

文章编号: 1001-0920(2007)10-1197-04

混沌耗散离散粒子群算法及其在故障诊断中的应用

王 灵, 俞金寿

(华东理工大学 自动化研究所, 上海 200237)

摘 要: 针对大型化工过程生产系统的高维度数据及其噪声严重影响故障诊断的性能, 采用基于故障特征选择和支持向量机(SVM)的故障诊断方法. 为了确保在线故障诊断的实时性和准确性, 提出一种新型的混沌耗散离散粒子群(CDDPSO)算法, 用于故障诊断中特征变量的搜索. 仿真结果表明, CDDPSO 算法能有效地搜索到全局最优解, 而基于故障特征选择的故障诊断方法具有良好的故障诊断性能.

关键词: 故障诊断; 粒子群优化算法; 特征选择; 支持向量机

中图分类号: TP273

文献标识码: A

Chaotic dissipative particle swarm optimization and its application to fault diagnosis

WANG Ling, YU Jin-shou

(Research Institute of Automation, East China University of Science and Technology, Shanghai 200237, China.

Correspondent: WANG Ling, E-mail: shwl_1212@163.com)

Abstract: Considering the high dimensionality of data and the noises in large-scaled chemical process industry system seriously spoil the fault diagnosing performances, a fault diagnosis method based on fault feature selection and support vector machines is proposed. To ensure the real-time capability and correct rate of diagnosing online, a novel chaotic dissipative discrete particle swarm optimization (CDDPSO) is developed to search fault feature variables for diagnosis. Simulation results show that CDDPSO finds the global optima more effectively and the proposed fault diagnosis method possesses better diagnosing performance.

Key words: Fault diagnosis; Particle swarm optimization; Feature selection; SVM

1 引 言

在实际的故障诊断中, 现场采集的故障数据中包含大量与故障不相关的变量信息及其噪声. 这些变量和噪声既加大了故障诊断输入数据的维数, 严重影响到在线诊断的实时性, 又干扰了故障诊断系统对故障信息的敏感度, 降低了故障诊断算法的诊断性能.

为了有效消除高维数据对故障诊断的不良影响, 特征提取方法近年来被应用于故障诊断的数据预处理^[1]. 该方法可达到抽取系统信息、去噪和降维的目的, 能有效提高故障诊断的性能. 然而, 特征提取方法提取的是系统的特征, 而不仅仅是故障特征. 对于复杂系统而言, 特征提取方法可能因为故障对系统的整体影响不够显著, 需要保留大量的特征元(主元或独立元)用于故障诊断, 不能很好地实现数

据降维; 在系统噪声严重的情况下, 或因算法自身的特性, 无法有效地提取故障特征而使故障诊断算法失效.

为了弥补基于特征提取的故障诊断方法的不足, 人们提出了基于特征选择的故障诊断方法. 该方法能直接选择表征所需系统特征的变量, 剔除不相关变量, 从而有效地实现数据降维和去噪, 现已广泛地应用于数据预处理^[2,3]. 本文采用基于特征选择的故障诊断方法, 提出一种新型的混沌耗散离散粒子群算法(CDDPSO), 实现快速选取适用于故障诊断的最优变量组合, 去除不相关变量的干扰, 提升故障诊断的性能.

2 故障特征选择算法

当系统发生故障时, 与该故障相关的变量将表现出相应的变化, 这些变化直接表征了该故障. 基于

收稿日期: 2006-01-12; 修回日期: 2006-05-28.

基金项目: 教育部博士点专项基金项目(20030251003).

作者简介: 王灵(1979—), 男, 江苏扬州人, 博士生, 从事故障诊断、智能优化算法的研究; 俞金寿(1939—), 男, 浙江海宁人, 教授, 博士生导师, 从事化工过程控制、过程建模与控制等研究.

特征选择的故障诊断方法,其基本思想是通过优化算法,从所有的系统变量中找出最优的能表征故障特征的变量组合,以达到使用最少的变量获得最佳的故障诊断性能.因此,快速准确地选出特征变量是基于特征选择的故障诊断方法的关键.

