

DOI:10.19651/j.cnki.emt.2211608

基于 CNN-LSTM 故障诊断的自动扶梯 监测软件设计*

谭博韬¹ 黄民¹ 刘跃¹ 安琪²

(1.北京信息科技大学机电工程学院 北京 100192; 2.清华大学机械工程系 北京 100084)

摘要: 自动扶梯的数量在我国呈逐年递增的趋势。定期检测、监督抽查等常见方法通常难以检验自动扶梯内部的潜在故障。提出了一种改进的 CNN-LSTM 神经网络故障诊断方法,并据此采用 LabVIEW 设计了自动扶梯监测与故障诊断软件。基于 CNN-LSTM 神经网络算法,提出将数据浅层特征与深层特征进行融合的改进方法,以提高故障诊断准确率。利用凯斯西储大学数据对提出的故障诊断方法进行实验。结果表明,该故障诊断方法快速有效,针对变工况的故障诊断准确率达到 99.4%。基于此,采用 LabVIEW 设计了自动扶梯监测与故障诊断软件。在自动扶梯关键部件安装多个振动传感器,利用监测软件进行数据采集、数据显示和数据存储。在积累大量工况数据后,可实现典型故障的诊断。

关键词: LabVIEW;故障诊断;神经网络;自动扶梯

中图分类号: TP277;TH133.33 **文献标识码:** A **国家标准学科分类代码:** 460

Software design of escalator monitoring based on CNN-LSTM fault diagnosis method

Tan Botao¹ Huang Min¹ Liu Yue¹ An Qi²

(1. School of Mechanical Electrical Engineering, Beijing Information Science & Technology University, Beijing 100192, China;

2. Department of Mechanical Engineering, Tsinghua University, Beijing 100084, China)

Abstract: The number of escalators in China has been increasing in recent years. However, regular inspection, supervision, spot check, and other common methods are hardly to inspect the potential failure inside the escalator. An improved fault diagnosis method based on CNN-LSTM neural network is proposed in this paper. Besides, a software for escalator monitoring and fault diagnosis is designed with LabVIEW. Furthermore, an improved method to fuse the shallow and deep data features to improve the accuracy of fault diagnosis based on the CNN-LSTM neural network algorithm is proposed in this paper. The fault diagnosis method proposed is tested with the data of Case Western Reserve University. The results show that the method is efficient and effective, and the fault diagnosis accuracy is 99.4%. Moreover, the software for escalator monitoring and fault diagnosis is designed. there vibration sensors are set on the key parts of the escalator, and monitoring software is used for data acquisition, data display and data storage. After collecting a large amount of operating condition data, the of typical faults can be diagnosed.

Keywords: LabVIEW; fault diagnosis; neural network; escalator

0 引言

自动扶梯已经成为现代人生活中不可或缺的一大工具,其运行的关键在于乘客的安全性,但受设备、使用环境及运营管理等多种因素影响,自动扶梯事故频发。为了预防事故的发生,需对自动扶梯的运行状况进行监视以及故

障诊断。常见的扶梯故障如电机转子动不平衡、定子偏心;联轴器注销磨损,轴承润滑不良、内外圈磨损;减速器齿轮啮齿不良、齿轮断齿等^[1]。由于扶梯中存在大量振动信号,所以故障大部分都会以振动幅值升高等指标而显现。

随着科学技术的发展,故障诊断领域开始逐步向智能化方向发展,国内外学者通过使用 LabVIEW 进行故障诊

收稿日期:2022-10-06

* 基金项目:国家重点研发计划课题(2020YFB1713205)项目资助

断的设计。LabVIEW 是一款强力的测试工具,采用直观的图形编程方式,且能够与 MATLAB 以及 Python 进行直接交互,可以轻松地通过判断图形实现故障诊断。

