

基于环状检测器的 WSN 节点异常度双向多重检测方法

顾 晟

(泰州学院 计算机科学与技术学院, 江苏 泰州 225300)

摘要: 双向多重检测一直是 WSN 节点异常检测的难点, 结合人工免疫原理提出了基于环状检测器的 WSN 异常度双向多重检测方法, 引入人工免疫原理, 设计了环状检测器, 利用环状检测器能够实现异常信号的分级, 并根据小波包提取信息的异常特征信号, 结合设计的环状检测器进行检测, 无需知道异常信号的参数和特点, 只要有正常的信号样本就能对 WSN 节点的早期故障进行检测, 实时预警; 以美国 Crossbow 公司生产的内置震动传感器的 WSN 节点进行测试, 测试结果表明, 环状检测器在选择合适的内径和外径后, 能够准确地对 WSN 节点的异常进行检测, 检测准确率高达 95% 以上, 比传统系统准确率提高了 35% 左右, 满足了 WSN 系统对 WSN 节点准确检测的要求, 有效地解决了传感网络节点异常双向检测的问题。

关键词: 环状检测器; 人工免疫; 无线传感器节点; 异常度

WSN Nodes Abnormal Degrees Two-way Multiple Detection Based on the Loop Detector

Gu Sheng

(School of Computer Science and Technology Taizhou University, Taizhou 225300, China)

Abstract: Two-way multiple detection has been the difficulty of WSN node anomaly detection based on artificial immune principle is presented based on the loop detector of WSN abnormality degrees two-way multiple detection method, this paper introduce artificial immune principle, designs the loop detector, using the loop detector can realize the abnormal signal classification, and according to the anomaly characteristics of the wavelet packet to extract the information of the signals, combining with the design of loop detector for testing, don't need to know parameters and characteristics of abnormal signal, as long as the normal signal samples can achieve early fault detection of WSN nodes, real-time early warning. Crossbow in the United States company's built-in vibration sensor of WSN node test, test results show that the inner and outer diameter of the loop detector in choosing appropriate, can accurately detect anomaly of WSN node detection accuracy is as high as 95% above, up about 35% higher than that of traditional system accuracy. Meet the requirement of the WSN system for WSN nodes, effective solve the problem of the abnormal bi-directional detection sensor network nodes.

Keywords: loop detector; artificial immune; WSN nodes; abnormal degree

0 引言

WSN 节点容易出现故障, 影响无线传感系统正常运行^[1-3]。传统的检测方法由于数据处理和分析过程复杂, 难以准确地对异常的节点进行检测^[4-5]。现实中, WSN 节点一旦出现故障, 一般会更换新的节点, 因此, 有必要研究一种能够及时准确检测 WSN 节点异常度的方法^[6]。

为此, 提出一种基于环状检测器的 WSN 节点异常度双向多重检测方法, 根据小波包提取信息的异常特征信号, 再根据环状检测器进行检测^[7-8]。与传统检测节点异常的方法相比, 此方法无需知道异常信号的参数和特点, 只要有正常的信号样本就能对 WSN 节点的早期故障进行检测, 为无线传感器网络系统的正常运行提供了有力的技术保障。实验证明, 利用该方法检测异常节点具有准确性高、稳定性好的特点^[9]。

1 人工免疫算法基本原理

人工免疫算法是人工智能领域的重要组成部分, 它能够对

信息进行智能处理, 被广泛应用到各个行业。人工免疫算法具有免疫识别、免疫学习、免疫记忆和克隆选择的功能。其中, 免疫识别是人工免疫算法的核心功能, 识别的目的是为了区分“自我”与“非我”。识别的过程如下:

- 1) 根据识别对象的特征进行标识;
- 2) 定义一个自我集合;
- 3) 随机产生一系列检测器, 对自我集合的变化进行检测;
- 4) 进行反向选择, 若检测集合与自我集合匹配, 则可判断被检测对象出现异常。

识别过程用基于人工免疫算法的法描述如下:

