

文章编号: 1001-0920(2009)04-0551-06

基于分布估计算法的磁浮列车故障综合评判

龙志强, 蔡 楹, 徐 昕

(国防科技大学 机电工程与自动化学院, 长沙 410073)

摘 要: 针对使用传统模糊综合评判方法进行故障级别评判时模型参数难以确定的问题, 提出一种基于分布估计算法(EDA)的模糊综合故障评判方法. 该方法利用 EDA 进行模糊评判模型的进化学习, 能有效实现模糊模型参数的自动优化, 并具有模型易于理解、计算效率高的优点. 通过对磁浮列车悬浮系统的仿真实验, 结果显示基于分布估计算法的模糊故障综合评判方法能获得优于传统进化算法和其他机器学习方法的评判效果, 具有较好的应用价值.

关键词: 磁浮列车; 模糊综合评判; 进化算法; 分布估计算法; 机器学习

中图分类号: TP27 **文献标识码:** A

Comprehensive fault evaluation on maglev train based on estimation of distribution algorithms

LONG Zhi-qiang, CAI Ying, XU Xin

(College of Mechatronics Engineering and Automation, National University of Defence Technology, Changsha 410073, China. Correspondent: LONG Zhi-qiang, E-mail: zhqlong@263.net)

Abstract: To solve the problem of model parameter selection of traditional methods, a fuzzy fault evaluation method based on the estimation of distribution algorithms (EDAs) is presented in this paper. In the proposed method, fuzzy fault evaluation models are learned by using EDAs, which makes the parameters of that optimized. And the obtained model has the advantages of easy understandability and high computational efficiency. Simulation results on fault evaluation of maglev trains illustrate that the fuzzy fault evaluation methods based on EDAs have high precision and the performance is better than other evolutionary algorithms and machine learning methods, and it is of great value in engineering application.

Key words: Maglev train; Comprehensive fault evaluation; Evolutionary algorithms; EDAs; Machine learning

1 引 言

磁浮列车系统结构复杂, 车上电气设备众多, 很难保证在列车运行过程中所有设备时刻都能保持正常工作. 除增强系统的容错性能外, 对已发生的部件故障或子系统故障对整车的综合影响做出正确评估, 指导列车司机或自动控制系统采取相应措施以保障旅客的生命安全均有十分重要的作用.

模糊综合评价是国内外对轮轨列车故障等级进行评价而广泛采用的一种方法^[2]. 该方法结构简单、易于理解且执行(计算)效率较高, 缺点在于模糊模型参数(重要程度参数和隶属度参数)的制定和修改困难^[3]. 特别是对磁浮列车系统进行故障级别评判而言, 模型参数的数目庞大, 单纯依赖专家进行制定

难以准确. 因为评判模型参数的合理与否对故障级别最终判定的正确性有着重大影响, 所以需要研究模糊评价模型的参数自动确定与优化方法.

近年来, 机器学习的蓬勃发展令人关注. 其中, 发展迅速的进化学习为各种复杂参数优化问题的解决提供了重要的方法和工具. 进化学习基于数据驱动和逼近建模的思想, 能够结合给定模型利用实际观测数据进行逼近建模, 并且在建模过程中采用进化算法来实现模型参数的自动优化^[4,5].

分布估计算法(EDA)是进化计算领域兴起的一类新型随机优化算法, 是当前国际计算智能领域的研究热点^[2]. EDA 继承了遗传算法的进化思想, 却又不同于大多数进化计算方法将交叉和变异操作

收稿日期: 2008-03-13; 修回日期: 2008-06-08.

基金项目: 国家自然科学基金项目(60874015); 湖南省自然科学基金项目(08JJ3129).

作者简介: 龙志强(1967—), 男, 江西吉安人, 研究员, 从事故障诊断、容错控制等研究; 蔡楹(1984—), 男, 江西南城人, 博士生, 从事系统仿真、故障诊断等研究.

