

DOI:10.19651/j.cnki.emt.2314985

L1 正则化和 BiGRU 模型的轴承状态预测研究

孙柳萌 杨永杰 张宁涛

(南通大学信息与科学技术学院 南通 226019)

摘要: 针对轴承健康状态无法直观监测以及预测问题,设计了一种 L1 正则化的双向门控循环单元模型和 Bray-Curtis 距离共同构建的健康指标,该指标能够直观表示轴承的健康状态。首先运用 L1 正则化对现阶段轴承振动数据提取有效特征作为退化特征,振动数据第一个时间窗的特征作为健康特征,然后计算轴承退化特征和健康特征之间的 Bray-Curtis 距离,构建轴承的 HI。通过云监控平台实时监测轴承的健康状态并采用 BiGRU 模型预测未来的健康状态,一旦轴承的 HI 超过变化率阈值,平台即刻报警,实现了轴承的健康状态预测。将本模型与双向长短期记忆网络以及双向长短期记忆网络-注意力机制模型作比较,结果表明本模型的准确率为 97.52%,远高于另外两种模型,且模型更加轻量化,体现出本方法的实用性。

关键词: 双向门控循环单元;特征提取;健康指标;状态监测

中图分类号: TP277 **文献标识码:** B **国家标准学科分类代码:** 510.40

Research on bearing condition prediction based on L1 regularization and BiGRU model

Sun Liumeng Yang Yongjie Zhang Ningtao

(School of Information Science and Technology, Nantong University, Nantong 226019, China)

Abstract: Aiming at the problem that the health status of bearings cannot be directly monitored and predicted, we designed a L1 regularized bidirectional gating recurrent unit model and a health index constructed by Bray Curtis distance, which can directly represent the health status of bearings. Firstly, L1 regularization is used to extract effective features from the current bearing vibration data as degradation features, and the features of the first time window of the vibration data as health features. Then, the Bray Curtis distance between the bearing degradation features and health features is calculated to construct the HI of the bearing. The health status of the bearing is monitored in real time through the cloud monitoring platform, and the future health status is predicted using the BiGRU model. Once the HI of the bearing exceeds the change rate threshold, the platform will alarm immediately, and the health status of the bearing is predicted. The model is compared with bidirectional long short term memory and bidirectional long short term memory with attention models. The results show that the accuracy of this model is 97.52%, much higher than the other two models, and the model is more lightweight, which reflects the practicability of this method.

Keywords: BiGRU; feature extraction; health index; condition monitoring

0 引言

轴承是旋转机械中的关键机械部件,在恶劣的环境和恶劣的工作条件下,其中可能会出现轴承损伤,导致机器故障^[1],会影响整个设备体系。对于轴承的健康监测管理,一个核心任务就是建立一种轴承的健康指数(health index, HI)来表示当前轴承的健康状态,赵志宏等^[2]提出了一种无监督的轴承健康指标及早期故障检测方法,设计了提取

轴承状态特征的深度可分离卷积自编码器,基于健康指标结合 Savitzky-Golay 滤波来判断轴承故障,汤武初等^[3]基于特征融合和 ResNet 的滚动轴承故障诊断,利用变分模态分解和经验模态分解的方法分解了原始信号,根据方差贡献率和相关系数筛选确定了有效分量,对筛选出的有效分量进行了特征融合,组成数据集输入到 ResNet 模型中,并进行了故障诊断,刘湘楠等^[4]提出一种奇异值分解(singular value decomposition, SVD)差分谱与 S 变换相结

合的微弱冲击特征提取方法,提取信号中的微弱冲击特征信息,来判断轴承故障,崔玲丽等^[6]采用高斯函数拟合退化数据并提出参数相似性原则,构建双指数函数模型,模拟退化信号,并验证仿真数据扩充参考字典集的有效性,实现剩余使用寿命预测,黄庆卿等^[6]将采集的振动信号进行快速傅里叶变换得到频域信号作为模型的输入,利用一维卷积将多个源域与目标域数据映射到一个公共的特征空间,采用局部最大均值差异进行领域自适应,实现轴承寿命预测。薛林等^[7]针对滚动轴承振动信号的周期性特点,利用 Transformer 类模型强大的多维特征提取能力挖掘输入特征与 RUL 之间的复杂映射关系来预测轴承寿命。