唐奕等^[2]使用 LabVIEW 实现了振动信号分析流程和传统的信号分析方法,能够对振动信号进行处理并能够分辨出轴承故障的特征频率。曹仕骏等^[3]根据滚动轴承的故障形成机理和故障信号的振动特征,提出了基于频谱包络监测的改进自适应经验傅里叶分解。张雅晖等^[4]为提高异步电机转子故障诊断的可靠性,介绍了一种基于小波包能量分析和信号融合的异步电机转子故障诊断方法。Jia 等^[5]为及时处理海量故障数据,自动提供准确的诊断结果,对旋转机械的智能故障诊断进行了大量研究,提出了能够自适应地从实测信号中挖掘出可用的故障特征的方法,而且此方法具有优越的诊断精度。陈坤等^[6]融合定位单元与布拉格波长,优化故障采集与处理能力,使用神经网络算法计算故障诊断幅值,上传机电设备故障数据,引入 LabVIEW 以图形化的方式实现对机电设备的故障诊断。上述方法大部分采用传统信号处理的方法进行基于 LabVIEW 的故障诊断,应用时更多依赖于工程师经验分析故障,不能直接做到故障诊断并分类。

神经网络对比传统方法具有自主学习、并行处理的能力,在解决非线性、高不确定度等问题具有独特优势,在复杂电子设备故障诊断领域得到了广泛的应用^[7]。目前反向传播(back-propagation, BP)神经网络、小波神经网络、模糊神经网络、孪生神经网络等在故障诊断中得到了广泛的应用,刘长良等^[8]提出了基于变分模态分解和奇异值分解提取特征,采用标准模糊 C 均值聚类进行故障识别的方法。李恒等^[9]提出了基于短时傅里叶变换和卷积神经网络的故障诊断方法。朱奇先等^[10]提出了一种基于残差神经网络的滚动轴承故障诊断方法。上述方法虽然通过神经网络实现了直接故障诊断并分类,但无法做到易于实地运行、直观显示运行过程等操作。

You 等^[11]提出了一种基于高斯混合模型的故障诊断方法,该方法考虑了运行过程的多模性。Jia 等^[12]提出了一种综合动态信息的多属性决策方法,并给出了最佳故障排除顺序,以提高故障排除的效率。Zheng 等^[13]提出了一种基于高斯混合模型的故障诊断方法,该方法考虑了运行过程的多模性。国外对于自动扶梯的故障诊断方面的研究主要集中在传统故障诊断方法与机器学习相结合方面,但是无法实现监测及故障诊断一体化。

本文从数据处理直观便捷性与神经网络故障诊断优势综合考虑,提出了基于 CNN-LSTM 故障诊断方法,并据此采用 LabVIEW 设计了自动扶梯监测与故障诊断软件。首先,设计了改进 CNN-LSTM 神经网络并利用公开数据集进行网络训练以及测试;其次,通过实验将该方法与其他故障诊断方法进行比对,实验结果表明,提出的故障诊断方法性能与传统诊断方法相比,准确率更高,且稳定性更好;再

次,针对自动扶梯的数据采集、分析及处理系统设计 LabVIEW;最后,将改进的 CNN-LSTM 网络与 LabVIEW 结合,最终实现通过 LabVIEW 设计界面直观显示的数据采集、分析、处理及故障诊断过程。

1 CNN-LSTM 神经网络

1.1 CNN 神经网络

卷积神经网络(convolutional neural network, CNN)最早由 Yann Lecun 于 20 世纪 80 年代受到生物神经学的启发而提出的一种前馈神经网络结构模型,主要是由卷积层、池化层、全连接层 3 个层级组成。卷积层是对输入的局部数据与卷积核进行卷积操作,计算公式如式(1)所示^[14]。

$$A_i = \text{ReLU}\left(\sum_{m=0}^2 \sum_{n=0}^2 \omega_{m,n} x_{i+m,n} + f\right) \quad (1)$$

