

基于级联极限学习机的基站空调在线监测系统

罗方芳¹, 陶求华²

(1. 集美大学计算机工程学院, 福建 厦门 361021; 2. 集美大学机械与能源工程学院, 福建 厦门 361021)

[摘要] 提出一种基于级联极限学习机的基站空调在线监测系统。首先, 基于某基站空调公司提供的监测数据集构建多个原子极限学习机分类器, 每一个原子极限学习机对应一种故障类别; 再将各原子分类器以级联方式组合用于未知样本的故障诊断; 最后将级联极限学习机与单独的多类极限学习机算法、SVM算法、BP神经网络算法、C4.5决策树算法进行比较测试。结果表明, 级联极限学习机算法提高了小类样本的故障识别率, 具有更高的故障诊断精度和较短的训练时间, 且诊断时间达到在线实时的要求。

[关键词] 基站空调; 故障诊断; 级联极限学习机; 在线监测

[中图分类号] TP 391.4

Air Conditioning Online Monitoring System for Base Station Based on Cascaded Extreme Learning Machines

LUO Fangfang¹, TAO Qiuhua²

(1. Computer Engineering College, Jimei University, Xiamen 361021, China;

2. School of Mechanical and Energy Engineering, Jimei University, Xiamen 361021, China)

Abstract: An efficient and real-time fault detection and diagnosis system for on-line base station air conditioner can ensure the stable operation of various equipment in the base station. Due to the fault categories of the base station air conditioner are nonlinear and unbalanced, an on-line monitoring system of cascaded extreme learning machines is proposed for the fault diagnosis of air conditioner in field base station. Firstly, based on the data set provided by a base station's air conditioning company, a collection of basic binary extreme learning machine classifiers are constructed, in which each classifier corresponds to a fault category. Then, these basic binary classifiers are combined in a serial cascade to be applied to the fault diagnosis of new samples. Finally, the cascaded extreme learning machine algorithm is compared with single multi-class extreme learning machine, SVM algorithm, BP neural network algorithm and C4.5 decision tree algorithm when they are used in the on-line monitoring system of the field base station air conditioner. Experimental results show that the cascaded extreme learning machine algorithm can improve the recognition rate for minority class, and has the advantages of higher fault diagnosis accuracy and shorter training time than traditional algorithm. Furthermore, the test diagnosis time can meet the on-line and real-time requirement.

Keywords: base station air-conditioning; fault diagnosis; cascaded extreme learning machines; on-line monitoring

[收稿日期] 2017-12-14

[修回日期] 2018-03-19

[基金项目] 国家自然科学基金资助项目(51508225); 福建省自然科学基金资助项目(2016J01244); 福建省教育厅资助项目(B16162; JB13137)

[作者简介] 罗方芳(1982—), 女, 讲师, 从事多标签分类学习、智能计算研究。E-mail:fangfangva@163.com

<http://xuebaobangong.jmu.edu.cn/zkb>

0 引言

由于通信基站设备需要在相对恒温的条件下才能正常工作,所以需要配备专用的基站空调,为基站内各种设备正常稳定的运行提供必要的条件。为确保基站空调稳定运行,有必要对基站空调进行实时的在线监测,了解相关设备的运行状况,并且对异常状态及时报警,以便尽早排查故障。因此,高效、实时的在线基站空调故障监测和诊断系统的研究有其实意义。目前的空调故障诊断系统主要有两种设计思路^[1]。一种是基于模型的故障诊断,将实测值和模型预测值之间的残差作为故障判断的依据。代表算法有:基于能量守恒的残差计算方法^[2]、基于残差特征和数理统计相结合的计算方法^[3],等等。基于模型的故障诊断方法应用很广泛,但其准确度依赖于所建模型的精度,故而对建模要求很高。另一种是基于数据的故障诊断,利用人工智能技术,通过教计算机如何学习、推理和决策来实现故障诊断。代表算法有:决策树算法^[4]、主成分分析法^[5]、神经网络算法^[6],等等。由于此类方法的参数选择较复杂以及训练速度较慢,故限制了其在故障诊断中的进一步使用。