作为产生新种群必要工具的做法,而是通过估计和模拟被选择个体的联合概率分布来实现新种群的生成.这种全新的进化模式能够通过概率模型对变量之间的关系进行建模,从而可以有效地解决多变量相关的优化问题.实验分析表明,分布估计算法在求解高维问题时表现出了比一般遗传算法更好的性能,应用分布估计算法解决工程和科学中的复杂优化问题具有很大的潜力^[2].

针对使用传统模糊综合评判方法进行故障级别评判时模型参数难以确定的问题,本文提出一种基于分布估计算法的模糊综合故障评判方法.通过进化计算自动优化模型参数,提高评估的准确程度,并保留了传统的模糊综合评判模型在形式上易于理解且运算效率高的优势,形成优势互补,有利于实现磁浮列车综合故障级别的正确评估.

2 分布估计算法的基本原理

进化算法是一类随机式的启发算法,优点是能在可以接受的时间内寻找近似最优解,这一点在工程研究领域尤为重要.因为进化算法是对问题的整个参数空间给出一种编码方案,而不是直接对问题的具体参数进行处理,是从一组初始个体搜索,而不是从某个单一的初始个体开始搜索,所以具有较好的鲁棒性和全局性.但传统的进化算法普遍存在两大问题^[4]:

- 1) 算法的进化性能与算法本身的参数有很大关系,如果研究人员对具体优化问题的求解没有经验,那么算法参数的选取本身就成为一个寻优问题;
- 2) 不同变量之间的相互关系没有在选择和产生个体时被有效考虑,导致算法对种群进化方向的预测十分困难.

分布估计算法中没有传统的交叉、变异等遗传操作,是一种全新的进化模式.这种优化技术能够通过概率模型对变量之间的关系进行建模,将种群的进化方向通过每一次迭代选择个体的联合概率分布(密度)进行控制.其基本算法如下^[4]:

Step1: 初始化种群,随机生成 N 组个体作为初始种群;

Step2: 重复 Step3 和 Step4,直到满足终止条件;

Step3: 通过对种群的评估,挑选出其中较好的个体作为优势群体,并构造出群体的概率分布;

Step4: 通过上一代优势群体的概率分布采样生成新的种群.

根据进化变量的定义域不同,概率模型可以分为离散域的概率分布和连续域的概率密度.

目前离散域的 EDA 研究相对成熟,即概率模

型采用贝叶斯网络表达.根据概率模型的复杂度,EDA 可以分为如下种类^[1]:

1) 独立变量分布估计,如 UDMA (Univariate marginal distribution algorithm), PBIL (Population based incremental learning), CGA (Compact genetic algorithm) 等;

2) 双变量相关分布估计,包括 MIMIC (Mutual information maximization for input clustering), COMIT (Combining optimizers with mutual information trees) 等;

3) 多变量相关分布估计,包括 ECGA (Extended compact genetic algorithm), FDA (Factorized distribution algorithms), BOA (Bayesian optimization algorithm) 等.

连续域 EDA 算法的设计相对困难,主要原因在于每一个连续变量都有无限的取值,可能使得优化算法的搜索空间很大,特别在变量维数较大的情况下这种矛盾更加突出.实际应用中连续的情况更为常见,因此对该领域也进行了很多研究,如在 UDMA 基础上发展的 UDMac^[5,7,8],在 PBIL 上发展的 PBILc^[6,9,10],双变量相关的 MIMICc^[5],多变量相关的有 EGN Aee, EGN A_{BG} 等^[4,5].

3 基于 EDA 的磁浮列车故障综合评估

针对磁浮列车的故障综合评判问题,利用系统的运行数据来进行评判模型的构造和参数自动优化是今后的一个重要研究方向,其中机器学习理论和方法的研究与应用将具有关键的作用.本文结合模糊故障综合评判模型的优点,提出采用 EDA 来实现模糊评判模型的参数学习,以充分利用观测数据,提高评判准确性.