- 1) 根据特征向量或者正常状态下采集的参数定义一个自我集合 S ;
- 2) 随机产生一系列检测器, 构成了检测器集合 R ;
- 3) 对检测器 R 中的每一个检测器都进行反向选择, 其中任何一个检测器都不能与自我集合 S 中的任何一个特征向量相匹配。若出现相匹配的情况则需从检测器集合 R 中去除掉对应的检测器;
- 4) 根据与初始检测器 R 的匹配状况检测自我集合 S 的变化。如果出现匹配情况就可以判断自我集合 S 中出现异常变化。

收稿日期: 2014-05-16; 修回日期: 2014-06-19。

作者简介: 顾 晟 (1976-), 男, 江苏兴化人, 工程硕士, 讲师, 主要从事计算机网络安全方向的研究。

在免疫识别的过程中，检测器是识别的关键，也是人工免疫算法研究的热门问题。

2 人工免疫算法现存问题

2.1 应用于超球体检测器中现存问题

当前，在利用人工免疫算法时，人们普遍使用超球体检测器进行计算。超球体检测器的原理是：对于随机出现的初始检测器，对其进行反面选择后得到一个检测器的集合，在此基础上，通过克隆变异的方法得到更多的检测器。由于异常空间足够大，使得检测器的数量远不能满足，会导致“孔洞”的存在^[10-12]。Z. B. Hu 等人提出可变超球体检测器和多形状检测器虽然能够对检测器重叠和“孔洞”问题进行优化，但却无法对异常信号的异常度进行分级。

2.2 环状检测器的提出

为此，借鉴了人工免疫算法的免疫识别的原理，提出一种环状检测器的概念，利用环状检测器能够实现异常信号的分级。

在环状检测器中，构成要素有自我、自我集合、自我空间和非我空间这 4 项。这 4 项构成要素定义如下：

自我与自我集合：将被控对象正常运行时获得的数据 N 维特征向量定义为自我，记作： $S_i = [s_{i1}, s_{i2}, \dots, s_{iN}]$ ，此处 $i = 1, 2, \dots, K$ ；由很多的自我组成一个自我集合 S ，记作 $S = [S_1, S_2, \dots, S_K]$ 。

自我空间与非我空间：在 $[0, 1]^N$ 区域内，将自我 S_i 作为中心点，将 r_s 作为半径，这样构成的内部空间定义为 S_i 的自我空间。自我空间是自我集合 S 组成的自我空间集；在自我空间之外的所有空间定义为非我空间。

t 级环状检测器：将自我 S_i 作为中心，将 r_{t-1} 作为内径，将 r_t 作为外径，这样组成的环状空间定义为 S_i 的 t 级环状检测器，记作 $d_{it} = [S_i, r_{(t-1)}, r_t]$ 。

环状检测器示意图如图 1 所示。根据环状检测器构成要素的定义可知，阴影部分就是由自我 S_i 组成的自我空间；中心点是 S_i ，内径是 r_s ，外径是 r_1 所构成的环状空间就是 S_i 的 1 级环状检测器，记作 $d_{i1} = [S_i, r_s, r_1]$ ；以此类推，可以得出 S_i 的 2 级环状检测器、3 级环状检测器……