以上研究尽管效果都不错但却存在以下问题:1) 容易造成梯度爆炸和梯度消失的问题;2) 在强噪声环境下振动信号特征难以提取;3) 网络结构复杂,学习困难,泛用性不广。为解决上述问题并实现轴承健康监测和预测,本文通过设计一种基于 L1 正则化的双向门控循环单元模型 (bidirectional gating recurrent unit, BiGRU),并结合 Bray-Curtis 距离构建健康指标,实现了对轴承健康状态的直观监测,通过实时监测平台,结合本模型对未来健康状态的预测。首先对振动信号序列提取轴承历史阶段的时域特征,随着轴承的运行,损伤不断积累,健康程度逐渐降低。然后在线阶段利用当前时间的退化特征输入进模型当中,并预测未来的退化特征,通过计算与轴承初始时刻的健康状态特征之间的 Bray-Curtis 距离从而得到健康指标,设定 HI 的变化率异常阈值,当发生机器的 HI 的变化率超出阈值,云平台会实时报警,从而可以及时排除故障,避免机器损坏带来的重大经济损失,提高工业设备的可靠性和寿命,降低维护成本,提高生产效益。

1 系统介绍

本文提出基于 NUC980 的机器健康监测系统的整体架构,如图 1,包括以下几个部分:工业振动传感器、PLC、NUC980DK61Y、EC20 通信模块、MQTT 服务器和监控终端。本设计硬件部分选用的是 ARM9 的微处理器 NUC980DK61Y,以它为核心,通过以太网接口以及 485 接口对 PLC 做数据采集,硬件上嵌入的通信模块 EC20,是一款支持 PCI-E 接口的 LTE 模块,用于实现 NUC980 和 MQTT 服务器的数据传输。软件上通过 MQTT 协议上传至云端服务器,存储数据,运用 Python 对采集到的振动数据提取分析,通过神经网络模型预测未来轴承的健康状态,并建立一个云监控平台监测轴承健康状态信息^[8]。

2 硬件设计

系统硬件由振动传感器、PLC、数据采集模块、云端服务器和 PC 机组成。本文主要设计了数据采集模块,该模块主要由数据采集端和微处理器控制端组成,硬件设计图如图 2 所示。

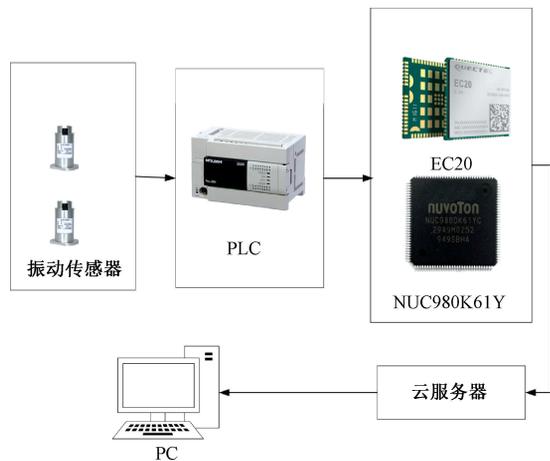


图 1 系统架构图

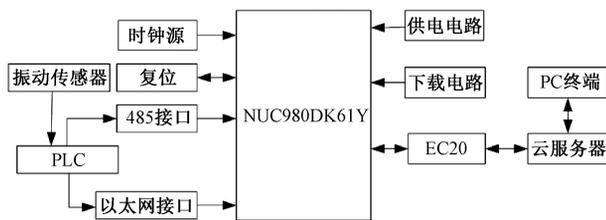


图 2 数据采集模块设计电路

数据采集端主要是若干个连接轴承的振动传感器,多个传感器连接到同一个 PLC,将传感器的数据保存在 PLC 中;微处理器控制端由 NUC980 芯片、复位电路、下载电路、供电电路、时钟源和无线通信电路组成,无线通信电路由 EC20 模组组成,搭配 MQTT 库能够方便与服务器进行数据传输和交换,最后将数据通过云端服务器上传到 PC 终端,实现远程监控。

3 软件设计

3.1 L1 正则化介绍

为了提取振动信号中有较高信息量的特征,引入 L1 正则化模型^[9]。L1 正则化是指在损失函数中添加 L1 范数惩罚项,通过最小化目标函数和特征的 L1 范数之和来实现特征选择。