2.1 粒子群算法

为了解决纯组合优化这类离散问题, Kennedy 等提出了离散 PSO (DPSO) 算法^[4]. 该算法保留了原始连续 PSO 的速度公式,即

$$V_{i_d} = wV_{i_d} + c_1 r_1 (p_{i_d} - x_{i_d}) + c_2 r_2 (p_{g_d} - x_{i_d}), \quad (1)$$

$$x_{i_d} = x_{i_d} + V_{i_d}. \quad (2)$$

粒子定义为由 0 和 1 组成的二进制向量,通过预先设定的 S 形限幅转换函数 $S(v_{ij})$, 将每个粒子元素速度 v_{ij} 转换为粒子该位元素取 1 的概率 p_{ij} .

$$S(v_{ij}) = \frac{1}{1 + e^{-v_{ij}}}. \quad (3)$$

2.2 混沌耗散离散粒子群算法

原始的 DPSO 算法收敛速度慢,难以有效地跳出局部最优解.为了增强 DPSO 算法的全局搜索能力,引入了耗散操作.即在每次迭代中,每个粒子以 k 的概率重新初始化,表示为

$$P_i = R_i(P_i), \text{rand}(\cdot) < k. \quad (4)$$

其中: P_i 表示第 i 个粒子; $R_i(P_i)$ 表示对 P_i 重新初始化; $\text{rand}(\cdot)$ 为 $[0, 1]$ 之间的随机数; k 为耗散控制参数,取值在 $[0, 1]$ 之间, $k = 0$ 为无耗散操作.

耗散操作的引入,使得 DPSO 算法有了跳出局部最优的能力,但对于复杂的优化问题,算法性能仍然不够理想.这主要是在耗散过程中,新的粒子是随机产生的,没有有效的机制来保证产生新模式的粒子搜索未搜索空间,从而不能更好地进行全局搜索.

为了进一步改善 DPSO 算法的性能,人们提出在 DPSO 算法中将混沌二进制序列与耗散操作相结合,即将随机初始化粒子群替换为由混沌二进制序列初始化粒子群.

根据门限函数

$$c(x) = \begin{cases} 0, & x < c; \\ 1, & x > c. \end{cases} \quad (5)$$

可由 Logistic 映射迭代 n 次,得到一个对应的 n 位长度的二进制混沌序列^[5]. 其中 c 为常数,对于 Logistic 映射, c 取 0.5. 由于混沌运动具有随机性和遍历性, CDDPSO 算法在迭代更新搜索过程中,通过耗散操作将新的模式不断引入到搜索空间,从而能有效地进行全局搜索,避免陷入局部最优.

仿真研究发现,在迭代后期,由于当前全局最优粒子与粒子历史最优非常接近,耗散后的粒子受

两个最优解的影响非常明显,很快进入当前全局最优值的邻域,从而无法更好地搜索解空间,跳出局部最优.因此,在 CDDPSO 算法的耗散过程中,当一个粒子被混沌耗散后,该粒子对应的历史最优解同时也被重置.

2.3 适应度函数

为了去除非必要变量以减小数据维数,提高故障诊断系统的实时性和正确率,在适应度函数 $f(x_{i_d})$ 中引入了惩罚项以剔除干扰变量,即

$$f(x_{i_d}) = f(i_d) - p \frac{m_c}{m_{\text{all}}}. \quad (6)$$

其中: $f(i_d)$ 为该粒子选中的变量在故障诊断中的正确率, m_c 为该粒子选中的变量数, m_{all} 为系统采集数据的全部变量数, p 为调整参数.

2.4 故障特征选择算法

在故障特征选择中, PSO 粒子由长度为 d 的 0 和 1 编码混沌二进制序列组成. 其中 d 为数据变量总数, 粒子元素值为 1 表示其对应的变量被选中, 为 0 则相反.

基于 CDDPSO 和 SVM 的故障特征变量选择算法具体实现如下:

- 1) 确定粒子群的粒子数,用混沌二进制序列初始化粒子;
- 2) 根据粒子所选择的变量得到相对应的故障训练数据集和验证数据集;
- 3) 用 SVM 进行故障分类,根据适应度函数计算出每个粒子的适应度值;
- 4) 根据适应度值更新粒子自身的历史最优值和全局最优值;
- 5) 根据式 (1) 和 (3) 更新粒子,并执行混沌耗散操作;
- 6) 判断是否满足终止准则,是则结束,否则跳转 2).

