

文章编号: 1006-4710(2015)02-0138-06

基于果蝇优化算法的多元质量控制故障模式诊断

杨明顺, 梁艳杰, 雷丰丹, 刘永, 杜少博

(西安理工大学 机械与精密仪器工程学院, 陕西 西安 710048)

摘要: 针对目前以神经网络为代表的主流智能故障模式诊断方法存在训练时间长、收敛速度慢、容易陷入局部最优等缺陷, 本文将果蝇优化算法用于多变量生成过程故障模式诊断, 重点分析了果蝇优化算法(FOA)的原理及其搜索优势, 设计了一种基于 FOA 的多变量生产过程故障模式诊断算法。将所设计的果蝇优化算法应用于汽车曲轴生产过程控制, 并与神经网络模型处理结果进行对比。对比结果表明, 果蝇优化算法训练时间短, 收敛速度快且诊断结果更加准确。

关键词: 多变量生产过程; 果蝇优化算法; 过程控制; 故障诊断; BP 神经网络; 质量控制

中图分类号: TH122, TP391 文献标志码: A

A fault diagnosis for multivariate production process based on Fruit Fly Optimization Algorithm

YANG Mingshun, LIANG Yanjie, LEI Fengdan, LIU Yong, DU Shaobo

(Faculty of Mechanical and Precision Instrument Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Neural network served as a representative of the mainstream intelligent fault mode diagnosis method, has had such defects as long learning time, difficulty of convergence and easily plunging into a local optimal solution. Thus, a Fruit Fly Optimization Algorithm for multivariable process fault diagnosis model is established in this paper, the principle and search advantage of Fruit Fly Optimization Algorithm (FOA) is emphatically analyzed and a multivariable process fault diagnosis model based on FOA algorithm is designed. The Fruit Fly Optimization Algorithm is used for analyzing control sample data in the automobile crankshaft production, and a contrast is made with the results obtained from the neural network model. And contrast results show that Fruit Fly Optimization Algorithm has a short training time, fast convergence rate and more accurate diagnosis result.

Key words: multivariate production process; Fruit Fly Optimization Algorithm (FOA); process control; fault diagnosis; BP artificial neural network; quality control

在生产过程质量控制当中, 为了避免单个质量特性控制可能引起的“过控”或者“欠控”现象, 必须同时考虑多个相互关联的多质量特性的相互影响以及其共同对产品质量的影响, 因此多元质量控制故障模式诊断成为保证产品质量的一个重要方面^[1-2]。

多元质量控制诊断的研究对象是多变量正态过程, 且变量间往往不是独立而是相关的, 一个或几个变量的均值(或/和方差)或/和变量间的相关关系偏离总体, 过程都会失控, 监控该过程的控制图都会发出警告信号。国内外许多学者对此进行了广泛研

究。针对多元质量控制图不能准确确定导致失控信号产生的变量或变量集这一缺陷, Mojtabsa Salehi^[3]提出了一种基于混合学习的模型, 从而实现在多变量制造过程中失控信号在线分析; Zhang Jiujiu^[4]针对使用单一控制图对多变量过程中数据平均值和变化同时进行监控的问题, 提出了一种新的包含指数加权移动平均过程和广义似然比测试的控制图, 实现多变量过程中平均值与变化过程的同时监控; 文昌俊^[5]在分析多元 T^2 控制图和多元过程能力指数的基础上, 利用主成分分析法实现了多元

收稿日期: 2014-09-06

基金项目: 国家自然科学基金资助项目(60903124); 陕西省教育厅科学研究计划资助项目(14JK1521); 西安理工大学青年科技创新团队建设计划资助项目(102-211408)。

作者简介: 杨明顺, 男, 副教授, 博士, 主要研究方向为制造系统优化与控制、集成产品开发决策、集成质量管理。

E-mail: yangmingshun@xaut.edu.cn。

T^2 控制图的计算,结合多元过程能力指数的计算,评价生产过程质量满足质量要求的过程。

研究表明,针对多个相互关联的多质量特性的多元质量过程控制,能够有效保证生产系统稳定性,提高产品效率,降低废品率。因此,为了能够及时发现产品生产质量特性异常波动,找出生产过程失控原因,并采取相应措施去除异常因素,针对多元质量控制过程的故障诊断模式的研究吸引了当前许多学者的目光。目前,多变量生产过程质量控制故障模式诊断包括基于传统统计学的故障模式诊断方法和智能故障模式诊断。其中,智能故障模式诊断方法已经成为近年来多变量生产过程故障模式诊断的主流方法^[6]。

