

# 电梯门机异常检测和故障定位方法

范玉川<sup>1,2,3</sup>, 范波<sup>3</sup>, 陈卓<sup>3</sup>, 张孝顺<sup>1,2</sup>

(1. 东北大学 佛山研究生创新学院, 广东 佛山 528311; 2. 东北大学 信息科学与工程学院, 辽宁 沈阳 110819;

3. 广东美的暖通设备有限公司, 广东 佛山 528311)

**摘要:** 提出一种电梯门机运行异常检测和故障定位方法. 首先,从电梯门机的运行数据中分离出开关门曲线并将其划分为10个运行段,提取各段的数据特征. 其次,提出基于箱线图的异常检测方法并利用各运行段的累积数据特征进行异常诊断;为防止数据不满足正态分布而造成的诊断误差,加入了门机特征数据的正态性检验方法,并对不满足正态分布的数据进行Box-Cox变换,使其满足正态分布. 最后,提取电梯门机分段特征数据,采用极限学习机(ELM)对门刀卡阻故障、整体阻力增大故障和同步带松脱故障3种故障进行分类模型训练. 经实验验证,提出的异常检测方法和故障定位方法准确度高,具有较高的应用推广价值.

**关键词:** 电梯;异常检测;箱线图;Box-Cox变换;故障定位;极限学习机

中图分类号: TP 206+.3 文献标志码: A 文章编号: 1005-3026(2024)06-0761-08

## A Method for Anomaly Detection and Fault Diagnosis of Elevator Door Machine

FAN Yu-chuan<sup>1,2,3</sup>, FAN Bo<sup>3</sup>, CHEN Zhuo<sup>3</sup>, ZHANG Xiao-shun<sup>1,2</sup>

(1. Foshan Graduate School of Innovation, Northeastern University, Foshan 528311, China; 2. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China; 3. Guangdong Midea Heating and Ventilating Equipment Co., Ltd., Foshan 528311, China. Corresponding author: FAN Yu-chuan E-mail: fycworking@163.com)

**Abstract:** A method for anomaly detection and fault diagnosis of elevator door machine operation is proposed. Firstly, the opening and closing door curve is separated from the operation data of the elevator door machine and divided it into 10 operating segments, and the data characteristics of each section is extracted. Secondly, an anomaly detection method based on boxplot is proposed, and the accumulated data characteristics of each running section are used for anomaly diagnosis. In order to prevent the diagnostic error caused by the data not satisfying the normal distribution, the normality test method of the feature data of the door machine is added, and the Box-Cox transformation is performed on the data that does not meet the normal distribution. Finally, the segmented feature data of the elevator door is extracted, and the extreme learning machine (ELM) is used to train the classification model for three faults: door knife jamming fault, overall resistance increase fault and synchronous belt loosening fault. Experiments have verified that the proposed anomaly detection method and fault diagnosis method have high accuracy and value of application and promotion.

**Key words:** elevator; anomaly detection; boxplot; Box-Cox transformation; fault diagnosis; ELM(extreme learning machine)