式中: A_i 为输出向量的第 i 位; ω 为卷积核; x 为输入; f 为偏置项; ReLU 为激活函数。

池化层的作用是保持重要信息的同时通过压缩参数的数量实现降维,从而减小模型过拟合,一般采用平均池化或者最大池化。

全连接层将池化层计算得到的特征空间映射成样本标记空间。在输出层使用 Softmax 激活函数将特征表示整合成一个值,输出各分类的概率分布然后进行分类。

1.2 LSTM 神经网络

长短期记忆(long short-term memory, LSTM)神经网络是在循环神经网络(recurrent neural network, RNN)的基础上改进的一种神经网络,对于时序数据处理具有优秀的表现,而且弥补了 RNN 不能处理长序列数据的不足^[15]。LSTM 通过增加输入门、输出门与遗忘门控制信息,单个 LSTM 神经元如图 1 所示,其中各量可由式(2)~(7)计算得到^[16]。

$$f_i = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (5)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = O_t \times \tanh(C_t) \quad (7)$$

式中: f_t 为遗忘门的输出信号,表示记忆单元 C 的遗忘比例; i_t 为输出门的输出信号,表示当前输入信息到记忆单元中的比例; O_t 为输出门的输出信号,表示记忆单元的信息输出到当前状态 s 中的比例。

1.3 改进的 CNN-LSTM 网络

由图 2 和表 1 所示,本文提出 CNN-LSTM 网络的改进方法。首先,针对经小波消噪的振动加速度信号作滑动窗口及归一化处理,其目的是扩充数据集及快速收敛数据;其次,对处理后的数据并行一维 CNN 卷积,提取浅层特征与深层特征;最后,融合浅层与深层特征作为 LSTM 网络的输入,提取长距离特征,经变换输入全连接层进行预测故障类别。