某基站空调公司提供的数据集存在着样本类别不平衡的问题,正常样本数据高达 62%,而某些故障的样本占数据集比例仅为 1%。这种不平衡性会使得一些少量样本的故障类型在单个的多类分类器的训练过程中被视为噪声而遭“吞噬”。相较于决策树处理方法,这种小类样本识别率低的问题在神经网络类型的故障诊断处理中更为严重。借鉴于极限学习机参数选择简单、学习速度快的特点,本文设计了一个基于级联极限学习机的基站空调故障监测与诊断系统。针对每一种故障类型单独训练一个原子极限学习机,再将其级联组合,以此来解决训练集类别不平衡的问题。

1 空调系统模型

实验对象是目前应用最为广泛的移动基站空调系统,基站空调有内机和外机两部分,中间采用制冷剂管道连接。基站空调在线监测系统的构建分为离线学习阶段与在线实时监测分析阶段两部分。在离线训练阶段收集大量故障样本和无故障样本数据,预处理后导入级联极限学习机进行训练,获得稳定的检测分析模型。在线实时监测分析阶段,系统接收基站空调传感器的数据(温度、湿度、压力等),对数据进行归一化预处理后,输入基于级联极限学习机的在线监测分析系统,实时分析当前空调运行状态,若诊断显示故障,则及时预警排除故障以提高空调系统的制冷效率及维护通信基站的稳定运行。

某基站空调公司提供的数据集的故障样本数据情况如表 1 所示,总的样例数为 160,其中编号 1 代表“正常-无故障”模式。样本集 $D = \{(\mathbf{x}_i, \mathbf{T}_i) | 1 \leq i \leq m\}$, $\mathbf{x}_i = [x_1^i, x_2^i, \dots, x_d^i]^T$, 其中 $d = 14$ 代表基站采集的空调参数数目,参数编号及阈值范围如表 2 所示。样本集中的 $\mathbf{T}_i = [t_1^i, t_2^i, \dots, t_q^i]^T \in \{-1, 1\}^q$ 为与 x_i 对应的故障类别标记, $q = 9$ 。例如当某样本对应的故障为“吸气滤网堵塞”,则该样本对应的网络输出为 $[-1, -1, -1, 1, -1, -1, -1, -1, -1]^T$ 。

表 1 故障模式样本分布表
Tab. 1 Corresponding fault mode

编号 No.	故障种类 Fault mode	样本数 Sample number/个
1	正常-无故障模式 Normal-trouble free	100
2	制冷剂不足 Insufficient refrigerant	18
3	制冷系统内有空气 Air in the refrigeration system	2
4	吸气滤网堵塞 Suction strainer block	10
5	内机过滤器堵塞 Filter clogging of indoor unit	2
6	压缩机内漏 Internal leakage of compressor	15
7	外风机问题 External fan problem	5
8	电子膨胀阀开启过大 Over regulation of electronic expansion valve	3
9	电子膨胀阀开启过小 Small regulation of electronic expansion valve	5

表2 系统接收参数及其含义
Tab.2 Parameters and meanings

编号 No.	对应参数 Parameters	阈值 Range	编号 No.	对应参数 Parameters	阈值 Range
1	外界干球温度 Outdoor temperature/℃	20 ~ 40	8	轴承温度 Bearing temperature/℃	50 ~ 70
2	室内温度 Indoor temperature/℃	22 ~ 24	9	吸气过热度 Suction overheat/℃	3 ~ 23
3	室内湿度 Indoor relative humidity/℃	55 ~ 65	10	排气压力 Exhaust pressure/MPa	1.3 ~ 1.55
4	蒸发温度 Evaporation temperature/℃	2 ~ 7	11	吸气压力 Suction pressure/MPa	0.35 ~ 0.55
5	冷凝温度 Condensing temperature/℃	28 ~ 40	12	空气过滤器压差 Air filter pressure difference/MPa	80 ~ 160
6	压缩机排气温度 Compressor exhaust temperature/℃	70 ~ 115	13	油温 Oil temperature/℃	10 ~ 70
7	马达线圈温度 Motor coil temperature/℃	50 ~ 70	14	油压 Oil pressure/MPa	0.18 ~ 0.50

2 算法模型

2.1 训练原子 ELM 分类器

即使在深度学习盛行的机器学习领域,单隐层前馈神经网络(single hidden layer feed-ward neural network)以其强大的非线性逼近能力仍广泛应用于故障诊断中。新兴的极限学习机(extreme learning machine ELM)^[7-8]是单隐层前馈神经网络的代表。