首先,需要根据数据集和任务的具体情况,将特征和对应的目标变量进行准备。然后使用 L1 正则化的线性模型,比如 Lasso 回归模型来拟合训练数据。这些模型在损失函数中加入了 L1 正则化项。通过训练模型,L1 正则化会对特征的权重进行调整,使得一些特征的权重变为 0。这是因为 L1 正则化通过最小化目标函数和特征的 L1 范数之和,促使一些特征的权重趋向于稀疏化。根据模型中特征的权重情况,可以筛选出权重不为 0 的特征。这些非零权重特征可以被认为对目标变量具有较大的影响力,即所需要的特征。

3.2 BiGRU 模型介绍

BiGRU 是一种基于循环神经网络 (recurrent neural

network, RNN) 的模型结构, 用于时间序列数据的建模和学习。它结合了双向性和门控机制, 能够更好地捕捉序列数据中的长期依赖关系。本文所使用的 BiGRU 模型减少了参数, 将隐藏状态与单元状态相结合, 使用两个独特的门, 称为复位门和更新门。单向 GRU 模型^[10] 只能获得前向时间的信息, 但在轴承健康状态的预测任务中, 该模型需要充分学习振动信号的前后信息并提取输入信息的深层特征。BiGRU 模型^[11] 由两个方向相反的单向 GRU 组成, 前向 GRU 捕获前一个信息, 反向 GRU 捕获下一个信息。具有相反方向的两个 GRU 共同确定当前位置的输出。更新门输出 z 的计算方法如式(1)。

$$z(t) = \sigma(V_z X(t) + W_z h(t-1)) \quad (1)$$

其中, $X(t)$ 是当前输入单元, V_z 和 W_z 是权重, $h(t-1)$ 是存储的上一个单元的数据, 能存储特征信息, σ 是激活函数, 范围是 $[0, 1]$ 。所有这些参数使网络能够调用过去的的数据。复位栅极 r 用式(2)表示。

$$r(t) = \sigma(V_r X(t) + W_r h(t-1)) \quad (2)$$

以类似于更新门的方式, 将总和传递给激活函数。当引入新的内存内容时, 复位门负责存储过去的相关信息, 计算如式(3)。

$$c(t) = \tanh(VX(t) + r(t) \odot Wh(t-1)) \quad (3)$$

其中, \tanh 是非线性激活函数, 复位门 r 和 $Wh(t-1)$ 确定要丢弃的信息。最后, $h(t)$ 存储当前单元的信息并将其传输到网络。 $h(t)$ 的计算方法如式(4)。

$$h(t) = z(t) \odot h(t-1) + (1-z(t)) \odot h(t) \quad (4)$$

3.3 HI 构建算法

仅仅是提取振动信号的特征并不能直观地看出轴承的健康状态, 所以需要建立一种能反映轴承的健康状态的指标, 即健康指数 HI。当轴承开始使用时, 认为它是健康的, 当轴承使用一段时间后, 轴承开始磨损, 这是轴承的特征值也会产生变化, 由此本文引入 Bray-Curtis 距离, 将轴承当前退化的特征值看作一个样本, 轴承初始时刻的特征值看作一个样本, 计算这两者的相似度来反映轴承此刻的健康状态, 由此来建立 HI 算法。

随着传感器实时生成大量振动数据, 为了在最短的处理时间内提取特征信息, 本研究首先对振动数据进行等长序列切分, 然后按等间距采样振动序列, 形成若干组一维数组序列。为表征振动数据的时域特征, 本文选取了表 1 中的 9 个公式。这些公式涵盖了振动信号的均方根、方差、峰峰值等关键特征, 全面而有效地描述了振动数据的时域特性, 从而实现对振动数据的高效处理和特征提取。