从智能故障模式诊断方法的原理等相关方面的内容可以将其分为五大类^[7],即:专家系统故障模式诊断方法、基于模型的故障诊断方法、机器学习方法、人工神经网络故障模式诊断方法和模糊逻辑故障模式诊断方法。就目前应用情况来看,基于神经网络的方法由于其自身所具有的并行性、联想记忆功能、自组织性、自学习等优良特性,获得了较为广泛的应用。程红军等在多种多元质量诊断方法的基础上,根据多元质量控制与诊断的特点和神经网络的优势,提出了基于神经网络进行多元质量控制与诊断的流程,并设计了多元质量诊断神经网络^[8];Czeslaw T Kowalski 和 Teresa Orlowska Kowalska 将两种神经网络模型分别应用于不同的故障诊断,其中前馈神经网络用于识别所有的故障,Kohonen 自组织网络用于给故障分类^[9];Wang Huaqing 和 Chen Peng 基于概率论和模糊神经网络提出一种滚动轴承故障智能诊断的方法,能够准确找出症状和故障模式之间的相关关系^[10]。

然而在实际应用过程中,一些学者在研究中发现,神经网络在某种程度上也存在着一些缺陷。张新海在将神经网络用于机械故障诊断时,认为传统神经网络收敛速度较慢,不能保证收敛到全局最小点,网络的学习、记忆具有不稳定性等缺点^[11]; Yu Jianbo 等应用可选择神经网络算法进行多变量生产过程故障模式诊断时,发现该算法容易陷入局部最优^[12];冯辉宗等认为传统 BP 网络的故障诊断过程训练时间长、准确度和精度不够高,因此,提出一种将粒子群优化算法与 BP 网络结合的新算法——PSO-BP 来训练神经网络的权值和阈值^[13]。

传统神经网络存在的缺陷一定程度上影响了神经网络故障模式诊断的效果,基于此,本文结合果蝇优化算法(Fruit Fly Optimization Algorithm,

FOA)的优点,给出了基于 FOA 的多变量生产过程的故障模式诊断算法;将所设计的算法用于汽车曲轴生产实例,并与由 BP 神经网络模型处理的结果进行对比,验证了其有效性。

1 果蝇优化算法

果蝇优化算法(FOA)是台湾潘文超博士于 2011 年从果蝇的觅食行为得到启发而提出的^[14]。该方法是一种根据果蝇觅食行为而推演出的寻求全局最优解的新方法。

果蝇算法的步骤如下^[15]。

1) 随机初始化果蝇群体位置,得到初始坐标(X, Y)。

2) 对每个个体飞行的方向和距离随机赋值:

$$X_i = X + \text{Random Value}$$

$$Y_i = Y + \text{Random Value}$$

3) 计算个体与原点距离 D ,取距离的倒数为味道最浓的判定值 S 。

$$D_i = \sqrt{X_i^2 + Y_i^2} \quad (1)$$

$$S_i = 1/D_i \quad (2)$$

4) 将判定值带入适应度函数计算味道浓度:

$$\text{Smell}_i = \text{fitness}(S_i)$$

5) 保留浓度最高的果蝇,进入迭代,更新最靠近食物的果蝇位置,最后找出最优解。

果蝇算法实现简单,全局寻优能力较强,寻优精度较高,它可应用于数学函数的极值求解、Z-SCORE 模型系数优化、广义回归神经网络参数优化、灰色神经网络参数优化、支持向量机回归参数优化等方面^[16]。本文所进行的多变量生产过程故障模式诊断就属于广义回归神经网络参数优化的一种应用。

目前,多元质量控制故障模式诊断的研究和实践大多还局限在对其统计过程控制的均值向量进行控制方面,特别是当控制图发出警告信号(即过程失控)时, T^2 图不能解释过程失控的原因。虽然多元控制图解决了质量控制问题,但当出现异常时,其并不能判定是什么异常,何处发生异常,即不能进行诊断。