ELM 的基本思想是通过训练误差的最小化得到最优的输出权值 β ,并且由输出权值 β 的 l_2 范式来达到较优的泛化效果。ELM 的数学模型为: $\min L_{\text{ELM}} = \|\beta\|^2 + C \sum_{i=1}^m \|\xi_i\|^2$, s. t. $f(x_i) = h(x_i)\beta = T_i - \xi_i, 1 \leq i \leq m$, 其中, $\beta = [\beta_1, \dots, \beta_L]^T$ 为隐层输出权值向量, C 为代价参数, ξ_i 为理论输出 T_i 与实际输出 $f(x_i)$ 的误差, $h(x_i)$ 为第 i 个实例 x_i 的隐层输出向量。

根据 Lagrange 对偶理论,采用 Moore-Penrose 广义逆计算方法即可解析求出网络的隐层输出权值,由此可见,ELM 算法避免了繁琐的迭代寻优的计算过程,也不易陷入局部极值。

然而在面对“训练样本集故障类别不平衡”的问题时,ELM 也遇到了与其他神经网络算法相同的困境,即,少量特殊样本会被单个的分类器在训练过程中视为噪声而遭“吞噬”,进而导致小类样本识别率低、泛化能力弱的情形。为此,本文为每一种故障类型(包括“正常-无故障”类型)单独设计一个原子 ELM 分类器,再将各分类器级联组合用于新样本的故障诊断。

原子 ELM 分类器的结构如图 1 所示。由于是针对具体的某一种故障类型训练原子 ELM 分类器,所以 ELM 的输出层只有一个神经元。实验阶段训练集的样本数为 100,所以需要对规模 $m = 100$ 的训练集针对具体故障模式进行数据预处理,即,该故障模式对应样本的输出值为 1,其余样本的输出值为 -1。

原子 ELM 分类器的理想输出公式为: $H\beta = T$, 其中,

$$H = \begin{bmatrix} g(x_1; w_1, b_1) & \cdots & g(x_m; w_1, b_1) \\ \vdots & & \vdots \\ g(x_1; w_L, b_L) & \cdots & g(x_m; w_L, b_L) \end{bmatrix}_{m \times L}, \beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_L \end{bmatrix}, T = \begin{bmatrix} t_1 \\ \vdots \\ t_m \end{bmatrix}。$$

由于设置隐层神经元数小于训练集样本数,即 $L < m$, 所以矩阵 H 是列满秩的。并且矩阵 $(I/C +$




图1 原子 ELM 分类器结构图

Fig.1 Structure of basic binary ELM classifier

HH^T) 为非奇异矩阵, 则输出权值 $\hat{\beta}$ 可由公式 (1) 求得。

$$\hat{\beta} = (I/C + H^T H)^{-1} H^T T \quad (1)$$

在测试阶段, 对于一个实例 x , 将其导入原子 ELM 分类器, 对应的输出可由公式 (2) 计算获得。

$$y^k = \begin{cases} 1, & \sum_{i=1}^L g(x; w_i, b_i) > 0 \\ -1, & \sum_{i=1}^L g(x; w_i, b_i) \leq 0 \end{cases} \quad (2)$$

原子 ELM 分类器的具体训练算法流程如下:

- 1) 输入归一化预处理后的训练集 D ;
- 2) 初始化隐层神经元数 L , 激励函数 g , 代价参数 $C = 1$;
- 3) 随机设定输入点与隐层之间的权值 w 和隐层偏置向量 b ;
- 4) 计算隐层的输出矩阵 $H = g(x; w, b)$;
- 5) 计算隐层与输出层之间的权值 $\hat{\beta} = (I/C + H^T H)^{-1} H^T T$ 。

2.2 级联 ELM

在所有的原子 ELM 分类器 (包括 “正常 - 无故障” 类型) 均训练完成后, 每一个原子 ELM 分类器相当于界定了某种故障模式与其他故障模式的分界线。将各原子 ELM 分类器按图 2 方式级联组合^[9]。由于在绝大多数情况下基站空调都处于正常运行模式, 所以将 “正常 - 无故障模式” 的原子 ELM 分类器放在级联串中的第一个。