本文提出的基于 EDA 的模糊模型参数优化流

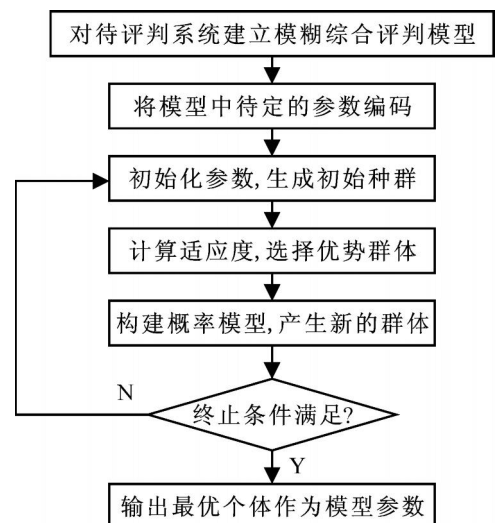


图1 EDA 优化模糊模型参数流程图

程如图 1 所示.

下面对优化过程进行具体说明.

3.1 建 模

以磁浮列车悬浮系统为研究对象,建立二级综合评判模型,如图 2 所示.对磁浮列车悬浮系统简化后,主要研究 8 种底层故障对顶层故障的影响,分别是 u_1 (悬浮主断路器), u_2 (280VDC-DC), u_3 (110VDC-DC), u_4 (诊断系统), u_5 (转向架 A), u_6 (转向架 B), u_7 (转向架 C) 和 u_8 (转向架 D), 每种故障分为 3 级.顶层故障综合评价级别也分为 3 级 {轻微故障、中等故障、严重故障}.评判因素集 $U = \{u_1, u_2, \dots, u_8\}$.根据故障之间的关系将因素集 U 划分为 4 个子集,分别为 $U_1 = \{u_1\}$, $U_2 = \{u_2, u_3\}$, $U_3 = \{u_4\}$, $U_4 = \{u_5, u_6, u_7, u_8\}$.二级评估权重集为 $\{A_{ij} \mid i = 1, 2, 3, 4\}$,隶属度矩阵 $\{R_{ij} \mid i = 1, 2, 3, 4\}$,一级评估各因素子集的权重集为 $\{A_i \mid i = 1, 2, 3, 4\}$,隶属度矩阵 $\{R_i \mid i = 1, 2, 3, 4\}$.




图 2 磁浮列车悬浮系统二级模糊综合评估过程

3.2 编 码

编码的主要任务是建立解空间与种群个体空间一一对应的关系,要求具有完备性、健全性和非冗余性.

根据研究对象的不同,编码可以分为二进制编码和浮点编码.对于本文研究对象而言,编码是将需要学习的权值和隶属度参数编成行向量.由于参数范围在 $[0, 1]$ 之间,应该采用浮点编码方式.同时,编码时需要充分利用已知信息,尽量减少不必要的变量个数,选择尽可能简单的编码方案,以提高进化计算效率.综合评判模型待定参数共有 $48 \times (3 + 3 \times 3 \times 4 + 2 + 4 + 3)$ 个.由于同层权值、隶属度相加为 1,可以将参数个数精简为 $33 \times ((3 - 1) + (3 - 1) \times 3 \times 4 + (2 - 1) + (4 - 1) + 3)$ 个,那么解空间即可编码为 1×33 维、范围为 $[0, 1]$ 的数组,从而保证了非冗余.

3.3 适应度的计算

适应度是判断学习个体与实际结果之间的吻合标准,适应度越大,表示个体对实际环境越适应.适应度函数的定义没有严格要求,可以使用一般的最小均方误差的倒数作为适应度标准,也可以根据最

小风险标准进行定义.对于磁浮列车这种以安全作为首要考虑的对象,最小风险标准无疑更加适合.