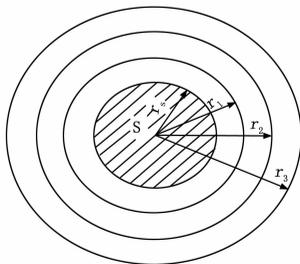


图 1 3 级环状检测器示意图

在一定的空间内，环状检测器之间可能出现相互重叠的情况，如图 2 所示。

3 基于环状检测器的 WSN 节点异常检测

3.1 环状检测器相关概念

为了便于对环状检测器检测异常度的方法进行准确描述，提出如下概念。

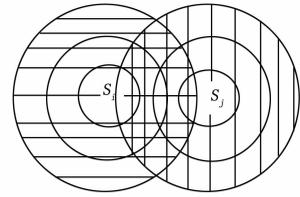


图 2 相互重叠的检测器集合

3.1.1 检测样本

在环状检测器中，“自我”与“非我”都根据特征向量进行描述。检测样本可用下式表示：

$$Ag_j = [ag_{j1}, ag_{j2}, \dots, ag_{jN}], \quad j = 1, 2, \dots \quad (1)$$

3.1.2 相似度

将检测样本与检测器间的距离定义为它们的相似度，相似度能够判断当前参数的异常度。相似度可用下式表示：

$$\text{similarity}(Ag_j, S_i) = \sqrt{\sum_{k=1}^N (ag_{jk} - s_{ik})^2} - r_s \quad (2)$$

也可记作： $\text{sim}(j, i) = \text{similarity}(Ag_j, S_i)$ 。

3.1.3 信号异常度的分级方法

在一定的区域内，检测器之间会发生重叠现象，因此不同的检测器对一样本进行检测时，其异常度和异常度分级也不同。因此，需要用最小相似度进行描述。

最小相似度可用下式表示：

$$\min_sim = \min[\text{sim}(j, 1), \dots, \text{sim}(j, K)] \quad (3)$$

异常度是相对正常状态而言的一种状态。在 $[0, 1]^N$ 空间内，用偏离正常状态的距离表示异常度。异常度可用下式表示：

$$\text{abnormality} = \min_A + r_s \quad (4)$$

设 $\min_A \in (-\infty, 0]$ 时的状态是正常状态，正常状态的异常度等级是 0；当 $\min_A \in (0, (r_1 - r_s)]$ 时，异常度等级是 1；以此类推，当 $\min_A \in ((r_{(t-1)} - r_s), (r_t - r_s)]$ 时，异常度等级是 $(t - 1)$ ；当 $\min_A \in ((r_t - r_s), +\infty)$ 时，异常度等级是 t 。

3.2 异常度双向多重检测方法

用“自我”表示设备正常状态时采集的参数样本，用“非我”表示设备异常状态时采集的参数样本。因此在环状检测器系统中，可以这样进行描述：设备正常状态时，采集参数样本并进行特征提取，获得一个自我集合 S 。将每个自我当作中心，就能组成多级环状检测器，将级数标记并置入检测器数据库中。检测器对采集的样本进行检测时，若样本特征符合自我空间要求，就可认定样本是正常状态；若样本特征符合某一级环状检测器，则按照相对应的等级进行区分；若样本特征不符合所有环状检测器，可认定为最高异常等级。

异常度等级算法步骤如下：

- 1) 设备正常状态时采集的参数，利用小波变换的方法进行特征提取并作归一化处理。能够获得正常的样本集合 $S_i, S_j = [s_{i1}, s_{i2}, \dots, s_{iN}]$ ；
- 2) 以 r_s 为半径构造自我空间；
- 3) 在正常样本集合 S_i 中，由最大异常度等级数 t 来决定步长。步长可用下式描述： $dir = 0.2 * 2^{(t-1-a)}$

在上述式中, a 表示检测器的级数。

自我样本 S_i 构成检测器集用下式表示:

$$D_i = [d_{i1}; d_{i2}; \dots; d_{i(t-1)}] \quad (5)$$

$$d_{i(t-1)} = [S_i, (r_s + (t-1) * dir), (r_s + t * dir)] \quad (6)$$

4) 对采集的样本进行小波变换提取特征并作归一化处理, 得到待测样本 Ag_j , 能够根据下式进行相似度计算:

$$A = [A(j, 1), A(j, 2), \dots, A(j, K)] \quad (7)$$

5) 利用最小相似度 \min_A 进行异常度等级。

4 实验与分析

为了验证本文所提方法的有效性, 需要进行一次实验。实验利用美国 Crossbow 公司生产的内置震动传感器的 WSN 节点采集数据, 信号采样频率为 10 kHz。通过改变节点内置模块的状态电路, 来模拟不同的节点故障。根据节点的故障类型, 模拟出电源能量即将耗尽故障、传感器灵敏度降低的故障、节点位置脱离有效通信范围故障、通信模块异常故障这 4 种主要故障。这几种故障程度各有差异, 部位各有不同。