3 应用研究

3.1 函数优化测试

为了测试和验证所提出的 CDDPSO 算法的性能,在相同参数设置下,与 DPSO 算法和引入随机耗散操作的 DPSO 算法 (DDPSO) 对下列函数进行寻优:

$$F_1 = 100(x_1^2 - x_2)^2 + (1 - x_1)^2, \\ - 2.048 \leq x_i \leq 2.048;$$

$$F_2 = (x_1^2 + x_2^2)^{0.25} [\sin^2(50(x_1^2 + x_2^2)^{0.1}) + 1.0], \\ - 100 < x_i < 100;$$

$$F_3 = (4 - 2.1x_1^2 + x_1^4/3)x_1^2 + x_1x_2 + (-4 + 4x_2^2)x_2^2,$$

表 1 BDPSO,DDPSO 和 CDDPSO 函数优化性能比较

函数	全局最优值	BDPSO		DDPSO		CDDPSO	
		最差值	局部最优次数	最差值	局部最优次数	最差值	局部最优次数
F_1	0	0.22	18	9.67E-4	4	0	0
F_2	0	3.66E-4	18	2.02E-7	2	0	0
F_3	- 1.031 628	- 1.019 696	14	- 1.031 569	4	- 1.031 569	1
F_4	1	0.921 81	10	1	0	1	0

$$F_4 = 0.5 - \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{(1 + 0.001(x_1^2 + x_2^2))^4},$$

- 100 < x_i < 100;

算法各运行 20 次,仿真结果如表 1 所示.

3.2 在故障诊断中的应用

3.2.1 Tennessee Eastman 过程(TEP)

TEP 是伊斯曼化学公司创建的一个著名的化学过程模型,目的是构造一个评价过程控制监控方法的现实工业过程. TEP 共有 41 个测量变量和 12 个控制变量,引入闭环控制的仿真程序可以仿真正常工况和预设的 21 个故障. TEP 的标准故障数据集包含训练集数据和测试集数据,分别由 22 次不同的仿真运行采集构成.

每次运行都改变随机过程的随机种子,并引入了高斯噪声. 其中 1 次运行在无故障情况下,用于产生正常的工况数据,另外 21 次分别对应 1 次故障产生故障数据. 对于训练集数据,每次仿真运行 25 h, 3 min 采样一次,观测数据 500 组. 故障在系统正常运行 1 h 后加入,采集故障数据 480 组. 对于测试集数据,每次仿真运行 48 h,故障在系统正常运行 2 h 后加入,采集故障数据 960 组^[6].

为使仿真结果更具一般性,本文采用 TEP 标准故障数据进行故障诊断仿真.

3.2.2 对 TEP 的故障诊断

采用所提出的基于特征选择的故障诊断方法,对故障 1~故障 3(分别对应 TE 预设故障 4,6 和 7)进行故障诊断. 当故障 1 发生时,变量 51 产生了明显的阶跃变化,而其他变量保持稳定不变,因此故障 1 的故障特征变量为变量 51. 当故障 2 发生时,变量 1 和变量 44 均产生了阶跃变化,其他变量受其影响也都有所变化,但变量 1 和变量 44 的阶跃变化非常明显,任选其一即可达到故障诊断的要求,因此故障 2 的故障特征变量为变量 1 和变量 44 中任意一个. 当故障 3 发生时,变量 45 产生了明显的阶跃变化,另有 34 个变量受其影响偏离了正常工况值,但随着闭环控制的作用,这 34 个变量逐渐回到正常值,因此故障 3 的故障特征变量为变量 45.

考虑到 SVM 适用于小样本机器学习,而实际生产过程中缺乏故障数据,分别从训练数据集中的正常工况数据和故障数据中随机选择 30 组数据构成训练集,再各选出 60 组数据构成验证集. 采用 CDDPSO 算法对故障数据集进行 10 次特征选择,3 个故障中故障特征变量的选择结果如图 1 所示.




图 1 故障特征变量选择结果

用基于故障特征变量选择的故障诊断方法,以 CDDPSO 选中的变量为故障特征变量(FS),对测试集数据进行故障诊断. 作为比较,分别用全部变量(All)以及主元分析后的主元作为特征(PCA),采用 SVM 对 3 类故障的测试集数据进行故障诊断仿真. 3 种方法的正确率(即 SVM 对所有测试数据的正确分类率)详见表 2.