近年来,随着电梯安装量和保有量的剧增,电梯给人们生活带来便利的同时,因电梯故障造成的事故也不断出现,给人们的生命和财产安全

造成了较大的威胁.据统计,80%以上的电梯故障和70%以上的电梯事故都是因为门系统出现问题造成的<sup>[1]</sup>,因此,研究电梯门机的运行异常检

测和故障定位方法具有重要的实际意义。

国外对于电梯门机故障诊断方面的研究起步较早,特别是头部的几大电梯公司,如奥的斯(OTIS)公司1988年在其专利中公开了一种电梯监控设备和方法,提出用运动闭环链状态机作为异常检测工具进行门机的异常检测<sup>[2]</sup>;通力(KONE)公司2002年提出了一种通过捕捉门控制器中运行信号(电流信号、速度信号、脉冲信号、开关门指令信号和安全保护装置信息等)来评判当前电梯是否需要维护的方法<sup>[3]</sup>。国内学者对于电梯门机故障诊断的研究较少,多集中在对整梯系统故障诊断的研究。乔久鹏<sup>[4]</sup>利用电梯曳引机的速度曲线结合故障树分析法(FTA)设计了电梯专家系统,建立了电梯急停故障、电梯不能启动故障和楼层召唤故障等8棵故障树。冷子文等<sup>[5]</sup>介绍了神经网络技术在电梯故障诊断中的应用。宗群等<sup>[6]</sup>详细介绍了故障树在电梯故障诊断中的应用,并以电梯门故障为例进行了说明,但是具体的故障定位方法并没有提及。郑淑娟<sup>[7]</sup>通过对门系统的门扇加速度、转矩电流和励磁电流进行时域和频域分析来进行故障的定位,其思路具有很好的借鉴意义,但是没有考虑到电梯门机运行的速度变化,方法实用性不强。

随着人工智能技术的发展,越来越多的学者将机器学习技术运用到故障诊断领域中来,其

中,极限学习机(ELM)因具有学习效率高、无需调参等优点得到了广泛的应用。Luo等<sup>[8]</sup>提出了一种基于符合特征选择和参数优化的ELM故障诊断方法,并成功应用于轴承故障诊断中。Isham等<sup>[9]</sup>提出一种基于差分进化算法(DEA)的优化变分模态分解(VMD)参数选择方法,并结合ELM进行了风电机组齿轮箱的故障诊断。

本文首先针对电梯门机的运行特点,将门机运行曲线进行拆分和分段,基于箱线图原理提出门机运行异常检测方法,并引入Box-Cox转换保证数据的正态性;其次,提取电梯门机的分段运行特征并采用ELM对门刀卡阻故障、整体阻力增大故障和同步带松脱故障进行故障定位方法的开发;最后,通过实验验证所提出的故障定位方法的有效性。

## 1 梯门机开关门曲线分离方法

电梯门机的运行是一个间歇性的过程,需要将门机运行的开关门曲线从运行数据中分离出来才能获取门机运行的有效信息。本文通过同步获取的开关门信号和开关门到位信号定位开关门的起始和结束位置,从而将开关门曲线进行分离。如图1所示,通过开关门信号的上升沿判定开关门曲线的起始位置,通过开关门到位信号的上




图1 开关门脉冲信号和开关门到位脉冲信号

Fig. 1 Opening/closing pulse signal and opened/closed pulse signal

(a)—开门信号; (b)—关门信号; (c)—开门到位信号; (d)—关门到位信号。

升沿判定开关门曲线的结束位置,并分别对开关门曲线的起始位置和结束位置进行记录.

获取的开关门曲线有可能并不是完整的,如图 1 中的开门信号有 4 个上升沿,而开门到位信号有 5 个上升沿,仔细观察发现,并没有与第一个开门到位信号对应的开门信号,因此需要将第一个开门到位信号的位置删除;同理,关门到位信

号中缺少与关门信号最后一个上升沿对应的脉冲,需要将最后一个关门信号位置删除.

由于电梯门机的运行过程是一个变速过程,依据电梯门机的开关门控制逻辑可将电梯门机的开关门曲线划分为“缓开 1”“加速开”“匀速开”“减速开”“缓开 2”“缓闭 1”“加速闭”“匀速闭”“减速闭”和“缓闭 2”共 10 段,如图 2 所示.




图 2 开关门曲线分段示意图

Fig. 2 Sectional diagram of door opening and closing curve

## 2 基于箱线图及 Box-Cox 变换的电梯门机异常检测算法

### 2.1 箱线图异常检测原理

箱线图<sup>[10]</sup>是可以指示数据分布状态的图表,通过最小值、第一分位数、中位数、第三分位数和最大值 5 个指标来描述数据的分布,并可以明确地显示出离群点信息.

