

基于深度自编码器和 t-SNE 算法的电梯故障预警

蒋曦阳¹,王淼²,童一飞²,黄健鹏²,黄晓晨¹

(1. 江苏省特种设备安全监督检验研究院,江苏 南京 210036;

2. 南京理工大学 机械工程学院,江苏 南京 210094)

摘要:为提高电梯承运质量,针对电梯轿厢系统,设计基于深度自编码器(DAE)和 t 分布随机邻域嵌入算法(t-SNE)相结合的电梯轿厢系统故障预警模型。通过计算电梯轿厢系统运行时振动信号的重构误差,并将其与预警阈值进行对比分析,可以直观地对振动信号波形进行分类,判别轿厢系统运行是否出现异常,通过 t-SNE 算法进行可视化分析。实验结果表明:该模型能够有效实现电梯轿厢系统的故障实时预警功能,为电梯的预防性维护提供依据。

关键词:电梯系统;故障预警;自编码器(AE);t-SNE

中图分类号:TP277.3 **文献标志码:**A **文章编号:**1671-5276(2023)05-0228-04

Elevator Fault Early Warning Based on Deep Auto-encoder and t-SNE Algorithm

JIANG Xiyang¹,WANG Miao²,TONG Yifei²,HUANG Jianpeng²,HUANG Xiaochen¹

(1. Special Equipment Safety Supervision Inspection Institute of Jiangsu Province, Nanjing 210036, China;

2. School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: In order to improve the quality of elevator transportation, designs a fault early warning model for elevator car system based on the combination of DAE and t-SNE. The reconstruction error of the vibration signal is calculated in operation of the elevator car system and compared with the early warning threshold to visually classify the vibration signal waveform, judge abnormal operation of car system, and visual analysis is conducted through the t-SNE algorithm. The experimental results show that the model can effectively realize the real-time fault warning function of the elevator car system and provide a basis for the preventive maintenance of the elevator.

Keywords: elevator car system; fault warning; auto-encoder (AE); t-SNE

0 引言

近年来,我国电梯年保有总量增长迅速。从 2010 年到 2019 年,我国电梯年保有量从 162.9 万台快速升至 700 万台^[1],已成为全球电梯保有量最多的国家。根据相关调查,我国电梯市场将持续发展,而相关核心领域技术的研发力度也会不断增强,未来的发展空间较为广阔。

虽然电梯保有量的快速增加,能够给人们的日常生活提供便利,但同时也带来了相应的问题:由于电梯保有量连年增长,电梯维保质量在不同维修单位中参差不齐^[2]。为了确保用户的安全,各省市的电梯维修公司和特种设备安全监督检验所将组建专门的维修团队,对电梯设备进行定期寿命检查,特别是对电梯的关键部件,以避免因其退化故障而停机检查,造成不必要的经济损失或人员伤亡。

近年来,许多国内外学者从不同角度,多方面开展研究,寻找电梯故障预警与排查的有效方法。MISHRA K M 等^[3]从时间序列数据中提取数据,提出了用于电梯故障检测的具有高信息含量的深度特征自动计算方法,该

方法基于电梯系统的运行状态值之间的内部关系,建立神经网络模型,通过预测下一时段的状态值来预测电梯系统可能会出现的故障。OLALERE I O 等^[4]使用了一种电梯运行状态远程监测方法,该方法利用物联网(IoT)设备进行远程数据采集(RDA),获取振动信号和声信号数据,并提取远程故障指标(RFI)来监测电梯设备的安全性。TRCKA N 等^[5]提出了一种电梯维护方法,其特征在于能够做出系统决策,并在此基础上识别有故障的特定部件,并通过电梯事故数据仿真证明了其有效性。王林林^[6]改进了 Holt-Winters 的时间序列预测模型,并将该模型的诊断结果作为输入,用于预测电梯故障。邹鑫等^[7]基于 S7-1500PLC,设计了一种电梯运行监控系统,其仿真实验结果表明,该系统能够有效降低电梯运行能耗,并提高了查找故障的准确性和维修效率。然而,现有电梯故障算法分类精度较低,且难以满足实时性要求。因此,本文以电梯轿厢系统为研究对象,建立了基于深度自动编码器的故障预警模型,设计了轿厢水平(垂直)振动加速度的 t-分布随机邻域嵌入算法(t-SNE)可视化算法,用于检测轿厢系统的运行状态。