在对未知样本故障诊断时, 将归一化预处理后的样本导入级联 ELM 系统。若第一个原子 ELM 分类器的输出为 -1, 它将继续进入下一个原子 ELM 分类器, 直到在第 j 个原子 ELM 分类器的输出为 1 时停止向下传输, 最终的诊断结果为第 j 个原子 ELM 分类器所对应的故障模式, $j = 1, \dots, 9$ 。

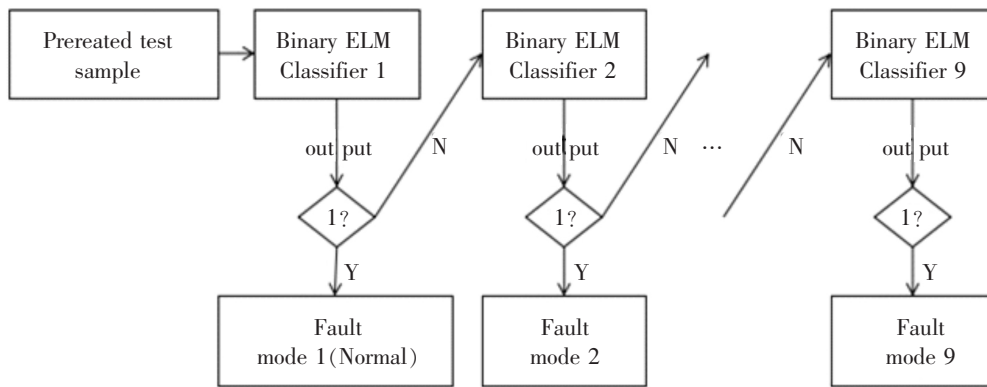


图 2 级联 ELM 流程图

Fig.2 Flow chart of cascaded ELM

3 实验结果分析

为了更好地测试级联 ELM 算法的性能, 从训练时间和故障诊断精度两方面进行考量。对比算法有: 单独的多类 ELM^[7]、单独的支持向量机 (SVM)^[10]、级联的 SVM、反向传输神经网络 (BP)^[11]、C4.5 决策树算法^[12]。其中 SVM 的级联组合方式与 ELM 的级联组合方式相同; 单独的 ELM 代码来源为 http://www.ntu.edu.sg/home/egbhuang/elm_random_hidden_nodes.html, 激励函数为 sigmoid 函数; SVM 算法的代码来源为 <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>, 采用径向基函数作为核函数; C4.5 决策树算法根据参考文献 [12], 采用 “后剪枝” 策略编写; BP 神经网络采用 Matlab 工具箱实现, 隐层神经元数设为 20。各程序均在 Matlab2012b 上部署运行, 训练集的样本数为 100, 测试集的样本数为 60。

和大多数的机器学习算法相类似, ELM 算法也存在参数(隐层神经元数)选择问题。原子 ELM 分类器的训练过程中, 采用增量生长法来确定, 将隐层神经元数从 5 开始递增测试学习误差, 若误差的变化低于阈值 δ ($\delta = 0.01$), 则停止增长。经多次实验后, 选择如表 3 所示的各原子 ELM 分类器隐层神经元数目。不可否认, 选择合适的隐层神经元数这一过程较为耗时, 在今后的工作中, 可以对隐层神经元个数的优化进行更深入的研究。但隐层神经元数确定后, 原子 ELM 分类器的训练过程是迅速的、稳定的。

表 3 各原子 ELM 分类器隐层神经元数
Tab.3 The number of hidden layer neuron of each binary ELM classifier

分类器编号 The ordinal number of classifier	1	2	3	4	5	6	7	8	9
隐层神经元数 Number of hidden neurons/个	35	20	15	18	10	18	15	10	15

表 4 罗列了各算法的训练时间、测试时间和故障诊断精度。从表 4 可以看出, 与 SVM 算法、BP 算法、C4.5 算法相比, 单独的多类 ELM 算法和级联 ELM 算法的训练速度极快, 时间优势十分明显。由于级联 ELM 算法需训练多个原子 ELM 分类器, 故训练时间比单独的多类 ELM 算法略长一些, 但级联 ELM 的故障诊断精度明显高于其他几种算法, 并且, 在线故障诊断时间达到毫秒级别, 满足实时监测的需求。