如图 3 所示,箱线图的中位数  $Q2$  是指数据集的中位数; $Q1$  表示下四分位数, $Q3$  表示上四分位数; $IQR$  表示四分位间距,即  $Q1$  和  $Q3$  之间的点数;图中的  $\sigma$  表示数据的标准差.具体计算公式为

$$Q1=(n+1)/4, \quad (1)$$

$$Q2=(n+1)/2, \quad (2)$$

$$Q3=3(n+1)/4, \quad (3)$$

$$IQR=Q3-Q1, \quad (4)$$

$$\text{上界}=Q3+1.5IQR, \quad (5)$$

$$\text{下界}=Q3-1.5IQR. \quad (6)$$

式中, $n$  表示数据总点数.

图 3 中,上、下边界分别对应正态分布图中的  $2.698\sigma$  和  $-2.698\sigma$ .按照正态分布  $3\sigma$  准则,数据落在  $-3\sigma$  和  $3\sigma$  之间的数据概率为 99.73%,数据落在  $-2.698\sigma$  和  $2.698\sigma$  之间的数据概率为 99.3%.利用正态分布数据的该特性,可以将下界和上界以外的数据归为异常值,以此来开发异常诊断算法.

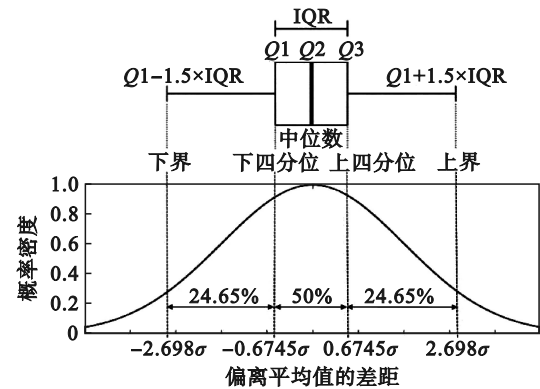


图 3 箱线图异常检测原理示意图

Fig. 3 Schematic diagram of boxplot anomaly detection principle

### 2.2 电梯门机数据特征的提取

对电梯门机的开关门曲线划分好的 10 段(“缓开 1”“加速开”“匀速开”“减速开”“缓开 2”“缓闭 1”“加速闭”“匀速闭”“减速闭”和“缓闭 2”)数据中的  $iq$ (扭矩电流)、 $RealSpeed$ (运行速度)和  $Disp$ (运行位移)数据进行计算,提取数据的  $mean$ (均值)、 $std$ (均方差)和  $kur$ (峭度):

$$mean = \frac{\sum_{i=1}^n x_i}{n}. \quad (7)$$

其中, $x_i$  表示第  $i$  个数据.

$$kur = \sqrt{\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2)^2}}. \quad (8)$$

其中, $\bar{x}$  表示数据均值.

$$\text{std} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (9)$$

按照如上方式计算,门机开关门分段曲线的数据可以计算得到  $10 \times 3 \times 3 = 90$  组数据特征,若一段数据有  $n$  个开门曲线,则得到的 90 组数据特征中每组有  $n$  个特征点。

### 2.3 门机特征数据的正态性检验

利用箱线图进行异常诊断的前提是数据服从正态分布,因此在进行异常诊断之前,需要对数据进行正态性检验.本文采用 Jarque-Bera 法<sup>[11]</sup>对数据进行正态性检验. Jarque-Bera 法需要计算数据的峭度和偏度,峭度计算公式与式(9)相同,偏度的计算公式如式(10)所示.

$$\text{skew} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\sqrt{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^{\frac{3}{2}}}} \quad (10)$$

Jarque-Bera 法建立了 JB 统计量:

$$\text{JB} = \frac{n}{6} \left[ \text{skew}^2 + \frac{(\text{kur} - 3)^2}{4} \right] \quad (11)$$

若数据服从正态分布,则 JB 统计量的值为 0.