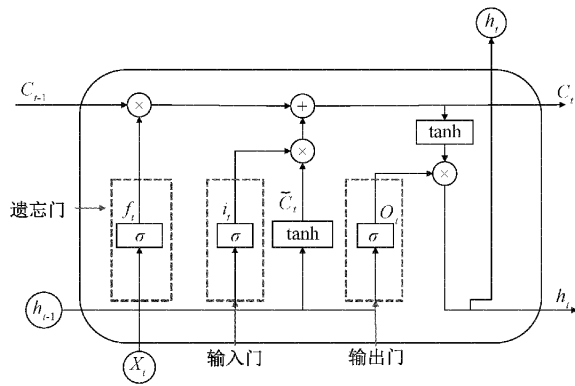


图 1 单个神经元结构

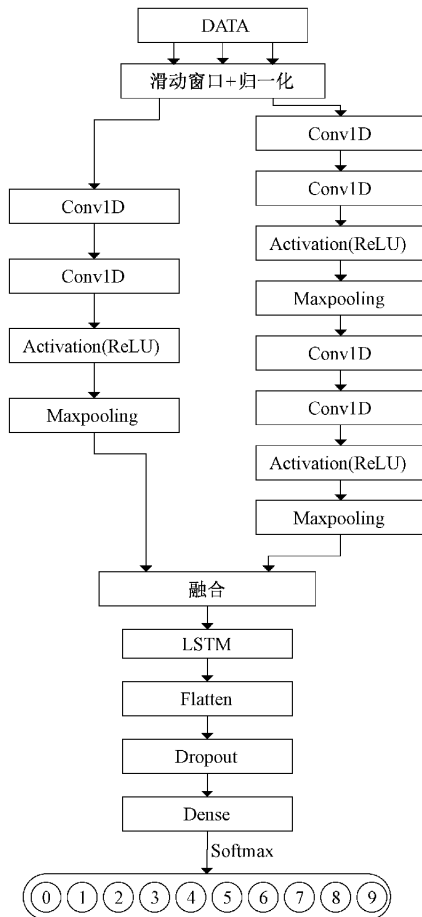


图 2 改进 CNN-LSTM 网络结构

本文在每个卷积层后应用激活层,选择整流线性单元(ReLU),目的是引入非线性特征加速卷积收敛。

池化层选用最大池化,目的是防止过拟合、降低了上层的计算复杂度、减少参数量、去除冗余信息、对特征进行压缩以及减少内存消耗。

优化器选择 Adam,采用 ReduceLROnPlateau 方法进行学习率的自适应调整。

表 1 改进 CNN-LSTM 模型部分参数

网络层	卷积核尺寸/步长	卷积核数量	网络层输出
卷积层 1	[16×1]/[1×1]	50	235×1
卷积层 2	[8×1]/[1×1]	40	228×1
池化层 1	[2×1]/—	40	114×1
卷积层 3	[6×1]/[1×1]	30	109×1
卷积层 4	[4×1]/[1×1]	30	107×1
池化层 2	[2×1]/—	30	53×1
卷积层 5	[16×1]/[2×1]	50	118×1
卷积层 6	[12×1]/[1×1]	30	106×1
池化层 3	[2×1]/—	30	53×1
融合	—	30	53×1
LSTM	—	—	60
Dense	—	—	9

2 实验与分析

2.1 实验平台

本文实验平台为笔记本电脑,其配置为 AMD R7-4800H CPU,6GB-RTX2060GPU,16 GB 内存,神经网络构建采用 Tensorflow2.9.0 框架。

2.2 数据来源

本文所用实验数据来源于美国凯斯西储大学(CWRU)的轴承实验平台^[17],此平台包括一个 2 马力的电机,一个振动加速度传感器以及电子控制设备,支承电机轴为测试轴承。选取模拟现实中的点蚀等轴承故障,振动信号的采样频率为 48 kHz。

由表 2 和 3 可知,实验样本为 4 种转速(工况)下的驱动端滚动轴承的 10 种不同故障状态数据作为训练数据,经过计算得出,转轴每转一圈传感器采集的点数应约为 401 个点,将各工况下每 5 个周期的点数设为样本长度,即 2 000 个点,并按照 9 : 1 的比例将 2 400 个样本分成训练集以及验证集。

表 2 工况分类

工况代号	电机转速/(r·min ⁻¹)
0HP	1 797
1HP	1 772
2HP	1 750
3HP	1 730

2.3 模型训练结果

实验基于 Tensorflow2.9.0 框架下进行 CNN-LSTM 网络模型的训练,由于信号处理的特殊性,扶梯实际运行需要对网络模型随时更新,故采用迁移学习策略进行训练。主干网络的初始权重通过 0 工况下故障数据中进行训练获得。加载预训练权重后,再分别对不同工况进行训练。

表 3 滚动轴承故障数据集分类

标签	电机转速/ (r·min ⁻¹)	轴承状态
0	1 797	正常
1	1 797	直径 0.017 78 cm 轴承滚动物故障
2	1 797	直径 0.017 78 cm 轴承内圈故障
3	1 797	直径 0.017 78 cm 轴承外圈故障
4	1 797	直径 0.035 56 cm 轴承滚动物故障
5	1 797	直径 0.035 56 cm 轴承内圈故障
6	1 797	直径 0.035 56 cm 轴承外圈故障
7	1 797	直径 0.053 34 cm 轴承滚动物故障
8	1 797	直径 0.053 34 cm 轴承内圈故障
9	1 797	直径 0.053 34 cm 轴承外圈故障