WSN 节点在实际应用时, 一般不必知道故障部位, 因此将节点故障状态采集的数据作为异常数据, 将正常状态下采集的数据作为训练数据。

对采集的信号利用小波变换的方法进行滤波, 提取信号的 8 维特征。通过多次实验, 得到正常样本 100 个, 电源能量即将耗尽故障、传感器灵敏度降低的故障、节点位置脱离有效通信范围故障和通信模块异常故障这 4 种故障样本各 30 个。在正常样本中随机抽取了 70 个数据当作训练样本, 剩余的当作测试样本。

根据环状检测器的原理, 设置信号的异常等级 t 最高值为 4。则一级环状检测器的空间为 (0.1, 0.5), 二级环状检测器的空间为 (0.5, 1), 三级环状检测器的空间为 (1, 1.5)。对采集的信号样本分 3 组进行如下分级:

实验 1: 将测试样本进行异常度和异常度分级。如图 3 所示。

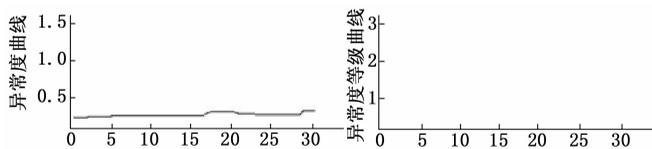


图 3 实验 1 结果

由图 3 可知, 对于 WSN 节点正常时采集的参数, 检测的准确率为 95%。提高准确率的关键是选择合适的自我半径, 文中选择的自我半径 $r_s = 0.2$ 。

实验 2: 将电源能量即将耗尽、传感器灵敏度降低的这两种故障样本作为测试样本, 进行异常度和异常度分级。如图 4 所示。

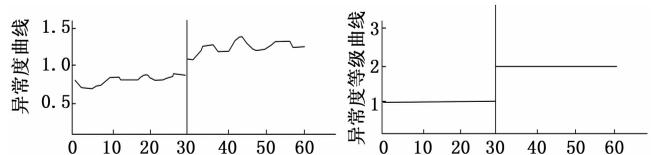


图 4 实验 2 结果

由图 4 可知, 对于电源能量即将耗尽和传感器灵敏度降低

这两种故障的检测, 后面 30 个的样本的异常度明显大于前面 30 个样本的异常度, 前面 30 个样本的异常度符合异常度分级中的第 1 级, 后面 30 个样本的异常度符合异常度分级中的第 2 级, 证明故障程度越高, 异常度就越高。

实验 3: 节点位置脱离有效通信范围故障和通信模块异常故障这两种故障样本作为测试样本, 进行异常度和异常度分级。如图 5 所示。

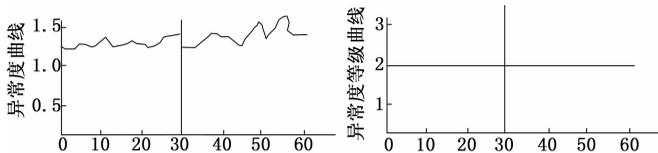


图 5 实验三结果

由图 5 可知, 对于节点位置脱离有效通信范围故障和通信模块异常故障这两种故障的检测, 前面 30 个样本的异常度和后面 30 个样本的异常度相似, 都符合异常度分级中的第 2 级。环状检测器的内径和外径是决定异常度分级的关键。若将内径和外径的距离缩小, 则异常度分级会更细。