基金项目:2020 年度江苏省特种设备安全监督检验研究院科技项目(KJ(Y)2020006)

第一作者简介:蒋曦阳(1989—),男,江苏南京人,工程师、电梯检验师,本科,研究方向为机电类特种设备检验检测和技术研究,1063939337@qq.com。

1 基于 DAE-t-SNE 的电梯轿厢系统故障预警模型构建

1.1 模型基本原理

深度自编码器 (DAE) 模型在通过训练之后,能够将输入的样本根据自学习的结果在特征空间上重构,其还原重构所得到的结果,可以判断测试样本与训练样本是否同分布。然后将 DAE 处理后得到的结果经 t 分布随机邻域嵌入 (t-SNE) 算法可视化展示,至此模型构建完成。

在构建 DAE-t-SNE 故障预警模型时,选择电梯轿厢系统在正常运作下的振动加速度信号作为训练样本,并构成特征空间。当模型在测试样本中的重构误差发生偏离,超出了正常的分布范围时,表明特征空间的相关性出现异常,即可能在该时间点电梯轿厢系统有局部缺陷发生。随着电梯继续运行,模型得到的重构误差越发偏离正常分布范围,表明故障越来越严重。通过对重构误差的分布进行可视化,并设置预警阈值,可以方便电梯维修人员进行预防性维修,如式(1)所示。

$$e = \|x - \hat{x}\|_2$$

$$\text{结果} = \begin{cases} 0 (\text{正常状态}), e \leq e_{th} \\ 1 (\text{存在故障}), e > e_{th} \end{cases} \quad (1)$$

式中: e 为测试样本重构误差,由测试样本和重构样本的二范数求得; e_{th} 为预警阈值,当求得重构误差超过阈值时,判定结果为存在故障。

1.2 模型结构与工作流程

如图 1 所示,电梯轿厢系统故障预警重点分为两部分。第一部分为离线学习,通过训练样本的学习得到故障预警模型,并通过测试集调试模型参数;第二部分为在线学习,模型根据输入的样本进行实时健康判断。具体的工作流程如下。

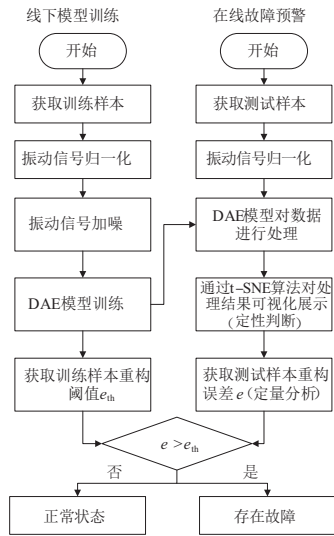


图 1 基于 DAE-t-SNE 算法的故障预警工作流程

1) 线下模型训练

第一步:训练样本的获取。通过传感器,采集获得电梯轿厢系统的振动加速度信号 $\{x_1, x_2, x_3, \dots, x_N\}$ 。

第二步:数据预处理。对采集得到的振动加速度信号 $\{x_1, x_2, x_3, \dots, x_N\}$ 进行归一化处理。本文在此处采用极大极小值归一化,如式(2)所示。

$$x^* = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

通过极大极小值归一化处理,可以将前述获得的训练样本映射至 $[0, 1]$ 之间,从而有利于模型的收敛,并提高其鲁棒性与准确率。由于采集到的振动加速度信号为时间序列数据,本文通过滑动窗口方法,对数据进行重复采用,得到样本 $\{f_1, f_2, f_3, \dots, f_T\}$ 。最后,为防止模型训练时过拟合,对样本按照 8:2 的比例进行训练集和验证集的划分。