### 2.4 Box-Cox 变换

当上述门机特征数据不满足正态分布时,可以通过 Box-Cox 变换<sup>[12]</sup>将特征数据转换为满足正态分布的数据. Box-Cox 变换是 Box 和 Cox 于 1964 年提出的一种广义幂变换方法,可以一定程度上减小不可观测的误差和预测变量的相关性,明显改善数据的正态性、对称性和方差相等性. Box-Cox 变换形式<sup>[13]</sup>为

$$y(\lambda) = \begin{cases} \frac{(y_i - C)^\lambda - 1}{\lambda}, \lambda \neq 0; \\ \ln(y_i), \lambda = 0. \end{cases} \quad (12)$$

其中:  $C$  为平移因子,当  $y < 0$  时,可以通过常数  $C$  进行平移;  $\lambda$  为引入的待定参数,参数的确定方法为假设经过转换后的因变量  $y$  是服从正态分布的,画出关于  $\lambda$  的似然函数,似然函数取最大值时对应的  $\lambda$  即目标参数。

### 2.5 电梯门机异常检测算法

利用箱线图方法进行异常诊断需要在算法部署后先进行一部分的数据采集形成电梯门机基准数据集.整体电梯门机异常检测算法流程如图 4 所示,具体算法流程如下:

- 1) 获取电梯运行数据,并截取开关门曲线;
- 2) 判断截取的开关门曲线中是否有完整的开门曲线和关门曲线,没有则重新采集数据,有则进行曲线分段;
- 3) 对分段好的门机数据的 iq(扭矩电流)、

RealSpeed(运行速度)和 Disp(运行位移)数据分别提取 mean(均值)、std(均方差)和 kur(峭度),得到 90 个特征值;

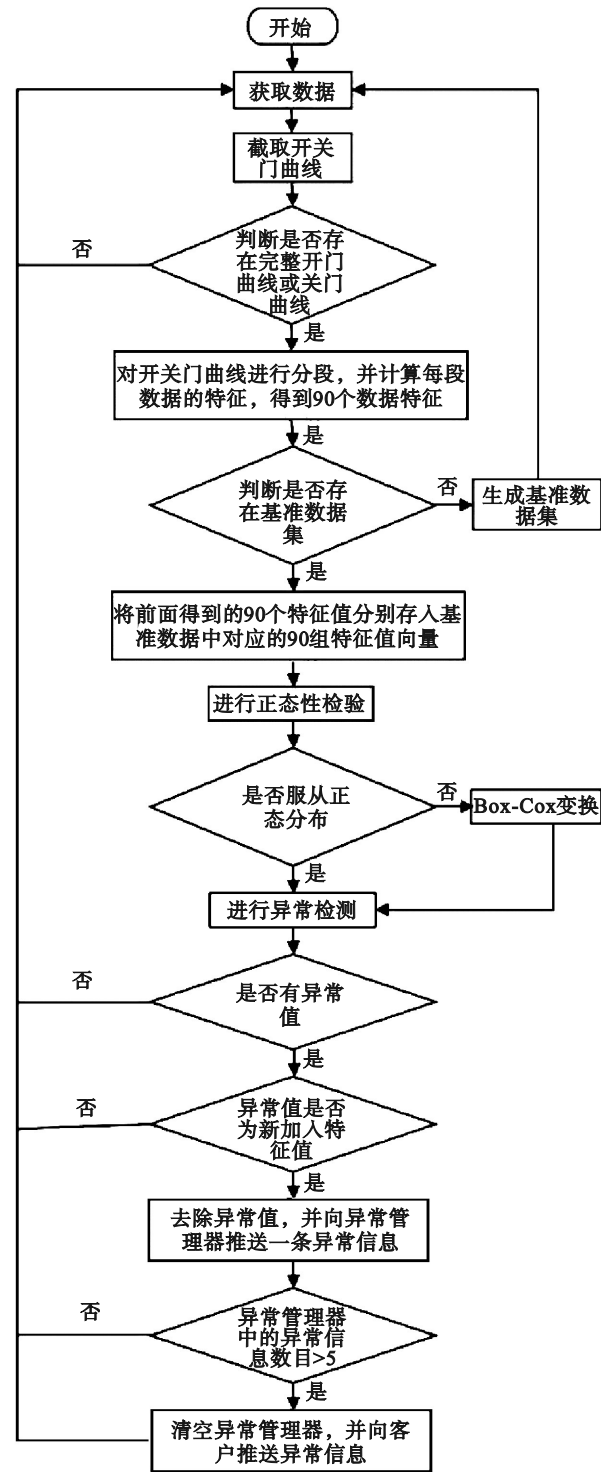


图 4 电梯门机异常检测算法流程图

Fig. 4 Flow chart of elevator door machine anomaly detection algorithm

- 4) 判断是否存在基准数据集,若不存在,需要先入基准数据集生成模块生成基准数据集,若存在则将新得到的 90 个特征值分别放入基准数据集对应的 90 组特征值向量;

