ 的适应值,但容易给出其范围,这个范围可用区间表示.因此, $x^k(t)$ 的适应值 $f(x^k(t))$ 可以表示为^[10]

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

其中 $\underline{f}(x^k(t))$ 和 $\bar{f}(x^k(t))$ 分别表示用户对进化个体 $x^k(t)$ 评价的下限和上限.

3 基于进化个体区间适应值的神经网络代理模型

本节建立神经网络代理模型,代替用户估计进化个体适应值.其思想是:首先,通过进化个体区间适应值交互式遗传算法得到一定数量的可靠数据,训练神经网络代理模型;然后,利用该模型估计后续部分进化个体适应值,从而减少用户评价进化个体的数量,减轻用户疲劳.为了保证代理模型的逼近精度,在合适的时机,基于新的数据更新代理模型.

3.1 代理模型训练数据获取与构建

为了获得神经网络代理模型,首先通过IGA-IIF获取训练数据,这些数据分别作为构造神经网络的学习样本 $D_1(t)$ 和测试样本 $D_u(t)$,即

$$\begin{aligned} D_1(t) &= \{(x^k, f(x^k)), k = 1, 2, \dots, N_1\}, \\ D_u(t) &= \{(x^l, f(x^l)), l = 1, 2, \dots, N_u\}. \end{aligned} \quad (3)$$

考虑到3层前馈神经网络的逼近能力^[12],本文采用3层前馈神经网络作为代理模型,文献[13]给

出了确定隐含层单元数 H 的方法.神经网络模型如图1所示.

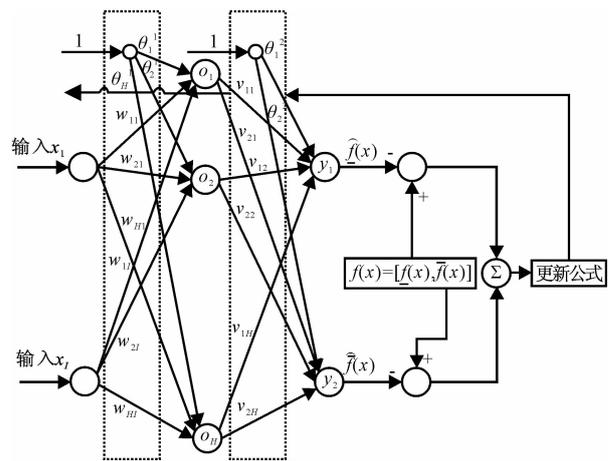


图 1 区间适应值神经网络代理模型

基于学习样本集,采用BP算法更新神经网络的参数.训练误差可表示为

$$\begin{aligned} e_1 &= \frac{1}{N_1} \sum_{k=1}^{N_1} e_{1k}, \\ e_{1k} &= \frac{1}{2} [(f(x^k) - \hat{f}(x^k))^2 + \\ & (\bar{f}(x^k) - \hat{f}(x^k))^2]. \end{aligned} \quad (4)$$

利用梯度下降法训练神经网络.设定训练误差阈值为 e_1^0 ,当 $e_1 \leq e_1^0$ 时,停止神经网络训练.

为了测试训练后的神经网络的泛化能力,将 D_u 中的进化个体 $x^l(l = 1, 2, \dots, N_u)$ 作为神经网络的输入,可得到神经网络的输出 $\hat{f}(x^l) = [\underline{\hat{f}}(x^l), \bar{\hat{f}}(x^l)]$,根据它与 $f(x^l)$ 的差异,定义如下测试误差:

$$\begin{aligned} e_i &= \frac{1}{2N_u} \sum_{l=1}^{N_u} (e^2(x^l) + \bar{e}^2(x^l)), \\ \underline{e}(x^l) &= \underline{\hat{f}}(x^l) - \underline{f}(x^l), \\ \bar{e}(x^l) &= \bar{\hat{f}}(x^l) - \bar{f}(x^l). \end{aligned} \quad (5)$$

e_i 越小,表明神经网络的泛化能力越强.设定测试误差阈值为 e_i^0 ,当 $e_i \leq e_i^0$ 时,认为神经网络的泛化能力已达到要求,可应用于后续进化个体适应值的估计;否则,重新训练该网络.

3.2 代理模型更新

神经网络代理模型是基于前几代用户评价的进化个体数据建立的.在后续进化过程中,会产生大量新的进化个体,这时,用户对其中某些进化个体的评价很可能与代理模型估计的适应值有较大的差别.这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.