由图 3 可知,模型在训练 20 次之后便能收敛并保持稳定,其在不同工况下的训练、验证准确率能达到 99.5% 以上,且训练、验证损失值较小。

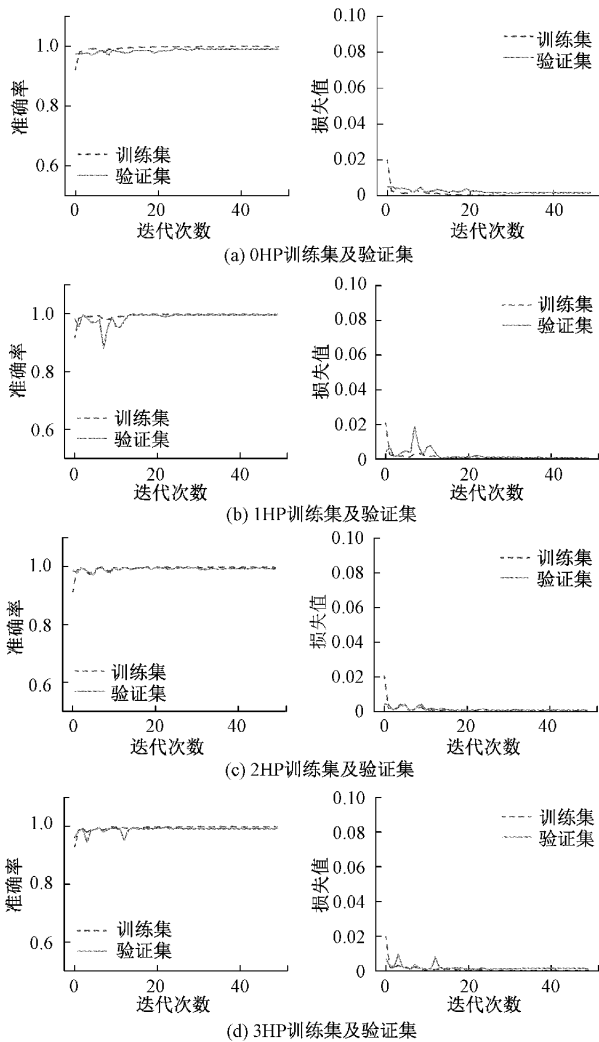


图 3 各工况训练准确率

2.4 模型测试结果

为验证上述模型的可靠性,采用混合工况下训练完成的 CNN-LSTM 模型对于变工况下数据随机进行测试,并与支持向量机(super vector machine, SVM)、CNN、LSTM 模型进行对比,综合评估改进的 CNN-LSTM 模型在变工况情况下的表现性能。本文选择混淆矩阵的准确率作为评价标准,即对给定的测试数据集,分类模型中所有预测正确的样本数除以总观测值的样本数。准确率越高,模型预测分类效果越好,准确率计算公式如式(8)所示。

$$ACC = \frac{(TP + TN)}{(TP + TN + FP + FN)} \times 100\% \quad (8)$$

由表 4、5 和图 4 可知,改进 CNN-LSTM 神经网络相较于传统方法检测准确率在变工况故障类别的分类情况下得到了大幅度的提升,运行过程更加稳定,收敛速度更快,能够快速完成实现故障识别分类任务。

表 4 混淆矩阵分类结果

真实情况	预测结果	
	正例	反例
正例	真正例(TP)	假反例(FN)
反例	假正例(FP)	真反例(TN)

表 5 4 种算法在测试数据集上准确率

类别	准确率			
	改进 CNN-LSTM	SVM	CNN	LSTM
0	1.000 0	0.989 2	0.985 2	0.953 7
1	0.994 5	0.993 1	0.979 3	0.682 5
2	0.994 5	0.687 5	0.963 1	0.848 9
3	0.977 8	0.674 4	0.958 2	0.968 6
4	1.000 0	0.163 7	0.972 2	0.915 2
5	1.000 0	0.187 5	0.989 4	0.874 5
6	1.000 0	0.987 4	0.953 7	0.869 3
7	1.000 0	0.103 2	0.967 4	0.957 5
8	0.972 1	0.837 8	0.956 5	0.856 1
9	1.000 0	0.127 1	0.965 2	0.933 4