5) 分别对 90 组特征值向量进行正态性检验,判断数据的正态性,若不服从正态分布,则进行 Box-Cox 变换,若服从正态性,则利用箱线图进行异常检测;

6) 若异常检测结果为无异常值,则进行下一次的数据采集和判定;若有异常值,则判断异常值是否为最新加入的数据,非最新则进行下一次的数据采集和判定,若为最新则去除本组异常特征值并向异常管理器推送一条异常信息;

7) 当异常管理器里面的异常信息超过 5 条时,向用户推送异常信息,清空异常管理器,并进行故障定位算法判定。

### 2.6 基准数据集生成方法

上述 2.5 节算法流程第 4 项中提到的基准数据集生成模块的执行流程如图 5 所示。

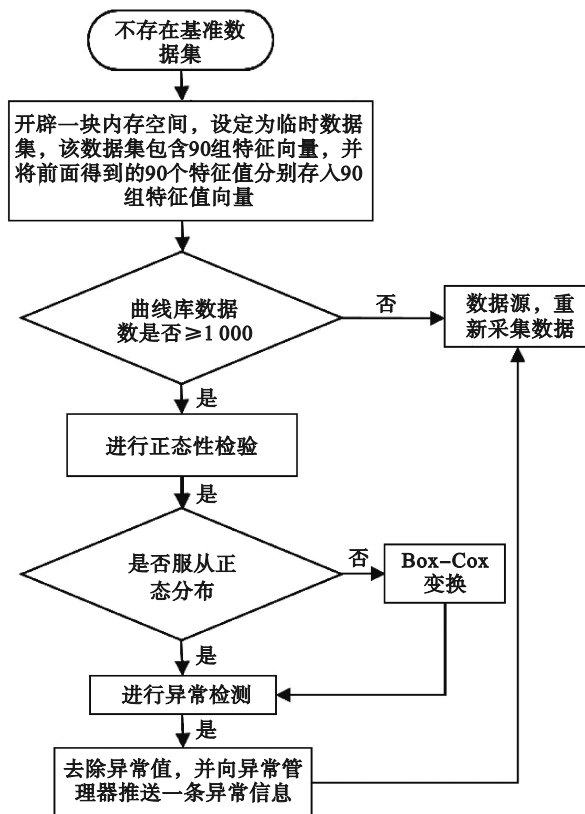


图 5 基准数据集生成流程图

Fig. 5 Flow chart of the benchmark dataset generation method

具体执行方法为

1) 当上述第 4 项中判定不存在基准数据集时,会在内存中开辟一块空间,并将其设定为临时数据集,该临时数据集包含 90 组空的特征值向量;

2) 将根据新获取的数据计算得到的 90 个电梯门机特征值分别存入该临时数据集;

3) 重复上述流程,使临时数据集中 90 组特征值不断积累,当向量长度大于 1 000 时,会执行异常检测运算,并剔除其中的异常值;

4) 上述剔除异常值后得到的临时数据集即为基准数据集。

## 3 基于 ELM 的电梯门机故障定位算法

### 3.1 ELM

ELM 属于前馈神经网络的一种<sup>[14]</sup>,最早于 2006 年由新加坡南洋理工大学的黄广斌教授提出<sup>[14]</sup>.单个样本极限学习机的网络结构如图 6 所示,输入层的  $m$  个输入表示样本的  $m$  个特征,输出层  $n$  个输出表示每个样本的输出个数,该网络输出结构可以描述为

$$y_k = \sum_{i=1}^r \beta_k h(\sum_{j=1}^m (\omega_i x_j + b_i)) \quad (13)$$

式中:  $k=1, 2, \dots, n$ ;  $r$  表示隐含层神经元个数;  $\omega_i$  和  $b_i$  为输入层与隐含层之间的输入权重和偏置;  $\beta_k$  为隐含层和输出层之间的输出权重。