设编码形式为 $X = (X_1, X_2, \dots, X_i, \dots, X_n)$,随机生成的评价个体为 $x = (x_1, x_2, \dots, x_i, \dots, x_n)$,综合评判模型为 $F(x, \cdot)$.其中 \cdot 为模糊参数,即待优化的系数,为底层故障输入, $f(\cdot)$ 为故障级别输出, $F(x, \cdot) \cdot f(x)$ 表示风险系数.则最小风险标准的适应度函数可以表示为

$$\text{Fitness}(x) = 1 / (F(x, \cdot) \cdot f(x) \cdot F(x, \cdot) - f(a)^2). \quad (1)$$

为避免除数为 0,定义 $\epsilon > 0$,式(1)重写为

$$\text{Fitness}(x) = 1 / (F(x, \cdot) \cdot f(x) \cdot F(x, \cdot) - f(a)^2 + \epsilon). \quad (2)$$

3.4 概率估计模型的构建

概率估计模型的构建是分布估计算法的核心,是使用 EDA 实现模型参数优化的关键.概率模型由两部分组成:结构和一组局部广义概率密度.设 $X = (X_1, X_2, \dots, X_i, \dots, X_n)$ 为一组随机变量,随机生成的评价个体为 $x = (x_1, x_2, \dots, x_i, \dots, x_n)$. S 表示 X 的结构, (x) 表示 X 的局部广义概率密度. X_i 的父节点变量集合为 $P_i^S (i = 2, 3, \dots, n)$,因为 X_i 仅与其父节点相关, X_i 与 $\{X_1, X_2, \dots, X_n\} \setminus P_i^S$ 独立,所以概率分布(密度)可以进行如下分解^[4]:

$$\begin{aligned} (x) &= (x_1, \dots, x_n) = \\ &= (x_n \mid x_1, \dots, x_{n-1}) (x_1, \dots, x_{n-1}) = \\ &= (x_n \mid x_1, \dots, x_{n-1}) \cdot \dots \cdot (x_i \mid x_1, \dots, x_{i-1}) \cdot \\ &\dots \cdot (x_2 \mid x_1) \cdot (x_1) = \\ &= (x_1) \cdot (x_2 \mid P_2^S) \cdot \dots \cdot (x_i \mid P_i^S) \cdot \\ &\dots \cdot (x_n \mid P_n^S) = \prod_{i=1}^n (x_i \mid P_i^S). \end{aligned} \quad (3)$$

假设局部广义概率密度与有限参数集 s 相关 ($s = s_1, \dots, s_n$),那么式(3)可以表示为

$$(x \mid s) = \prod_{i=1}^n (x_i \mid P_i^S, s_i),$$

其中 $s = (s_1, s_2, \dots, s_n)$.

根据模糊综合评判模型的定义,同层模型的隶属度(权值参数)相加为 1,模型参数并不独立.而对 EDA 而言,变量间关系越复杂,概率估计模型也越复杂,计算难度越大.同时,由于目前对多变量相关的 EDA 研究并不成熟,进化效果也会受到影响.

对此,本文通过将形如 $e_1, e_2, \dots, e_i, \dots, e_n$ 的同层隶属度参数表示为

$$e_i = \left(1 - \prod_{k=1}^{i-1} e_k\right) x_i, \quad i = 1, 2, \dots, n, \quad \prod_{i=1}^n e_i = 1$$

来将参数间的联系分解. 使用 $x_1, x_2, \dots, x_{n-1} (x_n = 1)$ 进行训练, 从而可以选择独立变量分布方法 UDMAc 实现参数的优化, 其概率分布简化为

$$(x/s) = \prod_{i=1}^n (x_i, i).$$

3.5 训练和测试模型

在实验设计方面, 主要采用图 3 所示的数据训练和测试过程.




图3 基于分布估计算法的模糊综合评估实验模型

将列车运行的故障数据搜集整理成 i 故障 - 级别 j 形式构成样本, 一部分用于训练, 一部分用于测试. 样本待定参数编码后, 使用训练集进行训练, 训练结束后将优化的参数输入综合评价模型, 使用测试集进行测试, 以此评价进化方法的效果. 此外, 虽然一般进化算法的种群初始化采取随机方式, 但对于本文研究对象, 可以加入人为粗略制定的个体, 以加速算法的收敛. 当出现误判需要对参数进行修正时, 可以将之前进化得到的参数个体加入初始种群.