为了进一步验证本文系统的优越性, 针对任意 10 个 WSN 节点用本文系统和传统系统进行异常度检测, 检测准确率结果如图 6 所示。

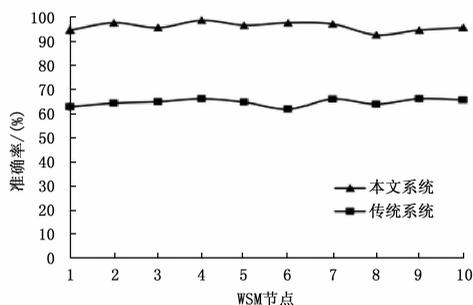


图 6 WSN 节点检测准确率对比

由上述实验可知, 环状检测器在选择合适的内径和外径后, 能够准确地对 WSN 节点的异常进行检测, 检测准确率高达 95% 以上, 比传统系统准确率提高了 35% 左右。满足了 WSN 系统对 WSN 节点准确检测的要求, 应用价值广阔。

5 结语

本文提出的基于环状检测器 WSN 节点异常度的检测方法, 只要参数设置适当, 就可以准确地检测 WSN 节点的异常状态, 并对异常程度进行合理判断, 能够实现对 WSN 节点的分级预警, 检测准确率高达 95% 以上。此方法对于设备异常情况分级预警具有较大的参考价值。

参考文献:

[1] 张盈盈, 潘宏侠, 等. 基于小波包和 Hilbert 包络分析的滚动轴承故障诊断方法 [J]. 电子测试, 2010, 6: 20-23.
 [2] 张秋, 梁小凡, 孙顺远, 等. 基于数据融合率的 WSN 节能策略 [J]. 计算机测量与控制, 2013, 21 (2): 454-457.
 [3] 许丽, 张进明, 等. 基于 PCA 的滚动轴承故障检测方法 [J]. 计算机仿真, 2010, 27 (6): 325-329.

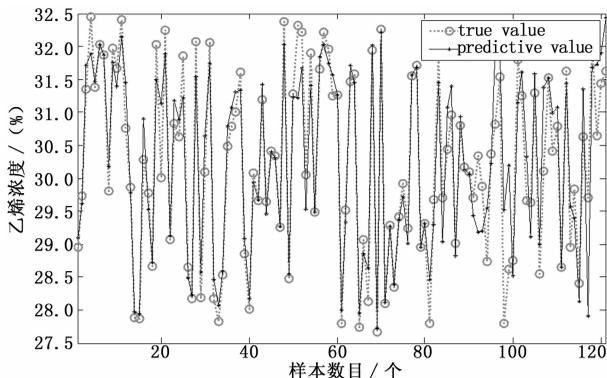


图 4 基于混沌离散 PSO 选取变量 PLS 回归预测

$$\begin{cases} RMSE = \frac{\|Y - Y_t\|_2}{\sqrt{M}} \\ MAXE = \max_M |Y - Y_t| \end{cases}$$

式中, $RMSE$ 为泛化均方根误差, 而 $MAXE$ 为最大泛化误差, M 为测试样本数, Y 为测试样本的实际输出, Y_t 为测试样本的预测输出。

3.2 实验结果分析

采用本文提出的混沌离散 PSO 算法, 经过多次迭代试验, 均可以得到全局最优解, 表明该方法有效, 由表 1 可以看出, 将所有原变量组合, 少量关键变量组合和本文所选的变量组合进行用于 PLS 建模, 本文所选的变量组合的泛化均方根误差和最大泛化误差比其它两种变量组合都小, 说明在乙烯生产过程中变量的选择或多或少都会影响模型的预测精度。而采用本文提出的方法进行变量选择建模减小了模型的泛化误差, 提高了模型预测精度。

4 结论

在乙烯生产过程中有诸多影响乙烯收率的变量, 而将选取少量变量或者所有变量进行建模都会影响模型的预测精度。本文在传统 PSO 算法基础上, 采用混沌的思想, 用计算粒子位置的隶属度将其离散化的方法, 来实现离散 PSO 算法在建模变量选择中的应用, 最后将该方法应用于乙烯生产过程模型变量选择的仿真实验中, 实验结果表明, 该方法可有效避免传统

PSO 算法容易陷入局部最优的问题, 并得到较好的模型预测精度。

参考文献:

[1] Xu L, Zhang W J. Comparison of different methods for variable selection [J]. *Analytica Chimica Acta*, 2001, 446: 477-483.