首先考虑代理模型的更新时机. 种群进化的目的是为了找到优化解, 而优化解一般来自于每代进化的最优个体, 因此, 利用神经网络评价进化个体, 应该保证估计的每代最优个体的适应值与用户评价的适应值不能有太大差异. 否则, 就表明利用现有的代理模型估计进化个体适应值已不再合适, 需要重新训练. 考虑 $X(t)$, 用户评价后得到的最优个体为 $x^b(t)$, 给出的适应值为 $f(x^b(t)) = [\underline{f}(x^b(t)), \bar{f}(x^b(t))]$, 代理模型估计的适应值为 $\hat{f}(x^b(t)) = [\underline{\hat{f}}(x^b(t)), \bar{\hat{f}}(x^b(t))]$, 若

$$\max\{ | f(x^b(t)) - \hat{f}(x^b(t)) |, | \bar{f}(x^b(t)) - \bar{\hat{f}}(x^b(t)) | \} \geq f^0, \quad (6)$$

则重新训练神经网络代理模型, 其中 f^0 为代理模型更新阈值.

由于代理模型偏离了用户当前的认知, 为了保证逼近性能, 更新代理模型的数据应是反映用户“最新”认知的. 因此, 应选择最近几代用户评价过的进化个体及其适应值作为更新数据, 也可重新评价一些新个体加入数据集, 并再次训练神经网络.

3.3 基于神经网络的进化个体适应值估计

当代理模型的精度达到要求后, 在种群后续进化过程中, 可利用该代理模型代替用户估计进化个体区间适应值. 用户每代只评价代理模型认为最优的进化个体, 并作为后续训练神经网络的数据, 这样可大大减少用户评价进化个体的数量, 从而减轻用户疲劳.

需要注意的是, 当进化个体 $x^k(t)$ 的区间适应值宽度较窄时, 由于神经网络逼近精度的限制, 利用神经网络代理模型估计进化个体适应值, 可能出现 $\underline{f}(x^k(t)) > \underline{\hat{f}}(x^k(t))$ 的情况. 为保证区间的有效性, 采用下式对其进行调整:

$$\begin{aligned} h^-(x^k(t)) &= \begin{cases} \underline{f}(x^k(t)), \underline{\hat{f}}(x^k(t)) \leq \underline{\hat{f}}(x^k(t)); \\ \frac{1}{2}(\underline{f}(x^k(t)) + \underline{\hat{f}}(x^k(t))), \\ \underline{\hat{f}}(x^k(t)) > \underline{\hat{f}}(x^k(t)); \end{cases} \\ h^+(x^k(t)) &= \begin{cases} \bar{f}(x^k(t)), \bar{\hat{f}}(x^k(t)) \leq \bar{\hat{f}}(x^k(t)); \\ \frac{1}{2}(\bar{f}(x^k(t)) + \bar{\hat{f}}(x^k(t))), \\ \bar{\hat{f}}(x^k(t)) > \bar{\hat{f}}(x^k(t)). \end{cases} \end{aligned} \quad (7)$$

则有 $h^-(x^k(t)) \leq h^+(x^k(t))$. 那么, $\hat{f}(x^k(t))$ 可表示为

$$\hat{f}(x^k(t)) = [h^-(x^k(t)), h^+(x^k(t))]. \quad (8)$$

4 性能分析

本节考察本文方法在减轻用户疲劳方面的性能, 并与无代理模型的基于区间适应值的交互式遗传算法比较.

设 T 为进化终止代数, T_1 和 T_2 分别是应用代理模型前和应用代理模型后的进化代数, 因此有 $T_1 + T_2 = T$. 对于无代理模型交互式遗传算法, 用户评价的进化个体数为 $TN_i = T_1N_i + T_2N_i$. 对于本文方法, 用户评价的进化个体数为 $T_1N_i + T_2$. 因此, 不需要用户评价的进化个体数为 $T_2(N_i - 1)$. 因为 $N_i - 1 > 0$, 所以 $T_2(N_i - 1) > 0$. 可以看出, 在进化相同代数的情况下, 利用本文方法可减少用户评价进化个体的数量, 从而能有效减轻用户疲劳.

5 在服装进化设计系统中的应用

服装进化优化设计系统是一类典型的隐式性能指标优化问题, 且已成为交互式遗传算法常用的验证平台, 为了说明本文算法的性能, 将其应用于该系统中, 并与 IGA-IIF 比较.

5.1 参数设置

两个算法采用完全相同的遗传操作与控制参数, 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不小于 0, 上限不大于 100, 种群规模为 8. 根据文献[13]的方法求取 H , 其他参数如表 1 所示.