4 性能测试与比较

根据磁浮列车的运行记录, 搜集整理 400 组样本. 其中: 300 组用于训练, 样本分布如图 4 所示; 100 组用于测试, 样本分布如图 5 所示.

图中共有 9 个子直方图, 分别描述相应的输入或输出属性的样本分布. 其中输入包括: 悬浮主断路器, 280VDC-DC, 110VDC-DC, 诊断系统, 转向架




图4 用于训练样本数据集分布(300组)

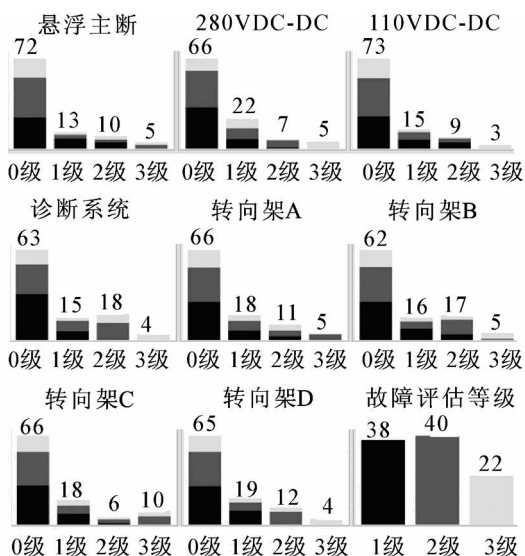


图5 用于测试样本数据集(100组)

A, 转向架B, 转向架C, 转向架D等8种属性, 输出为故障评估等级. 分布图中以黑色、灰色、浅灰色部分分别代表列车悬浮系统 1 级故障、2 级故障和 3 级故障的数量, 对于输入属性子图, 这 3 种颜色表示输入属性中相应故障级别的数量.

为充分验证本文提出方法的性能, 仿真实验中不仅测试了基于 EDA 的故障综合评判系统参数对评判精度的影响, 而且对基于 EDA 与 GA 的参数优化方法以及采用其他机器学习算法获得的评价模型的性能进行了全面对比.

在 EDA 算法的设计中, 进行参数影响测试时的编码不考虑变量联系, 而与其他方法比较时按 3.4 节将关联分解, 使用 UDMAc 概率模型.

4.1 基于 EDA 综合评判系统参数对性能的影响测试

分布估计算法的参数主要有: 种群数量、截断概率、最大迭代次数等, 其中种群数量和截断概率是 EDA 的关键参数.

(1) 种群数量对 EDA 的影响

设置截断概率为 0.2, 最大迭代次数为 200. 改变初始化种群的数量, 得到训练的正确率 - 学习次数曲线如图 6 所示, 图中 population 表示种群的数量.

从图 6 可以看出, 虽然初始种群随机选择造成各次训练的初始精度略有不同, 但评判精度随训练次数快速递增. 当训练次数到达 80 次后, 训练结果都稳定在比较高的精度上. 训练精度随种群数量递增总体呈上升趋势, 种群数量高于一定值 (600) 时, 训练的最终结果受随机因素的影响大大降低, 稳定在高精度范围 (99%).

(2) 截断概率对 EDA 的影响




图 6 种群数量变化的训练次数 - 正确率关系曲线

设置种群数量为 300,最大迭代次数为 80,改变每次训练的截断概率,得到训练的正确率 - 学习次数曲线如图 7 所示, truncation 表示截断概率.




图 7 截断概率变化的训练次数 - 正确率关系曲线

图 7 显示了截断概率对评判结果的影响,从截断概率与最终正确率曲线可以看出, truncation [0.2, 0.3],精度最高,而偏离此范围越大,精度下降趋势越明显.这种现象从理论上解释可以理解为在 truncation [0.2, 0.3] 范围,种群中的优势群体最能代表最优个体的趋势,截断概率太小则随机成分较重;截断概率太大则难以体现优势群体的概率分布.

实验结果显示,EDA 能够快速收敛到较小的误差范围.随着种群数量的增大,效果趋于稳定的最佳值,从而使基于 EDA 故障综合评判系统能够获得较高的正确率.