3 监测软件设计

3.1 总体设计

LabVIEW 端的设计主要集中在振动加速度、温度数据的采集、分析、处理、数据库存储以及结合 CNN-LSTM 神经网络进行故障诊断,系统总体结构如图 5 所示。

软件设计界面如图 6 所示,主要分为振动、温度、设备自动化系统(building automation system, BAS)数据、设置、故障诊断系统 5 个子界面。其中,振动子界面分别采集来自 12 个不同自动扶梯位置振动加速度传感器数据,并显示




图 4 模型预测混淆矩阵




图 5 LabVIEW 系统结构

其时域及频域图;温度子界面显示 8 个不同自动扶梯位置的温度信号;BAS 数据子界面通过建立与自动扶梯的串口通信,显示自动扶梯运行状态,如钥匙启动、扶梯上下行等;故障诊断系统子界面可以利用神经网络模型进行在线诊断或离线更新模型。软件右侧分别为振动各通道的烈度均方根值以及温度各通道的温度数值。

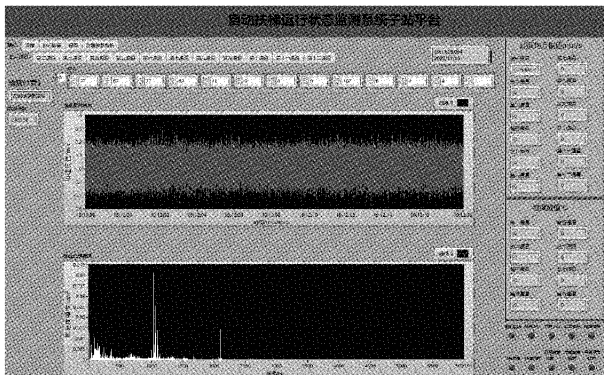


图 6 LabVIEW 设计界面

3.2 数据采集及传输

数据采集部分为监测系统中重要的一部分,它连接采集卡以及上层软件,在整个系统中为连接软硬件起到承上启下的作用。本文采用压电式加速度、温度传感器,分别安放在自动扶梯的电机、齿轮箱、主机链轮、主驱动轮、扶手带、涨紧轮等部位。

本文采用的数据传输协议为 TCP/IP,通过设置 IP 地

址以及通道号与自动扶梯端的采集卡建立通信,实现各类数据的传输。

3.3 数据处理与存储

系统主要处理振动加速度时间序列数据,绘制振动加速度数据时域图,通过 LabVIEW 频谱测量组件将时间序列数据经快速傅里叶变换后得到频谱图。

采用小波去噪的方法消除噪声,积分模式采用一次积分,并设置滤波器截止频率,获得振动烈度信号,指物体振动速度的均方根值,即振动速度的有效值,反映了包含各次谐波能量的总振动能量的大小,其表达式如式(9)所示^[18]。

$$V_{rms} = \sqrt{\frac{1}{T} \int_0^T v^2(t) dt} \quad (9)$$

式中: T 为所测信号的长度(s); $v(t)$ 为物体的振动速度(mm/s)。

搭建方式选择 linear 方式进行时间序列拟合,并消除烈度信号中的趋势项。数据处理流程如图 7 所示。

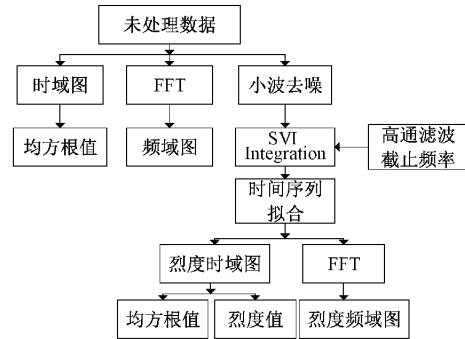


图 7 振动加速度数据处理流程

本文通过对安装在自动扶梯各点位的传感器数据进行读取,然后进行数据分析与处理,并将扶梯运行状态数据存储。首先,将经过处理的振动加速度数据进行数据类型转换,将数组转换成字符串;其次将时间、通道号以及数据含义融入数据;最后利用 Microsoft ADO 以及 SQL 语言完成对 MySQL 数据库实现实时访问记录存储以便输入神经网络进行预测,导入数据库流程如图 8 所示。