多元质量控制故障诊断一直是国内外诊断理论研究焦点之一,许多学者做了大量的工作,先后提出十余种解决方法,如:将主成分分析法(PCA)用于解释多变量控制过程的警告信号;邦菲隆尼不等式法则应用一元休哈特图判断每个原始变量,找出异常变量;判别分析法找出异常变量的集合;应用 T^2 统计量分解问题识别程序等。然而这些方法并不能充分解释过程失控的所有原因,从而成为多元质量

控制故障模式诊断的一大障碍,因此,为了查明过程是否失控,特别是查明究竟是哪个变量的变化导致过程失控,是多变量过程控制诊断技术所要研究的关键,本文以此为出发点,结合多元质量控制过程,提出将果蝇优化算法应用到多元质量诊断中,从而以最短的时间,较准确地找到失控变量,保证生产效率,降低废品率。

2 基于 FOA 的多变量生产过程故障诊断算法设计

根据上述 FOA 的原理和多变量生产过程故障诊断的特点,设计出基于 FOA 的多变量生产过程故障诊断算法流程如图 1 所示,实现步骤如下。

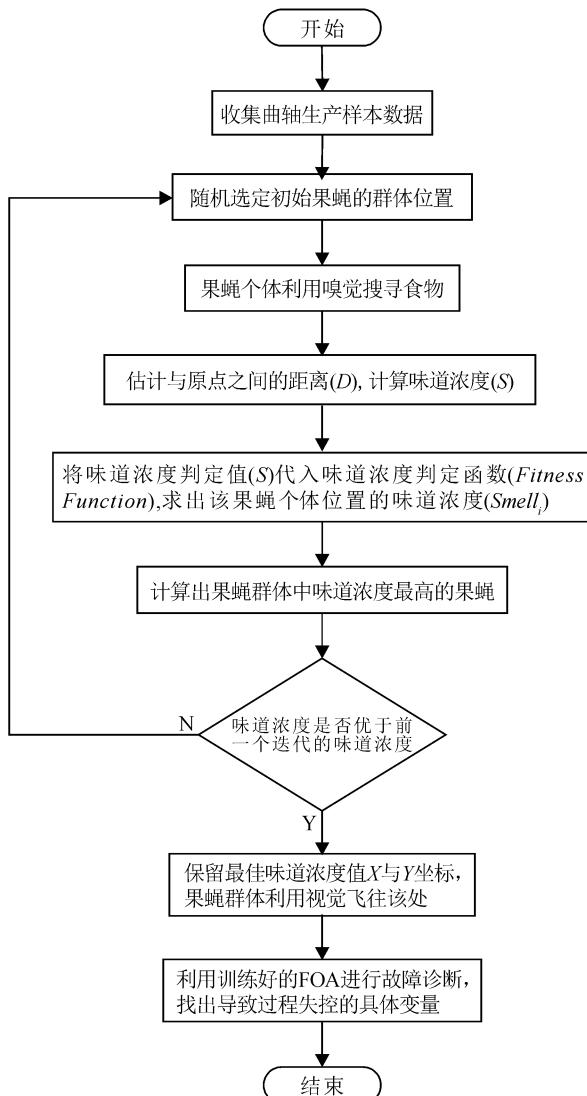


图 1 果蝇优化算法流程图

Fig. 1 Flow chart of Fruit Fly Optimization Algorithm

1) 初始化果蝇群体的初始位置,随机选择果蝇个体的初始位置:Init X_axis, Init Y_axis, 即多元质量控制环境下的多个变量初始位置。

2) 对每个个体飞行方向和距离随机赋值(即搜索步长):

$$X_i = X_axis + \text{Random Value}$$

$$Y_i = Y_axis + \text{Random Value}$$

得到每个变量的下一个位置。

3) 计算果蝇与坐标原点的距离(D),并计算出味道浓度判定值(S)即变量值,其计算公式如式(1)、(2)所示。

4) 将味道浓度判定值(S)代入到味道浓度判定函数(*Fitness Function*)中(一般为优化函数),计算出果蝇个体的味道浓度($Smell_i$)。

$$Smell_i = \text{Fitness Function}(S_i)$$

5) *fitness* 的最大值对应位置浓度最高的果蝇,保留该果蝇的坐标值,此为初始最佳坐标值;