4.2 EDA 和 GA 的效果比较

分别使用 EDA 和 GA 对模型进行进化计算,比较两种算法在种群大小相同情况下的训练效果.训练后模型的测试错误率如表 1 所示,所有结果均为 10 次重复计算的平均值.

由表 1 可见,使用遗传算法的错误率始终在 10% 左右,参数的改变并没有使结果得到进一步的改进.此外,通过 GA 进化的模型错误率的方差较大,训练得到的结果不够稳定且总体性能不高.比较而言,种群数相同时 EDA 训练得到的结果错误率明显更低,算法稳定性也有很大提高,充分体现了 EDA 在处理高维进化问题的优越性.实验结果表明:通过合理地设置参数,EDA 能够较好地完成磁浮列车故障综合评判模型参数优化的任务.

表 1 遗传算法和分布估计算法的效果比较

种群数量	分布估计算法		遗传算法	
	选择概率	错误率,方差	选择概率	错误率,方差
100	0.1	(0.0310, 0.0404)	0.08	(0.1189, 0.0545)
	0.2	(0.0160, 0.0304)	0.2	(0.068, 0.059)
	0.3	(0.0210, 0.0151)	0.3	(0.1220, 0.0594)
300	0.1	(0.0272, 0.0704)	0.08	(0.0994, 0.0652)
	0.2	(0.0050, 0.0087)	0.2	(0.0657, 0.0750)
	0.3	(0.0100, 0.0122)	0.3	(0.1153, 0.0501)
1000	0.1	(0.0050, 0.0671)	0.08	(0.1036, 0.0503)
	0.2	(0.0090, 0.0104)	0.2	(0.1103, 0.0661)
	0.3	(0.0120, 0.0074)	0.3	(0.1153, 0.0501)

4.3 EDA 与其他机器学习算法的性能比较

机器学习领域, C4.5 决策树(C4.5 Tree) 算法,朴素贝叶斯算法(NaiveBayes),支持向量机(SVM)和神经网络算法(NeuralNetwork) 都是应用广泛的学习算法,能够基于训练数据自动建立故障评价模型.为比较不同机器学习算法在磁浮列车故障评价中的模型优化性能,本文选择 WEKA 软件平台进行学习算法的性能测试,各种算法的参数设置如下:

- 1) C4.5 decision tree: confidence Factor = 0.25, minNumObj = 1, numFolds = 3;
- 2) NaiveBayes;
- 3) SMO: complexity parameter C = 1.0, use RBF = false;
- 4) BP neural network, learning Rate = 0.2: momentum = 0.2, hidden Layers = (attributes + classes) / 2, training Time = 500;
- 5) 基于 EDA 进化的模糊综合评判,种群数 = 1000,截断概率 = 0.3.

不同学习算法与 EDA 的性能比较如表 2 所示.

表 2 EDA 与其他机器学习方法的比较

分类器	测试方式	错误率 / %
J48(C4.5 Tree)	10-fold cross	9.33
	test set	12
NaiveBayes	10-fold cross	13
	test set	16
SMO(SVM)	10-fold cross	8
	test set	10
multilayerPerceptron(BP)	10-fold cross	6
	test set	4
基于 EDA 的模糊综合评判	10-fold cross	16.04
	test set	1.00

由表 2 可以看出,EDA 的 10 折交叉验证效果并不出众,甚至低于其他机器学习算法,但对测试集进行验证时,错误率却有效保持在一个很低的范围内,明显优于其他算法.这种结果并不冲突,原因如下: 10 折交叉验证的原理是在训练样本中选取 10% 进

行训练,而90%用于测试,即只有30组样本用于训练,而本实验中模糊评判模型设定的未知数就达到33个,这样训练效果不理想也是可以理解的;而使用测试集验证的方式,训练样本达到300组,训练后的评估精度大幅提高,达到了应用可接受标准,特别是EDA进化后,评估精度能够随列车运行数据的不断丰富稳中有升,能够胜任保障列车运行安全的任务。