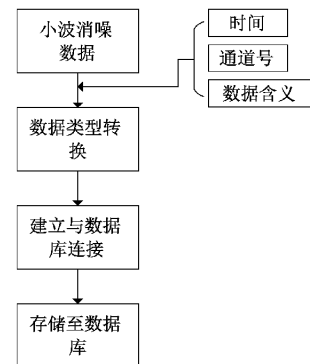


图 8 LabVIEW 连接数据库流程

3.4 故障诊断流程

运用 Pycharm 平台搭建神经网络更加方便快捷,且

LabVIEW 提供了命令行语句,可直接调用 Python 文件。本文模拟了通过调用扶梯工作时的振动加速度数据,通过训练好的网络模型进行故障诊断,并显示出故障类型,若出现故障类别则会触发报警机制。故障诊断流程如图 9 所示。

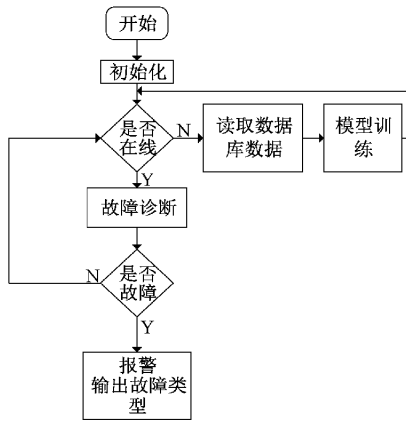


图 9 LabVIEW 故障诊断流程

本文将 CNN 与 LTSM 各自的优势结合,针对自动扶梯可能遇到的轴承故障进行故障诊断以及进行预警。使用双层一维卷积(1D-CNN)提取数据特征,结合 LSTM 处理时序特征进而预测输入的时间序列数据,将预测结果通过 LabVIEW 直观显示出来。若发生故障,故障诊断子界面波形图将会显示故障类型(0~9 代表滚动轴承的各类故障,具体类型如表 3),且软件右下角中故障报警灯将会亮起。

3.5 故障诊断测试

本文故障诊断测试实验将西储大学轴承正常数据通过 TCP/IP 与上位机建立通讯,模拟故障诊断环境。

如图 10 可知,LabVIEW 智能故障诊断系统是整个软件中最主要的部分,分为在线和离线两种模式,现阶段主要应用于滚动轴承的故障诊断。离线模式中,通过点击“训练模型”按钮,即可调用数据库中扶梯运行数据,系统自动根据采样频率进行数据预处理,然后训练网络模型。在线模式中,通过点击“开始/暂停预测”会自动调用训练完成的模




图 10 LabVIEW 故障诊断界面

型对扶梯运行中的数据进行实时故障诊断。通过实验证明,软件初步实现了在线诊断以及离线模型训练功能,后续将通过现场测试进一步验证其在自动扶梯上电机、减速器、滚动轴承的表现。

4 结 论

本文提出了改进 CNN-LSTM 神经网络故障诊断方法,对小波降噪后的数据进行浅层以及深层特征提取融合,再经过 LSTM 网络以及全连接层进行故障分类。通过 LabVIEW 设计了自动扶梯监测及故障诊断软件,该软件具备自动扶梯各类信号的采集、分析与处理以及故障诊断的功能。该方法首先可以实时地对采集到的多种信号进行时域、频域的监测;其次,及时对采集数据进行小波消噪等操作计算烈度值;最后,利用小波消噪后的数据进行自动扶梯轴承的故障诊断。对于自动扶梯的状态监测及故障诊断应用提供了一定的参考价值。