$$[bestSmell \ bestIndex] = \max(Smell)$$

$$Smell_{best} = bestSmell$$

$$X_axis = X(bestIndex)$$

$$Y_axis = Y(bestIndex)$$

6) 进入迭代寻优过程,重复进行步骤 2 到步骤 5 的操作,并且进行味道浓度的判断,若所计算出的味道浓度值高于前一值,便将味道浓度最高的果蝇坐标值记录为最佳坐标值。通过该操作流程最终便可以找出味道浓度值最佳的食物的具体位置。

7) 利用训练好的 FOA 进行故障诊断,找出导致过程失控的变量或变量集。

3 实例分析

以某企业汽车曲轴的生产数据为研究对象,根据其生产特点,选取变量为曲轴主轴颈直径 X_1 、曲轴连杆轴颈直径 X_2 以及主轴颈与连杆轴颈所构成的曲轴的冲程 X_3 。对此多变量生成过程进行质量控制与诊断的基本思路:当基于 Z 统计量的 MEWMA 控制图探测出失控信号(表明生产过程失控)时,可以将故障模式诊断过程模拟为一个故障问题的分类问题。

在此情况下,首先将所收集到的失控样本数据通过改进 PCA 算法^[2]进行数据降维,然后将其输入到训练好的果蝇优化算法当中,利用训练好的果蝇优化算法进行故障模式诊断,寻找出导致生产过程失控的具体变量。

为了验证本文所设计的 FOA 在处理汽车曲轴生产的多变量生产过程故障模式诊断问题上的效果优于 BP 神经网络模型,分别建立了果蝇优化算法和 BP 神经网络模型。本文利用 MATLAB R2011a 软件设计优化算法,随机生成各失控模式的足够训

练样本数据和具有 2σ 偏移量的足够训练样本数据。该训练样本数据包含了所有的失控模式种类,并且在每种失控模式中选取50组数据作为训练样本数据,共计350组训练样本数据。其中,表1为 X_1 、 X_2 与 X_3 发生偏移时的训练数据。对其经PCA算法

进行降维处理之后,仅保留两个主成分。

因此,所设计的果蝇优化算法的输入数据包含两个参数,输出数据为一个三维列向量。同理,建立的BP神经网络模型的输入层为2个神经元,输出层为3个神经元。

表1 X_1 、 X_2 与 X_3 发生偏移的训练数据
Tab. 1 The training data of X_1 , X_2 and X_3 offset

序号	X_1 /mm	X_2 /mm	X_3 /mm	序号	X_1 /mm	X_2 /mm	X_3 /mm
1	89.981	73.110	67.266	26	89.976	73.229	67.127
2	89.991	73.118	67.798	27	89.974	73.642	67.134
3	89.913	73.641	67.488	28	89.939	73.485	67.099
4	89.991	73.329	67.769	29	89.966	73.152	67.142
5	89.963	73.654	67.396	30	89.917	73.782	67.168
6	89.910	73.749	67.273	31	89.971	73.101	67.196
7	89.928	73.583	67.037	32	89.903	73.294	67.318
8	89.955	73.740	67.673	33	89.928	73.237	67.316
9	89.996	73.235	67.430	34	89.905	73.531	67.218
10	89.997	73.735	67.452	35	89.910	73.092	67.251
11	89.916	73.971	67.610	36	89.982	73.405	67.893
12	89.997	73.867	67.059	37	89.970	73.105	67.703
13	89.996	73.086	67.316	38	89.932	73.112	67.556
14	89.949	73.366	67.773	39	89.995	73.784	67.184
15	89.980	73.369	67.696	40	89.903	73.292	67.212
16	89.914	73.685	67.125	41	89.944	73.604	67.077
17	89.942	73.598	67.130	42	89.938	73.964	67.914
18	89.992	73.789	67.092	43	89.977	73.433	67.707
19	89.979	73.368	67.008	44	89.980	73.695	67.558
20	89.996	73.206	67.423	45	89.919	73.758	67.313
21	89.966	73.087	67.656	46	89.949	73.433	67.166
22	89.904	73.772	67.723	47	89.945	73.656	67.623
23	89.985	73.206	67.531	48	89.965	73.110	67.988
24	89.993	73.388	67.109	49	89.971	73.934	67.170
25	89.968	73.552	67.632	50	89.976	73.188	67.258