图 6 极限学习机网络结构图

Fig. 6 Network structure diagram of ELM

假设有  $L$  组输入输出样本,则整个网络可采用矩阵形式表示,输入矩阵为

$$P = \begin{bmatrix} P_{1,1} & \dots & P_{1,L} \\ \vdots & & \vdots \\ P_{m,1} & \dots & P_{m,L} \end{bmatrix} \quad (14)$$

式中:  $L$  表示样本数;  $m$  表示特征数目.输出矩阵为

$$T = \begin{bmatrix} T_{1,1} & \dots & T_{1,L} \\ \vdots & & \vdots \\ T_{n,1} & \dots & T_{n,L} \end{bmatrix} \quad (15)$$

式中,  $n$  表示输出值个数.随机生成输入权值矩阵为

$$IW = \text{rand}(N, m), \quad (16)$$

偏置矩阵为

$$B = \text{repmat}(\text{rand}(N, 1), 1, L). \quad (17)$$

式中:  $N$  为神经元数目;  $\text{rand}(a, b)$  表示随机生成  $a$  行  $b$  列的矩阵;  $\text{repmat}(a, b, c)$  表示将矩阵  $a$  复制

生成  $b$  行  $c$  列的分块矩阵. 设激活函数为

$$Y=h(X). \quad (18)$$

则隐含层输出矩阵为

$$\mathbf{H}=h(\mathbf{IW}\times\mathbf{P}+\mathbf{B}). \quad (19)$$

设输出权值矩阵为

$$\boldsymbol{\beta}=\begin{bmatrix} \beta_{1,1} & \cdots & \beta_{1,n} \\ \vdots & & \vdots \\ \beta_{N,1} & \cdots & \beta_{N,n} \end{bmatrix}. \quad (20)$$

则模型的权值训练问题可以转化为如式(21)的最优化问题<sup>[15-16]</sup>.

$$\min_{\boldsymbol{\beta}} \|\mathbf{H}\times\boldsymbol{\beta}-\mathbf{T}\|. \quad (21)$$

求解该最优化问题可转化为求解式(22)的线性求解问题.

$$\hat{\boldsymbol{\beta}}=\mathbf{H}^+\mathbf{T}, \quad (22)$$

式中,  $\mathbf{H}^+$  为隐含层输出矩阵  $\mathbf{H}$  的广义逆矩阵.

### 3.2 电梯门机故障分类算法

文中涉及的电梯门机故障包括门刀卡阻故障、整体阻力增大故障和同步带松脱故障共 3 类故障. 选取第 2.2 节得到的 90 组特征值向量中的  $iq\_mean$  (扭矩电流均值)、 $iq\_std$  (扭矩电流均方差) 和  $iq\_kur$  (扭矩电流峭度),  $RealSpeed\_mean$  (运行速度均值), 4 种特征类型共 40 个特征值组成特征值向量.

对多组数据的特征值向量作为训练集进行故障标签, 对应设定作为模型训练的输出. 将训练集及其对应标签输入 ELM 模型进行训练即可得到模型的训练参数.

## 4 算法试验验证

### 4.1 试验数据的采集

图 7 为本次试验所用电梯门机试验台, 该试验台包含门机控制器、异步电机、同步带、随行链、梯门门板、层门门板和门板轨道等部件组成.

门刀卡阻故障试验采取如图 8 所示在门刀滑块处放入挡块的方式模拟, 为保证试验的充分性, 图中白框圈出的黑色挡块分别放置在门刀滑轨的左端和右端分别进行试验, 以模拟门刀卡阻故障的不同情形.