[2] Szekeley N. Simplifying the model of a complex industrial process using input variable selection [J]. *Periodica Polytechnica Electrical Engineering*, 2003, 47 (1/2): 141-147.

[3] Gauchi J P, Chagnon P. Comparison of selection methods of explanatory variables in PLS regression with application to manufacturing process data [J]. *Chemometrics and Intelligent Laboratory Systems*, 2001, 58: 171-193.

[4] 雷秀娟. 群智能优化算法及其应用 [M]. 北京: 科学出版社, 2012.

[5] Reynolds C W. Flocks, herds, schools: a distributed behavioral model [J]. *Computer Graphics*, 1987; 21 (4): 25-34.

[6] Liu B, Wang L, Jin Y H. Improved particle swarm optimization combined with chaos [J]. *Chaos, Solitons and Fractals*, 2005, 25 (5): 1261-1271.

[7] 王松汉. 乙烯工艺与技术 [M]. 北京: 中国石化出版社, 2012.

[8] Geladi P, Kowalski B R. Partial least-squares regression: a tutorial [J]. *Analytica Chimica Acta*, 1986, 185 (1): 1-17.

[9] 李丽娟. 最小二乘支持向量机建模及预测控制算法研究 [D]. 浙江大学, 2008.

[10] Kennedy J, Eberhart R. Particle swarm optimization [A]. *Proceedings of IEEE International Conference on Neural Networks* [C]. Perth Australia, 1995: 1942-1948.

[11] Kennedy J, Eberhart R. C. A discrete binary version of the particle swarm algorithm [A]. *Proceedings of the World Multi-conference on Systemic, Cybernetics and Informatics*. Piscataway [C]. NJ: IEEE Service Center, 1997: 4104-4109.

[12] Hasegawa K, Miyashita Y, Funatsu K. GA strategy for variable selection in QSAR studies: GA-based PLS analysis of calcium channel antagonists [J]. *Journal of Chemical Information and Computer Sciences* (S0095-2338), 1997, 37 (2): 306-310.

[13] Li L J, Su H Y, Chu J. Modeling of isomerization of C8 aromatics by online least squares support vector machine [J]. *Chinese Journal of Chemical Engineering* (S1004-9541), 2009, 17 (3): 437-444.

(上接第 2624 页)

[4] Dasgupta D, Forrest S. Artificial immune systems in industrial applications [C]. *Intelligent Processing and Manufacturing of Materials*, 1999.

[5] Gonzalez, Dasgupta D. Anomaly detection using real-valued negative selection [C]. *Genetic Programming and Evolvable Machine*, 2003.

[6] Zhou J, Dasgupta D. V-detector: An efficient negative selection algorithm with "probably adequate" detector coverage [J]. *Information Sciences*, 2009, 179: 1390-1406.

[7] Hu Z B, Zhou J, Ma P. A novel anomaly detection algorithm based on real-valued negative selection system [J]. *Knowledge Discovery and Data Mining*, 2008.

[8] 刘树林, 王日新, 黄文虎, 等. 基于反面选择算法的压缩机振动在线检测方法研究 [J]. *压缩机技术*, 2001, 5: 9-10.

[9] 窦唯, 刘树林, 孙明, 等. 生物免疫机理在往复压缩机在线状态检测中的应用 [J]. *流体机械*, 2004, 32 (5): 16-19.

[10] 刘树林, 丛蕊, 冷建成, 等. 孟庆武小波包特征免疫检测器在设备异常状态检测中的应用 [J]. *大庆石油学报*, 2005, 29 (6): 101-103.

[11] Zhou J, Dasgupta D. Augmented negative selection algorithm with variable-coverage detectors [A]. *Congress on Evolutionary Computation, CEC2004* [C]. Portland, Oregon, 2004: 123-136.

[12] 程军圣, 于德介等人. 时间-小波能量谱在滚动轴承故障诊断中的应用 [J]. *振动与冲击*, 2004, 23 (2): 34-36.