3.1 应用FOA进行故障模式诊断

1) 输入与输出设计

针对本文的研究对象,设输出变量为 $\mathbf{T}=(T_1, T_2, T_3)^T$,则该实例共有7种显著的输出模式(见表2)。

表2 7种显著的输出模式

Tab. 2 Seven marked output modes

序号	失控	受控	\mathbf{T} 表达式
1	T_1	T_2, T_3	$\mathbf{T}=(1, 0, 0)^T$
2	T_2	T_1, T_3	$\mathbf{T}=(0, 1, 0)^T$
3	T_3	T_1, T_2	$\mathbf{T}=(0, 0, 1)^T$
4	T_1, T_2	T_3	$\mathbf{T}=(1, 1, 0)^T$
5	T_1, T_3	T_2	$\mathbf{T}=(1, 0, 1)^T$
6	T_2, T_3	T_1	$\mathbf{T}=(0, 1, 1)^T$
7	T_1, T_2, T_3		$\mathbf{T}=(1, 1, 1)^T$

说明:1表示失控,0表示受控。

通常来讲,当变量的个数为 p 时,其故障模式

的分类数目为 $(2^p - 1)$ 。

2) 种群规模与迭代次数设定

本文所设计的果蝇优化算法迭代次数根据具体的训练效果来确定,根据多次尝试,迭代次数取1 000次为宜。随机初始化果蝇群体位置区间为[0, 1],迭代的果蝇搜寻食物的随机飞行方向与距离区间为[-10, 10]。

3) 网络训练

FOA的相关参数设定完成之后,便可以进行网络训练。网络训练应该注意以下两点:①样本数据的选取应该具有完整性、代表性以及全面性;②训练的目的是找出样本数据当中输入数据与输出数据之间的映射关系,需要进行多次尝试,以选择合适的网络训练次数。

3.2 应用BP神经网络模型进行故障模式诊断

输入层神经元的数量为多元质量控制环境下变量的数量,该实例中变量数为2(降维处理后的两个主成分),输出层神经元的数量为3,因此本文所建立的BP神经网络模型故障模式分类的数量为7,该输出变量为 $T=(T_1, T_2, T_3)^T$,输出的7种模式与FOA相同。

在设计BP神经网络结构时,应该综合考虑网络结构的层数、各层神经元的个数、期望误差,学习率以及动量因子、网络循环次数和训练函数等方面因素,考虑一般情况下网络结构设计经验及本文处理的对象特点,最终确定本文所建立的BP神经网络模型的训练样本数为350,结构为3层:即输入层、隐层以及输出层,输入层神经元的个数为2,隐层神经元的个数为15,输出层神经元的个数为3;期望误差为0.000 001;学习率为0.01;动量因子为0.9;网络循环次数为1 000次。

将BP神经网络各参数设定之后,即可进行网络训练。经过多次训练尝试,最终确定BP神经网络模型输入层的训练函数为tansig函数,隐层的训练函数为tansig函数,输出层的训练函数为logsig函数。

3.3 诊断结果对比与分析

将经过PCA算法降维操作之后所得的失控样本数据作为输入数据,分别输入到所设计的果蝇优化算法以及BP神经网络模型当中,对其进行网络训练;在此基础上,利用MATLAB R2011a软件分别随机生成七种失控模式的足够失控样本数据,每种失控模式选取20组样本数据,合计140组样本数据进行故障模式诊断验证。训练结果以及故障模式诊断结果如下。