门板的整体阻力增大故障主要是由于滑轮磨损或滑轨污垢增多造成的摩擦阻力增大, 在试验中采用砝码和滑轮来模拟门板的阻力, 不同大小的砝码可以模拟不同大小的阻力并有助于对阻力进行量化. 图 9 中的白框部门为本次试验采用的砝码, 砝码质量分别取 1, 2 和 3 kg 3 种, 对应

3 种不同的阻力大小.



图 7 电梯门机试验台

Fig. 7 Elevator door test bench




图 8 门刀卡阻试验方案

Fig. 8 Test scheme of elevator door knife jamming fault




图 9 整体阻力增大试验方案

Fig. 9 Test scheme for overall resistance increase of elevator door knife

同步带松脱故障试验主要模拟的是门机同步带老化松脱但未出现打滑的情况, 对该故障进行诊断可以有效防止同步带松脱严重出现打滑对用户生命安全造成的威胁. 同步带松脱故障

采用如图 10 所示的放松张紧螺栓的方式进行模拟,试验中将张紧螺栓分别放松 1~5 mm 以模拟不同的松脱状态.




图 10 电梯门机同步带松脱试验方案

Fig. 10 Test scheme of elevator door machine synchronous belt looseness

#### 4.2 模型训练和结果分析

按照上述试验方案分别采集 310 组开关门循环的正常数据,109 组开关门循环的门刀卡组故障数据,217 组开关门循环的整体阻力增大故障数据和 420 组开关门循环的同步带松脱故障数据,合计 1 056 组数据.

按照 8:2 的比例将数据划分为训练集和测试集,并将数据进行归一化处理,归一化方法为

$$y'_i = \frac{x'_i - \min(x'_i)}{\max(x'_i) - \min(x'_i)}, 1 < i < n. \quad (23)$$

式中: $y'_i$ 表示归一化后的数据; $x'_i$ 表示归一化前的数据; $n$ 表示数据点数.

将归一化后的数据导入 ELM 模型进行模型训练和模型验证,模型的隐含层神经元个数设置与特征数相同,模型训练时间为 0.04 s.

利用训练好的模型对训练集和测试集进行测试,测试结果如表 1 所示,训练集的分类准确率为 97.63%,而测试集的分类准确率为 99.53%.可知,该模型达到了较高的诊断准确率.

表 1 数据分类结果

Table 1 Data classification results		%
数据集	分类准确率	
训练集	97.63	
测试集	99.53	

图 11 为测试集诊断结果展示,图中“1”表示正常数据,“2”表示门刀卡组故障数据,“3”表示整体阻力增大故障数据,“4”表示同步带松脱故障数据.测试集共 211 组数据,仅有一组数据为门刀卡组故障被错误识别为同步带松脱故障,其他组数据均可被正确识别.




图 11 测试集诊断结果

Fig. 11 Test set diagnostic results

因隐含层神经元个数对 ELM 模型分类精度有影响,有必要对不同隐含层神经元数目的 ELM 模型精度进行对比分析.如图 12 所示,该模型隐含层神经元个数在 40~200 之间时模型的预测精度能保持在 96% 以上,随着隐含层神经元个数的增加预测准确率呈下降趋势.




图 12 隐含层神经元个数对 ELM 性能的影响

Fig. 12 Effect of the number of hidden layer neurons on ELM performance

## 5 结 论

1) 本文提出了电梯门机开关门数据分离方法和开关门数据分段方法,将电梯门机变速开关门数据转换成了 10 段体现门机不同运行状态的数据.

2) 本文提出了基于箱线图原理的电梯门机异常运行检测方法和电梯门机运行特征数据正态性评估方法,对于不满足正态分布的电梯门机运行特征数据提出了利用 Box-Cox 转换使其正态化的方案.

3) 采用 ELM 作为分类器对选取的典型电梯

门机运行特征数据进行故障分类,成功对门刀卡阻故障、电梯门机整体阻力增大故障和同步带松脱故障进行了预测分类,并对比分析了不同隐含层神经元个数对模型预测精度的影响.试验结果表明:该模型具有运行速度快,预测准确度高等优点;隐含层神经元个数在 40~200 之间时模型的预测精度较高,能保持在 96% 以上,随着隐含层神经元个数的增加预测准确率呈下降趋势.