表 2 故障诊断性能比较 %

故障	FS	All	PCA
故障 1	100.0	61.3	68.2
故障 2	100.0	100.0	100.0
故障 3	100.0	51.8	59.7

由表 2 可见,在故障 2 的诊断中,3 种方法都达到了 100% 的故障诊断正确率. 对于故障 1 和故障 3,由于高维数据及其噪声对 SVM 的干扰,使得基于全部变量的故障诊断方法的正确率最差,分别只有 61.3% 和 51.8%. 基于 PCA 的方法虽然有效地降低了数据维度,一定程度上降低了系统噪声,改善了故障诊断的性能,但由于主元变换后得到的主元

变量不能很好地表征故障特征,正确率分别只有 68.2%和 59.7%。相比之下,基于故障特征选择的故障诊断方法由于直接选中故障特征变量进行故障分类,排除了不相关变量的干扰,能在复杂工况中有效地保证故障诊断性能,在 3 个故障中均达到了 100%的故障诊断正确率,具有良好的鲁棒性和可靠性

4 分析与结论

作为基于特征选择的故障诊断的关键技术,故障特征变量的选择对故障诊断的有效实施起着至关重要的作用。由函数优化测试以及故障特征选择的仿真结果可以验证,CDDPSO 算法能有效跳出局部最优,搜索到全局最优解,可靠地完成特征选择的任务,保证了故障诊断的可靠性和实时性。基于 SVM 的故障诊断方法适用于小数据集分类问题,而实际工业过程中缺乏故障数据,因此基于特征选择的 SVM 故障诊断方法具有一定的实用价值。

对于大型系统的故障诊断,由于系统存在大量的监控变量以及系统噪声的干扰,使得利用故障分类器对全部数据进行故障诊断的方法难以达到满意的性能。基于特征提取的方法虽能有效降低数据维度,但由于特征提取方法得到的特征并不仅仅是故障特征,不能确保在复杂工况下可靠地实施故障诊断。基于故障特征选择的故障诊断方法直接选取导致故障的源变量进行故障诊断,既大大降低了数据维度,又准确地保留了系统故障的本质特征,因此在复杂大系统中能有效可靠地实现对系统的在线故障

诊断。

参考文献(References)

- [1] 李尔国,俞金寿. 一种基于输入训练神经网络的非线性 PCA 故障诊断方法[J]. 控制与决策, 2003, 18(2): 229-232.
(Li Er-guo, Yu Jin-shou. Input-training neural network-based nonlinear principal component analysis approach for fault diagnosis[J]. Control and Decision, 2003, 18(2): 229-232.)
- [2] Leo Chiang, Pell H, Randy J. Genetic algorithms combined with discriminant analysis for key variable identification[J]. J of Process Control, 2004, 14(2): 143-155.
- [3] Oh I S, Lee J S, Moon B R. Hybrid genetic algorithms for feature selection [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2004, 26(11): 1424-1437.
- [4] Kennedy J, Eberhart R C. A discrete binary version of the particle swarm algorithm[C]. Proc of the 1997 Conf on Systems, Man and Cybernetics. Piscataway: IEEE Press, 1997: 4104-4108.
- [5] Kohda T, Tsuneda A. Pseudonoise sequences by chaotic nonlinear maps and their correlation properties [J]. IEICE Trans on Communication, 1993, 76(8): 855-862.
- [6] Chiang L H, Russell E L, Braatz R D. Fault detection and diagnosis in industrial systems [M]. London: Springer-Verlag, 2001.

(上接第 1196 页)

- [4] 杨智民,王旭,庄显义. 遗传算法在自动控制领域中的应用综述[J]. 信息与控制, 2000, 29(4): 329-339.
(Yang Zhi-min, Wang Xu, Zhuang Xian-yi. Application of genetic algorithm in control [J]. Information and Control, 2000, 29(4): 329-339.)
- [5] Dorigo M, Maniezzo V, Colnari A. Ant system: Optimization by a colony of cooperating agents [J]. IEEE Trans on Systems, Man and Cybernetics, 1996, 26(1): 29-41.
- [6] Shelokar P S, Jayaraman V K, Kulkarni B D. An ant colony approach for clustering [J]. Analytica Chimica Acta, 2004, 509(2): 187-195.
- [7] Takagi T, Sugeno M. Fuzzy identification of system and its application of modeling and control [J]. IEEE Trans on System, Man and Cybernetics, 1985, 15(1): 16-32.
- [8] Rudin W. Principles of mathematical analysis[M]. 3rd ed. New York: McGraw-Hill, 1976.
- [9] Box E P. Time series analysis, forecasting and control [M]. San Francisco: Holden Day, 1970.