果蝇优化算法的训练过程如图2和图3所示,BP神经网络模型的训练结果如图4所示。FOA故

障模式诊断结果和BP神经网络模型的故障模式诊断结果如表3所示。

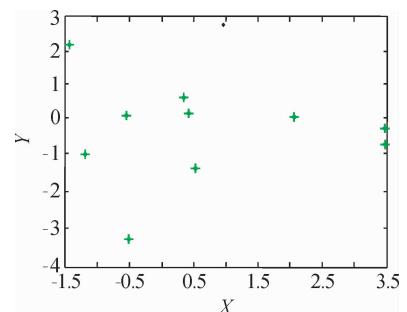


图2 果蝇优化算法行进轨迹

Fig. 2 Track of Fruit Fly Optimization Algorithm

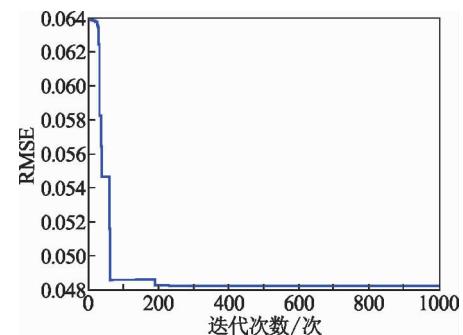


图3 果蝇优化算法训练图

Fig. 3 Train diagram of Fruit Fly Optimization Algorithm

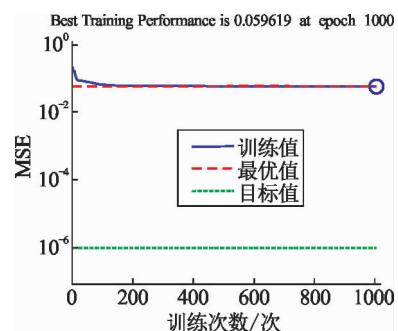


图4 BP神经网络训练图

Fig. 4 Training figure of BP Neural Network

表3 FOA诊断结果和BP神经网络模型的故障模式诊断结果
Tab. 3 The diagnosis results of FOA and BP neural network model

诊断模式	(1,0,0)	(0,1,0)	(0,0,1)	(1,1,0)	(1,0,1)	(0,1,1)	(1,1,1)
FOA诊断数量	19	23	22	19	18	20	19
BP诊断数量	25	14	28	15	29	15	14

从FOA故障模式诊断算法与BP神经网络故障模式诊断模型的训练结果可以看出,二者经过网络训练以后,其识别效果均达到最优。但是,果蝇优化算法在迭代到230次时,其训练误差已经达到了训练要求,而BP神经网络模型在迭代到大约420次时,其训练误差才达到训练要求;此外,从果蝇优

化算法的建立过程当中也可以看出,其建立过程当中所需人为设定的不确定参数的数目明显少于BP神经网络故障模式诊断模型,更加便于操作。其次,从故障模式的诊断效果来看,果蝇优化算法比BP神经网络模型的诊断结果更加精确。

因此,果蝇优化算法在处理汽车曲轴生产的多

变量故障模式诊断问题中相对于BP神经网络模型具有明显优势。

4 结 论

1) 根据多元质量控制诊断的研究现状、研究方法以及存在的缺陷,讨论了现有优化算法存在的缺陷,重点分析了果蝇优化算法(FOA)的原理以及搜索优势,设计了一种基于FOA的多变量生产过程故障模式诊断算法。

2) 以汽车曲轴生产为例,分别建立FOA优化流程和BP神经网络优化模型。故障模式训练过程对比结果表明,本文所设计的基于FOA多元质量故障模式诊断的训练时间远小于BP神经网络模型,并且可以有效避免BP神经网络模型在建立过程中网络结构相关参数设定的不确定因素对故障模式诊断效果的影响。

参考文献:

- [1] 董兰娟,樊树海,黄婷华,等.大规模定制多元质量控制概述[J].现代制造工程,2013,(12):125-129.
Dong Lanjuan, Fan Shuhai, Huang Tinghua, et al. Summary on the mass customization multivariate quality control [J]. Department of Industrial Engineering, 2013,(12):125-129.
- [2] 余婷,杨明顺,刘永,等.改进PCA降维算法及其在多元质量控制中的应用[J].工业工程与管理,2014,19(3):66-71.
Yu Ting, Yang Mingshun, Liu Yong, et al. An improved PCA dimension reduction algorithm for multivariate quality control [J]. Faculty Mechanical Precision Instrument Engineering, 2014,19(3):66-71.
- [3] Mojtaba Salehi, Ardesir Bahreininejad, Isa Nakhai. On-line analysis of out-of-control signals in multivariate manufacturing processes using a hybrid learning-based model [J]. Neurocomputing, 2011, 74 (12-13): 2083-2095.
- [4] Zhang Jiujun, Li Zhonghua, Wang Zhaojun. A multivariate control chart for simultaneously monitoring process mean and variability [J]. Computational Statistics and Data Analysis, 2010, 54(10): 2244-2252.
- [5] 文昌俊,李莉,杨练根.多元质量控制分析与多元过程能力指数计算研究[J].湖北工业大学学报,2009,24(1):32-34.
Wen Changjun, Li Li, Yang Liangen. Research on the Multivariate Quality Control Analysis and the Calculation of Process Capability Index based on PCA[J]. Journal of Hubei University of Technology, 2009, 24 (1): 32-34.
- [6] 李绍彬.基于知识工程的图形化网络拓扑诊断系统[J].中国机械工程,2006,17(S1):226-229.
Li Shaobin. Development of intelligent fault diagnosis system based on KBE graph[J]. China Mechanical Engineering, 2006,17(S1):226-229.
- [7] 张冰凌,许英姿,潘全文.智能故障诊断方法的研究和展望[J].飞机设计,2007,27(5):55-58.
Zhang Bingling, Xu Yingzi, Pan Quanwen. Research and development trend of intelligent fault diagnosis techniques[J]. Aircraft Design, 2007,27(5):55-58.
- [8] 程红军.基于神经网络的多元质量控制与诊断技术研究[D].天津:天津大学,2008.
Cheng Hongjun. Multivariate quality control and diagnosis research[D]. Tianjin: Tianjin University, 2008.
- [9] Czeslaw T Kowalski, Teresa Orlowska-Kowalska. Neural networks application for induction motor faults diagnosis[J]. Mathematics and Computers in Simulation, 2003, 63(3-5):435-448.
- [10] Wang Huaqing, Chen Peng. Intelligent diagnosis method for rolling element bearing faults using possibility theory and neural network[J]. Computers & Industrial Engineering, 2011, 60(4):511-518.
- [11] 张新海,雷勇.BP神经网络在机械故障诊断中的应用[J].噪声与振动控制,2008,(5):95-97.
Zhang Xinhai, Lei Yong. Application of BP neural network in mechanical fault diagnosis[J]. Noise and Vibration Control, 2008,(5):95-97.
- [12] Yu Jianbo, Xi Lifeng. A neural network ensemble-based model for on-line monitoring and diagnosis of out-of-control signals in multivariate manufacturing processes [J]. Expert Systems with Applications, 2009, 36(1): 909-921.
- [13] 冯辉宗,吴小敏,袁荣棣,等.基于PSO-BP神经网络的发动机故障诊断[J].化工自动化及仪表,2013,40(1):76-79.
Feng Yaozong, Wu Xiaomin, Yuan Rongli, et al. Engine fault diagnosis based on PSO-BP neural network[J]. Automotive Electronics and Embedded Systems Engineering, 2013,40(1):76-79.
- [14] Pan Wentsao. A new fruit fly optimization algorithm: Taking the financial distress model as an example[J]. Knowledge-Based Systems, 2012, 26: 69-74.
- [15] 张翔,陈林.基于果蝇优化算法的支持向量机故障诊断[J].电子设计工程,2013,21(16):90-93.
Zhang Xiang, Chen Lin. Fault diagnosis based on support vector machines optimized by fruit fly optimization algorithm[J]. Electronic Design Engineering, 2013,21(16):90-93.
- [16] 李泓泽,郭森,李春杰.果蝇优化最小二乘支持向量机混合预测模型-以我国物流需求量预测为例[J].经济数学,2012,29(3):103-106.
Li Hongze, Guo Sen, Li Chunjie. A hybrid forecasting model based on fruit fly optimization algorithm and least squares support vector machine—the case of logistics demand forecasting of China[J]. Journal of Quantitative Economics, 2012,29(3):103-106.

(责任编辑 王卫勋)