第三步:DAE 模型的训练。将上述划分得到的训练集作为输入数据,输入 DAE 模型中,初始化权重矩阵与偏置项,设置学习率、batchsize 等参数。同时将验证集输入模型中,帮助模型在迭代过程中进行参数调整,防止模型过拟合。同时为了节约时间成本,设置迭代早停参数,使得模型在验证集上一定时间内不再出现更优解时提早迭代,以减少无效训练所浪费的时间。

第四步:预警阈值的计算。将训练得到的最优模型重新对训练集进行处理,从而得到训练集的重构误差,设为 $E = \{e_1, e_2, e_3, \dots, e_T\}$ 。由于箱型图分析法能够较好地进行异常值的检测与处理,本文采用箱型图分析法对重构误差集 E 进行检测,取上限值 K^* 为模型的预警阈值 e_{th} ,计算公式如式(3)所示。

$$K^* = Q_3 + 1.5 \cdot Q_{IQR} \quad (3)$$

$$Q_{IQR} = Q_3 - Q_1$$

式中: Q_1 和 Q_3 分别代表第一等份和第三等份的数据; Q_{IQR} 代表四分位距。

2) 在线故障预警

第一步:测试数据的获取。同上文方法,通过传感器获取电梯轿厢系统振动加速度信号,得到测试样本 x 。

第二步:测试数据预处理。对采集得到的测试数据进行归一化处理,同线下训练,采用极大极小值归一化方法,所得结果记为 f' 。

第三步:重构误差的计算。将预处理后的测试数据带入 DAE 模型中,得到测试集的重构误差 e 。将其与预警阈值 e_{th} 进行对比分析,若 $e > e_{th}$,则表明电梯轿厢系统处于退化阶段。

第四步:将 DAE 降维后得到的数据输入 t-SNE 算法当中,使其降至二维或三维供可视化展示。

2 电梯轿厢系统故障预警实验验证与结果分析

为验证本文所提出模型的有效性,本章选取空载电梯作为实验对象,在其运行时测量 x, y, z 轴 3 个方向上的振动加速度。具体实验过程如下。

1) 训练样本获取

以电梯轿厢系统正常运行时的振动加速度信号作为训练集,记作 T 。同时再随机采集 3 组未知健康状况的电梯数据作为测试集,记为 $V = \{v_1, v_2, v_3\}$ 。采用滑动窗口方法,对训练集进行重采样,以扩充训练集大小,提升模型

的性能。

在所进行的实验中,设置采样频率为 200 Hz,采集到共 9657 个数据点。然后,根据上述的滑动窗口方法,对该数据集进行重采样。在多次对比实验后,选择滑动步长为 7,窗口长度为 512。从而最终共得到 1307 个训练样本,每个样本中包含 512 个数据。

2) 数据预处理

首先在训练样本中加入高斯白噪声,并进行极大极小值归一化处理,得到样本 $\{f_1, f_2, f_3, \dots, f_T\}$, $T=1307$ 。然后随机打乱训练样本,按照 8:2 的比例划分训练集与测试集。其中训练集为 $\{f'_1, f'_2, f'_3, \dots, f'_M\}$, 测试集为 $\{f''_1, f''_2, f''_3, \dots, f''_N\}$, 且 $M=1045, N=262$ 。

3) DAE 模型训练

模型超参数的优化是深度学习与机器学习中极为重要的部分,直接影响到模型最终的泛化性能。经过反复试验,确认本文所提出 DAE 模型的最优结构为 512-256-

128-20-128-256-512,其余参数如表 1 所示。通过模型迭代(图 2),可以看出模型在 3 个方向上的验证集重构误差已趋于稳定,判定模型已经收敛。

将训练好的 DAE 模型对样本进行降维,从原来的 512 维的高维特征向量降至 20 维,然后将降维后的数据输入至 t-SNE 中进行可视化展示。重构后得到的 x, y, z 轴 3 个方向上的数据列于表 2 中。