通过比较4.1节与4.2,4.3节的EDA进化结果可以发现,由于4.1节编码时不考虑变量联系,而后两节将关联分解,导致相同参数情况下后者效果更优,说明概率模型与研究问题变量关系匹配的重要性。在避免使用复杂概率模型的情况下,本文使用将变量关系分解的形式编码,得到了很好的效果。

5 结 论

本文主要研究了基于进化学习的磁浮列车系统故障等级评判方法。针对传统模糊综合评判方法模型参数难以确定和优化的缺点,提出了基于分布估计算法的模糊参数优化方法,通过使用EDA对评判模型进行逼近建模,实现了模糊评估模型参数自动学习和优化。性能评测显示,基于EDA的故障综合评判方法能够较快收敛到最优结果,并有很高的评判精度,效果明显优于遗传算法和其他机器学习算法,能够胜任磁浮列车系统故障评级的任务。

参考文献(References)

- [1] 周树德,孙增圻. 分布估计算法综述[J]. 自动化学报, 2007, 33(2): 113-124.
(Zhou S D, Sun Z Q. A survey on estimation of distribution algorithms [J]. Acta Automatica Sinica, 2007, 33(2): 113-124.)
- [2] 龙志强,吕治国. 基于模糊综合评估的磁浮列车故障诊断系统[J]. 信息与控制. 2004, 33(2): 227-230.
(Long Z Q, Lv Z G. The fault diagnostic system of maglev train based on fuzzy comprehensive evaluation [J]. Information and Control. 2004, 33(2): 227-230.)
- [3] 黄文虎,夏松波,刘瑞岩. 设备故障诊断原理、技术及应用[M]. 北京: 科学出版社, 1996.
(Huang W H, Xia S B, Liu R Y. Theory technology and application on equipment fault diagnosis [M]. Beijing: Science Press, 1996.)
- [4] Larranaga P, Etxeberria R, Lozano J A, et al. Optimization by learning and simulation of bayesian and gaussian networks[M]. Spain: University of the Basque Country, 1999.
- [5] Larranaga P, Etxeberria R, Lozano J A, et al. Optimization in continuous domains by learning and simulation of gaussian networks[C]. Proc of the 2000 Genetic and Evolutionary Computation Conference Workshop Program. Las Vegas: Nevada, 2000: 201-204.
- [6] Sebag M, Ducoulombier A. Extending population based incremental learning to continuous search spaces [C]. Proc of the 5th Conf on Parallel Problem Solving from Nature-PPSN V. Springer-Verlag, 1998: 418-427.
- [7] Mühlenbein H. The equation for response to selection and its use for prediction [J]. Evolutionary Computation, 1997, 5(3): 303-346.
- [8] Shapiro J L. Drift and scaling in estimation of distribution algorithms[J]. Evolutionary Computation, 2005, 13(1): 99-123.
- [9] Hohfeld M, Rudolph G. Towards a theory of population based incremental learning[C]. Proc of the 4th Int Conf on Evolutionary Computation. IEEE, 1997: 1-5.
- [10] Cristina G, Lozano J A, Larranaga P. Analyzing the PBIL algorithm by means of discrete dynamical systems [J]. Complex Systems, 2001, 12(4): 465-479.

(上接第550页)

- [7] Mitani Y, Hamamoto Y. A local mean-based nonparametric classifier [J]. Pattern Recognition Letters, 2006, 27(10): 1151-1159.
- [8] Duda R O, Hart P E, Stork D G. Pattern classification [M]. 2nd ed. New York: John Wiley Sons, 2001.
- [9] Jain A K, Ramaswami M D. Classifier design with Parzen windows[z]. Amsterdam: Elsevier, 1988.
- [10] Rumelhart D E, Hinton G E, Williams R J. Learning internal representations by error propagation [z]. Cambridge: MIT Press, 1986.
- [11] Ness J V. On the dominance of nonparametric Bayes rule discriminant algorithms in high dimensions [J]. Pattern Recognition, 1980, 12(3): 355-368.