实验数据表明,本文提出的方法快速有效,识别准确度可以达到 99.4%。为后续现场地对自动扶梯的实时状态监测及故障诊断提供了基础。现阶段已经应用于地铁自动扶梯的状态监测及故障诊断系统,以后将对数据进行进一步的分析和故障诊断研究。

参考文献

- [1] 梁敏健,彭晓军.基于 LabVIEW 的自动扶梯机械振动数据采集系统的设计与实现[J].工业仪表与自动化装置,2021(2):54-58.
- [2] 唐奕,李祺,王文娟,等.基于 LabVIEW 的振动信号分析系统设计[J].计算机测量与控制,2016,24(6):218-222.
- [3] 曹仕骏,郑近德,潘海洋,等.基于改进自适应经验傅里叶分解的滚动轴承故障诊断方法[J].振动与冲击,2022,41(15):287-299.
- [4] 张雅晖,杨凯,杨帆.基于小波包能量分析和信号融合的异步电机转子故障诊断[J/OL].电测与仪表:1-9 [2022-11-15]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20211029.1754.006.html>.
- [5] JIA F, LEI Y G, LIN J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data [J]. Mechanical Systems and Signal Processing, 2016(S72-73): 303-315.
- [6] 陈坤,朱森.基于 LabVIEW 的机电设备故障诊断系统设计[J].电子技术与软件工程,2020(22):201-202.
- [7] 单显明,李长伟,张忠传.基于神经网络的复杂电子设备故障诊断系统的设计[J].电子测量技术,2022,45(11):52-56.
- [8] 刘长良,武英杰,甄成刚.基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J].中国电机工程学

- 报,2015,35(13):3358-3365.
- [9] 李恒,张氢,秦仙蓉,等.基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法[J].振动与冲击,2018,37(19):124-131.
- [10] 朱奇先,梁浩鹏,赵小强,等.基于残差神经网络的滚动轴承故障诊断方法[J].兰州理工大学学报,2022,48(3):86-93.
- [11] YOU F, WANG D, LI G, et al. Fault diagnosis method of escalator step system based on vibration signal analysis [J]. Int. J. Control Autom. Syst., 2022(20): 3222-3232.
- [12] JIA M X, PAN ZH H. A fast diagnosis method of escalator reversal faults based on dynamic information and multiattribute decision-making [J]. Journal of Mathematics,2021, DOI:10.1155/2021/6294869.
- [13] ZHENG Q, ZHAO C. Gaussian mixture model based fault diagnosis for elevator overspeed and automatic reset[J]. 2020 39th Chinese Control Conference(CCC), 2020; 4210-4215.
- [14] 王成瀚,苏沛源,张臣宏,等.基于深度 CNN-LSTM 神经网络的加工过程实时异常监测模型[J].机械设计与研究,2021,37(6):128-132,140.
- [15] YU L, QU J, GAO F, et al. A novel hierarchical algorithm for bearing fault diagnosis based on stacked LSTM[J]. Shock and Vibration,2019, DOI:10.1155/2019/2756284.
- [16] 曹正志,叶春明.考虑转动周期的轴承剩余使用寿命预测[J/OL].计算机集成制造系统:1-14[2022-11-15].
<http://kns.cnki.net/kcms/detail/11.5946.TP.20210702.1723.008.html>.
- [17] WADE A, SMITH, ROBERT B, et al. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study [J]. Mechanical Systems and Signal Processing, 2015, 64-65: 100-131.
- [18] 王尉军,郭举富,殷慧,等.应用于光缆外破监测的雨水信号识别[J].激光与红外,2022,52(7):1042-1047.

作者简介

谭博韬,硕士研究生,主要研究方向为设备状态监测与故障诊断等。

E-mail:t403905443@163.com

黄民,教授,博士生导师,主要研究方向为机器人技术、故障诊断等。

E-mail:huangmin@bistu.edu.cn