表 1 DAE 模型的具体参数

参数	数值	参数	数值
激活函数	ReLU	Drop-remainder	True
损失函数	MSE	learning rate	0.003
输出层函数	Sigmoid	Batch-size	128
DAE 结构	[512-256-128-20-128-256-512]	Epoch	500
优化算法	Adam	Simple-length	512




图 2 DAE 模型迭代图

表 2 x, y, z 轴 3 个方向上的重构数据

轴方向	特征 1	特征 2	特征 3	...	特征 19	特征 20
x 轴	4.88	-2.33	-0.53	...	-2.15	-0.37
	4.22	-2.71	-0.89	...	-1.90	-0.23
	⋮	⋮	⋮	...	⋮	⋮
	5.06	-3.21	0.17	...	-2.93	-1.10
y 轴	-5.24	-1.82	0.56	...	0.59	-0.91
	-5.14	-1.49	0.62	...	0.60	-0.96
	⋮	⋮	⋮	...	⋮	⋮
	-4.92	-1.70	0.68	...	1.08	-1.30
z 轴	3.26	2.69	-1.27	...	-6.36	6.23
	3.77	0.21	-0.78	...	-3.81	2.53
	⋮	⋮	⋮	...	⋮	⋮
	2.91	0.76	-1.84	...	-3.76	3.02

4) 预警阈值计算

通过上述箱型图方法,计算训练样本在 x, y, z 轴 3 个方向上的重构误差,如图 3 所示。计算结果表明,三者分别集中在 $9 \times 10^{-4}, 6 \times 10^{-3}, 1.2 \times 10^{-3}$ 左右,而与之相对应的预警阈值 K^* 分别为 $k_x = 1.41 \times 10^{-2}, k_y = 8.9 \times 10^{-3}, k_z = 1.68 \times 10^{-3}$ 。

5) 在线故障预警

将测试样本 v 输入至 DAE 模型中,计算测试样本的重构误差。由于机械系统的健康状态可以通过某一段时间的数据来决定,本文特采用滑动窗口方法,对相邻的重构误差进行平均化处理。从而,在第 i 时刻的重构误差 $e_i = \text{average}\{e_{[i-d,i]}\}$ 。式中 d 为滑动窗口大小,此处为 5。图 4 表示了所有测试样本 v 在 x, y, z 轴 3 个方向上样本的重构误差与时间的关系图。




图 3 训练样本重构误差箱线图

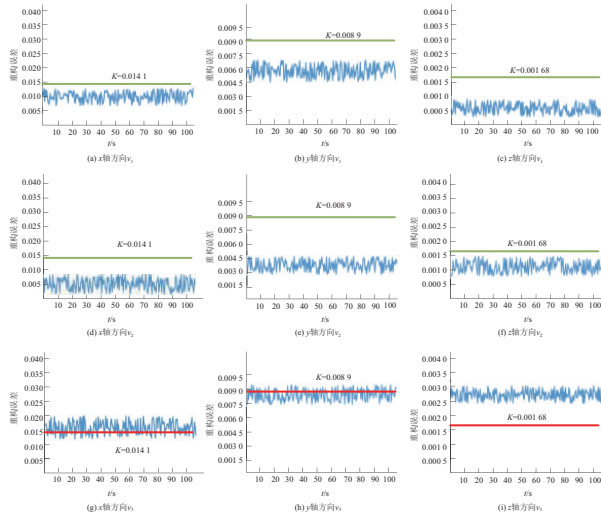


图4 重构误差与时间的变化图

在图4中,每一行代表一个测试样本在 x 、 y 、 z 轴3个方向上的重构误差与时间的变化关系图,分别代表样本 v_1-v_3 。图中波状信号为重构误差,横线代表计算求得的预警阈值。若测试样本的重构误差始终在预警阈值以下,则判定为系统运行正常,处于健康状态;若在某一时刻重构误差超过了该阈值,如图4(g)—图4(i)所示,图中3个方向上的重构误差都部分甚至全部超过了预警阈值,则判定系统进入退化状态。此时电梯维保人员应进行预防性维修,避免电梯进一步恶化至失效阶段,导致严重事故发生。