表 1 参数取值

e_1^0	e_t^0	f^0	N_1	N_u	H
0.005	0.0144	15	32	8	18

5.2 实验结果与分析

系统界面如图 2 所示. 开始时, 单击“初始化”按钮, 系统自动生成初始进化种群, 并通过人机交互界面显示表现型. 用户根据偏好评价这些进化个体后, 单击“下一代”按钮, 种群进行遗传操作, 生成子代种群. 系统自动把前 5 代用户评价的结果写入数据集. 种群进化到第 5 代之后, 若用户单击“NN 评价”按钮, 则进行神经网络的训练和适应值估计. 在后续进化过程中, 用户只对每代的最优个体进行评价. 若出现 3.2 节的情况, 则更新神经网络. 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, 获得的最终优化结果如图 3 所示.

由图 3 可知, 在固定优化目标条件下, 从用户评价个体数、评价耗时、进化系统评价的总个体数和总



图 2 系统界面



图 3 优化结果

的进化代数 4 个方面比较本文算法和 IGA-IIF 的性能差异. 每种方法独立运行 10 次后计算平均值, 结果如表 2 所示.

表 2 统计结果

指标	本文算法	IGA-IIF
用户评价个体数	186.5	365
用户评价耗时	11'36"	21'
评价总个体数	420	365
进化代数	71	63

从表 2 可知, 在找到相同优化解的前提条件下, 本文方法可以大大减少用户评价的个体数量, 从用户评价耗时上看, IGA-IIF 的用户评价耗时几乎是本文算法的 2 倍, 因此, 本文算法可大大减轻用户疲劳. 此外, 虽然本文算法用户评价的进化个体数少了, 但由于在进化过程中采用了代理模型, 搜索到的进化个体总数多于 IGA-IIF 方法搜索到的个体总数, 这说明本文算法具有更多找到满意解的机会. 但也应看到, 可能由于神经网络的逼近性能, 需多次训练神经网络, 因此, 本文算法的进化代数大于 IGA-IIF. 但这并不违背本文的初衷——减轻用户疲劳. 综上所述, 与 IGA-IIF 相比, 本文算法可大大减轻用户疲劳, 改进算法搜索性能.

6 结 论

本文采用神经网络构造代理模型近似用户对进化个体的评价, 从而减轻用户疲劳. 神经网络的输出有两个, 分别逼近进化个体适应值的上限和下限. 基于用户评价的数据训练神经网络后, 采用该网络评价后续的进化个体. 为了保证代理模型的逼近性能,

根据用户和代理模型对最优个体的评价偏差, 确定代理模型的更新时机, 并基于用户“最新”认知, 选择用户评价的“最近”数据更新代理模型. 在服装进化设计系统中的应用结果表明, 本文方法可减轻用户疲劳, 并增加寻找满意解的机会. 当进化个体适应值采用其他不确定表示方式, 如模糊数时, 如何构建交互式遗传算法代理模型以减轻用户疲劳, 将是下一步需要研究的问题.

参考文献 (References)

- [1] Dawkins R. The blind watchmaker [M]. Essex: Longman, 1986.
- [2] Caldwell C, Johnston V S. Tracking a criminal suspect through ‘face-space’ with a genetic algorithm[C]. Proc of the 4th Int Conf on Genetic Algorithms. San Diego CA, 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. Music composition with interactive evolutionary computation[C]. Proc of the 3rd Int Conf on Generative Art. Milan, 2000: 215-226.
- [5] Takagi H, Ohsaki M. Interactive evolutionary computation-based hearing aid fitting[J]. IEEE Trans on Evolutionary Computation, 2007, 11(3): 414-427.
- [6] Sugimoto F, Yoneyama M. An evaluation of hybrid fitness assignment strategy in interactive genetic algorithm[C]. Proc of the 5th Australasia-Japan Joint Workshop on Intelligent and Evolutionary Systems. New Zealand, 2001: 62-69.
- [7] 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 genetical algorithm[J]. Control and Decision, 2005, 20(2): 234-236.)
- [8] Llorca X, Sastry K, Goldberg D E, et al. Combating user fatigue in lgas: Partial ordering, support vector machines, and synthetic fitness[C]. Proc of Genetic Evolutionary Computation Conf. Washington D C, 2005: 1363-1370.
- [9] Ecemis I, Bonabeau E, Ashburn T. Interactive estimation of a agent-based financial markets models: Modularity and learning [C]. Proc of Genetic and Evolutionary Computation Conf. Washington D C: ACM Press, 2005: 1897-1904.