#### 参考文献:

- [ 1 ] 刘秀华,张兴法.电梯门系统主要事故的分析与预防[J].中国特种设备安全,2006,22(1):13-14.  
(Liu Xiu-hua, Zhang Xing-fa. Analysis and prevention of main accidents in elevator door system [J]. *China Special Equipment Safety*, 2006, 22(1): 13-14.)
- [ 2 ] Coste S D, Schiend G A. Elevator car door and motion sequence monitoring apparatus and method; US4750591 [P]. 1988-06-14.
- [ 3 ] Pekka P, Riitta P J, Seppo S A, et al. Elevator door monitoring method that uses internal control signals of the door system to determine its need for maintenance W0, 200236476-A1 [P]. 2002-04-10.
- [ 4 ] 乔久鹏.电梯故障检测及诊断系统研究[D].哈尔滨:哈尔滨工业大学,2007.  
(Qiao Jiu-peng. Research on detection and diagnosis system for elevators fault [D]. Harbin: Harbin Institute of Technology, 2007.)
- [ 5 ] 冷子文,卜永刚,朱文杰.神经网络在电梯故障诊断中的应用[J].中国电梯,2019,30(19):70-72.  
(Leng Zi-wen, Bu Yong-gang, Zhu Wen-jie. Application of the neural network to elevator fault diagnosis [J]. *China Elevator*, 2019, 30(19): 70-72.)
- [ 6 ] 宗群,陈东航,牙淑红.基于故障树分析法的电梯远程监控系统故障诊断[J].制造业自动化,2003,25(11):45-48.  
(Zong Qun, Chen Dong-hang, Ya Shu-hong. Fault diagnosis of remote elevator monitor system based on fault tree analytical method [J]. *Manufacturing Automation*, 2003, 25(11): 45-48.)
- [ 7 ] 郑淑娟.电梯门系统状态监控和实验研究[D].上海:上海交通大学,2009.  
(Zheng Shu-juan. State monitor and experimental research of elevator door system [D]. Shanghai: Shanghai Jiao Tong University, 2009.)
- [ 8 ] Luo M, Li C S, Zhang X Y, et al. Compound feature selection and parameter optimization of ELM for fault diagnosis of rolling element bearings [J]. *ISA Transactions*, 2016, 65: 556-566.
- [ 9 ] Isham M F, Leong M S, Lim M H, et al. Intelligent wind turbine gearbox diagnosis using VMDEA and ELM [J]. *Wind Energy*, 2019, 22(6): 813-833.
- [ 10 ] Mirzargar M, Whitaker R T, Kirby R M. Curve boxplot: generalization of boxplot for ensembles of curves [J]. *IEEE Transactions on Visualization and Computer Graphics*, 2014, 20(12): 2654-2663.
- [ 11 ] Fiorentini G, Sentana E, Calzolari G. On the validity of the Jarque-Bera normality test in conditionally heteroskedastic dynamic regression models [J]. *Economics Letters*, 2004, 83(3): 307-312.
- [ 12 ] 田亚茹.基于 Box-Cox 变换结合多种算法的风电机组数据预处理与故障预警的研究[D].保定:河北大学,2022.  
(Tian Ya-ru. Research on data preprocessing and fault warning of wind turbine based on Box-Cox transform and multiple algorithms [D]. Baoding: Hebei University, 2022.)
- [ 13 ] Osborne J W. Improving your data transformations: applying the Box-Cox transformation [J]. *Practical Assessment, Research and Evaluation*, 2010, 15(12): 1-9.
- [ 14 ] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [ 15 ] Huang G B, Wang D H, Lan Y. Extreme learning machines: a survey [J]. *International Journal of Machine Learning and Cybernetics*, 2011, 2(2): 107-122.
- [ 16 ] Huang G B, Zhou H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems, Man, and Cybernetics Part B, Cybernetics: a Publication of the IEEE Systems, Man, and Cybernetics Society*, 2012, 42(2): 513-529.