3 基于t-SNE的可视化分析

对于上一章节的实验结果,本章通过t-SNE算法进行可视化验证。以图4(g)—图4(i)异常数据作为样本,将其在DAE重构后得到的20维数据作为输入,通过t-SNE算法降至二维和三维,进行可视化分析,可以直观地看出测试样本与训练样本之间的异同,从而方便管理人员实时检测电梯轿厢系统的健康状态。测试样本与训练样本的可视化对比结果如图5所示。

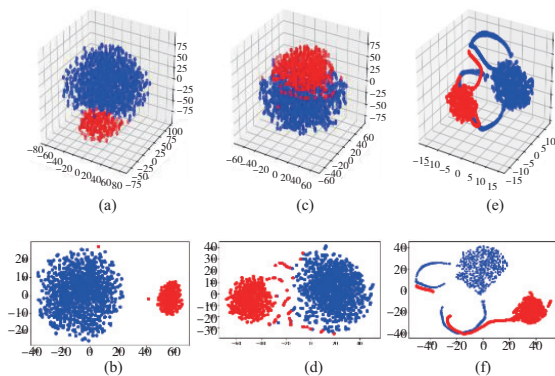


图5 重构误差可视化结果图

分析图5可知,图5(a)和图5(b)、图5(c)和图5(d)、图5(e)和图5(f)分别代表 x 、 y 、 z 轴3个方向上重构误差的可视化结果。其中,不同于 x 、 y 轴方向上的重构误差, z 轴方向上出现了多条曲线,这是因为电梯在运行过程中在 z 轴上会有加速度的变化。该测试样本在3个方向上的分布都明显与训练样本不同,表明该状态下的电梯轿厢系统可能出现了异常。该结果与图中测试集 v_3 重构误差超过预警阈值相一致,验证了本文模型的有效性与准确性。同时该结果也表明,采用DAE重构误差作为电梯轿厢系统的健康指标能够较好地反映电梯运行状态。同时,在实际的应用当中,基于t-SNE算法的可视化结果能够作为电梯轿厢系统故障预警的重要检验方法,可以对DAE模型做出的在线预警结果进行实时验证,以此保障模型的准确率与有效性。

4 结语

本文提出了一种电梯轿厢系统在线故障预警方法,首先基于DAE-t-SNE算法,以电梯轿厢振动加速度信号作为输入,通过无监督学习方法将原始高维数据映射至低维空间。然后通过箱型图方法,在训练样本中计算得到预警阈值,将测试样本的重构误差与预警阈值进行对比分析,判断系统处于健康或是异常状态。最后通过t-SNE算法将结果实时可视化,从而方便电梯维保人员及时进行预防性维修,以防止带来更大损失。

参考文献:

- [1] 李永亮,李俊良. 改革开放以来我国电梯检验制度发展历程[J]. 中国电梯,2020,31(20):20-26.
- [2] 杨华江. 电梯安全隐患的分析及对策探讨[J]. 科技信息,2009(11):440,400.
- [3] MISHRA K M, HUHTALA K J. Fault Detection of elevator systems using multilayer perceptron neural network[C]//2019 24th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA). IEEE, 2019:904-909.
- [4] OLALERE I O, DEWA M, NLEYA B. Remote condition monitoring of elevator's vibration and acoustics parameters for optimised maintenance using IoT technology[C]//2018 IEEE Canadian Conference on Electrical & Computer Engineering. Quebec, QC, Canada: IEEE, 2018:1-4.
- [5] TRCKA N, LOVETT T E, SUDI S, et al. Elevator health monitoring system;US11286133[P]. 2022-03-29.
- [6] 王林林. 电梯故障预测及远程监控平台的研究与实现[D]. 沈阳:东北大学,2013.
- [7] 邹鑫,何文雪,牛杰. 基于SIMATIC S7-1500PLC的电梯监控系统设计[J]. 机械制造与自动化,2022,51(2):210-213.

收稿日期:2022-10-13