表 4 各算法性能对比
Tab.4 Performance comparison of each algorithm

算法 Algorithm	训练时间 Training time/s	测试时间 Testing time/s	故障诊断精度 Fault diagnosis accuracy/%
级联 ELM Cascaded ELM	1.241	0.032	0.908
单个 ELM Single ELM	0.127	0.024	0.720
级联 SVM Cascaded SVM	28.732	1.450	0.854
单个 SVM Single SVM	6.152	1.022	0.816
BP	76.240	0.078	0.743
C4.5	160.430	0.046	0.878

表 4 的对比数据显示单个 ELM、单个 SVM 的故障诊断精度均明显低于 C4.5 决策树算法, 这是由于训练集中故障模式的样本数不平衡造成的。特别地, 图 3 展示了训练集中小样本的故障模式, 如“制冷系统内有空气(模式 3)”、“内机过滤器堵塞(模式 5)”、“电子膨胀阀开启过大(模式 8)”, 及其在 20 次测试中被正确识别的比率。样本数的不平衡在单个的多类分类器的训练过程中会吞噬掉小样本数的故障模式, 相比于决策树分类算法, “吞噬”情况在神经网络结构的分类器中更为明显。采用级联 ELM 的方式能大幅度地提高小样本的故障识别率, 虽然 C4.5 算法对故障模式 8 的识别率高于级联 ELM 算法, 但在树的构造过程中, 需要对数据集进行多次的顺序扫描和排序, 因而训练时间长。总体而言, 级联 ELM 算法在训练时间和故障诊断精度方面的综合性能更优。




图 3 小样本故障识别率
Fig.3 Small sample fault recognition rate

4 结论

本文提出一种级联 ELM 的基站空调在线故障诊断算法。实验结果表明该算法与单独的多类 ELM 算法、SVM 算法、BP 算法、C4.5 决策树算法相比都能获得更高的分类精度。与 SVM 算法、BP 算法相比,级联 ELM 算法的训练时间也大大缩短。通过训练针对各个故障模式的原子 ELM 分类器来消除训练集中样本不平衡而产生的小类样本故障模式被吞噬问题,提高了小类样本的故障识别率,进一步通过级联原子 ELM 分类器来提高系统的泛化性能。测试数据的故障诊断时间达到毫秒级别,达到实时预警的需求,并输出可能的故障源,为基站空调维护人员提供相应的技术支持。但在真实复杂的野外基站空调运行环境中还有一些问题需要进一步考虑完善,如各基站传感器通信的有效距离,数据丢包率等问题。

[参考文献]

- [1] 迟金磊. 变风量空调系统的变工况故障检测与诊断研究 [D]. 上海: 上海交通大学, 2014.
- [2] WANG S W, WANG J B. Robust sensor fault diagnosis and validation in HVAC systems [J]. Transactions of the Institute of Measurement and Control, 2002, 24(3): 231-236.
- [3] 晋欣桥, 杜志敏, 肖晓坤, 等. 冷水机组系统的温度传感器故障诊断 [J]. 上海交通大学学报, 2004, 38(6): 976-981.
- [4] 程丽群. 基于故障树分析的汽车空调系统故障诊断研究 [J]. 制冷与空调, 2015, 15(3): 18-21.
- [5] 任文强. 基于主成分分析方法的空调系统传感器故障诊断与检测 [D]. 西安: 西安建筑科技大学, 2011.
- [6] 刘德永. 基于神经网络预测的中央空调故障诊断 [J]. 制造业自动化, 2012, 34(19): 41-43.
- [7] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [8] 裘日辉, 刘康玲, 谭海龙, 等. 基于极限学习机的分类算法及在故障识别中的应用 [J]. 浙江大学学报 (工学版), 2016, 50(10): 1965-1972.
- [9] YU Y L, YE Z F, ZHENG X H, et al. An efficient cascaded method for network intrusion detection based on extreme learning machines [J]. Journal of Supercomputing, 2016: 1-16.
- [10] 刘顺波, 段洪倡, 周光伟. 基于 SVM 的空调系统智能故障诊断研究 [J]. 安全与环境工程, 2013, 20(3): 139-142.
- [11] 杨金宝, 张昌宏, 陈平. 基于改进 BP 神经网络的网络故障诊断研究 [J]. 计算机与数字工程, 2012, 40(2): 65-67.
- [12] 周志华. 机器学习 [M]. 北京: 清华大学出版社, 2016: 73-79.

(责任编辑 朱雪莲 英文审校 黄振坤)