计算振动信号的时域特征后, 再用式(5)归一化。

$$X = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

由此得到的特征序列作为模型的输入样本, 为构建 HI 做好准备^[12]。

由于需要测试的数据在实时环境中产生, 数据包括历

表 1 时域特征公式表

时域特征	公式
最大绝对值	$MAX = \max(x_i) $
均方根	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$
峰峰值	$p.p = \max(x_i) - \min(x_i)$
偏度	$skewness = \frac{1}{N} \sum_{i=1}^N \left(\frac{(x_i - \bar{x})}{std(x)} \right)^3$
峭度	$Kurtosis = \frac{1}{N} \sum_{i=1}^N [x_i - \bar{x}]^4$
方根幅值	$RA = \frac{1}{N} \left(\sum_{i=1}^N \sqrt{ x_i } \right)^2$
方差	$Var = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$
脉冲因子	$X_{PulseF} = \frac{\max(x_i)}{\bar{x}}$

史数据和实时监测到的数据, 构建轴承的健康指数变得尤为关键。这一过程的精度直接影响着对轴承状态的准确监测, 从而提高机器设备的可靠性和寿命。

本文选择采用了 BiGRU 模型和 Bray-Curtis 距离相结合的方式构建轴承的健康指数。首先通过 L1 正则化设一个上升趋势的标签, 从表 1 中所得到的所有时域特征中提取有效的时域特征, Bray-Curtis 距离能够计算出当前退化特征与首个时间窗的相似度, 从而量化了退化特征与健康特征之间的关系, 从而直观地表达了轴承的健康状态。

HI 构建算法的流程如图 3 所示。

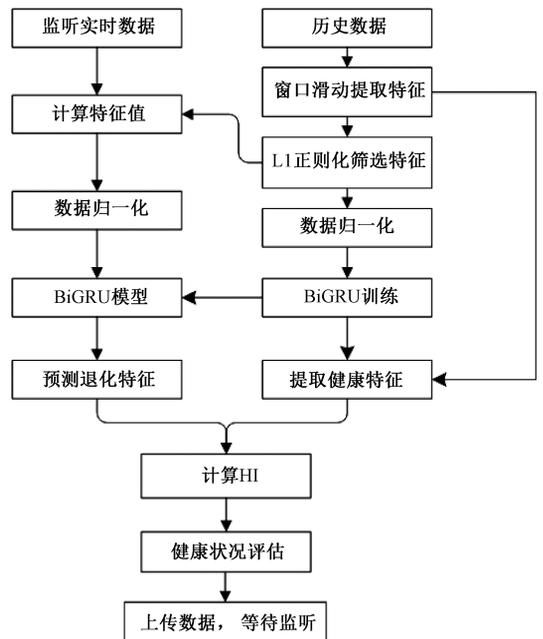


图 3 算法任务流程图

详细步骤如下:

步骤 1) 首先离线训练模型, 将训练的样本数据进行预处理得到的输入序列, 以一个上升趋势的 y 数组作为标签, 输入进 L1 正则化模型中提取有效特征值得到输入样本 X_{input} 。

步骤 2) 输入样本 X_{input} 进行 BiGRU 模型训练, 并且将目标值和预测值之间的均方误差作为损失函数。当损失收敛, 停止迭代, BiGRU 模型训练完毕, 能有效学习到滤波规律和参数的特征, 保存模型。

步骤 3) 训练完毕后用验证集验证, 并且用回归评价指标来表示模型的准确度。

步骤 4) 在线使用阶段, 要实现数据的采集和传输, 将振动传感器采集到的轴承振动信号, 上传至云服务器并存储这些数据, 经过预处理成为输入样本后, 采用第一个时间窗的输入样本作为轴承的健康特征 $F_{\text{healthy}} = \{F_{\text{healthy}, i}\}, i \in [1, 5]$ 。

步骤 5) 云平台选择历史数据, 输入进已经训练好的 BiGRU 模型, 得到预测的轴承退化特征 $F_{\text{degenerative}} = \{F_{\text{degenerative}, i}\}, i \in [1, 5]$ 。

步骤 6) 回归和分析, 可以通过轴承健康状态的特征和预测的退化状态特征对应的特征值之间的差异大小来预测轴承的健康状态, 利用 Bray-Curtis 距离来计算轴承的损伤值, 如式(6)。

$$D_{\text{Bray-Curtis}} = \frac{\sum_{i=1}^N |F_{\text{healthy}, i} - F_{\text{degenerative}, i}|}{\sum_{i=1}^N F_{\text{healthy}, i} + \sum_{i=1}^N F_{\text{degenerative}, i}} \quad (6)$$

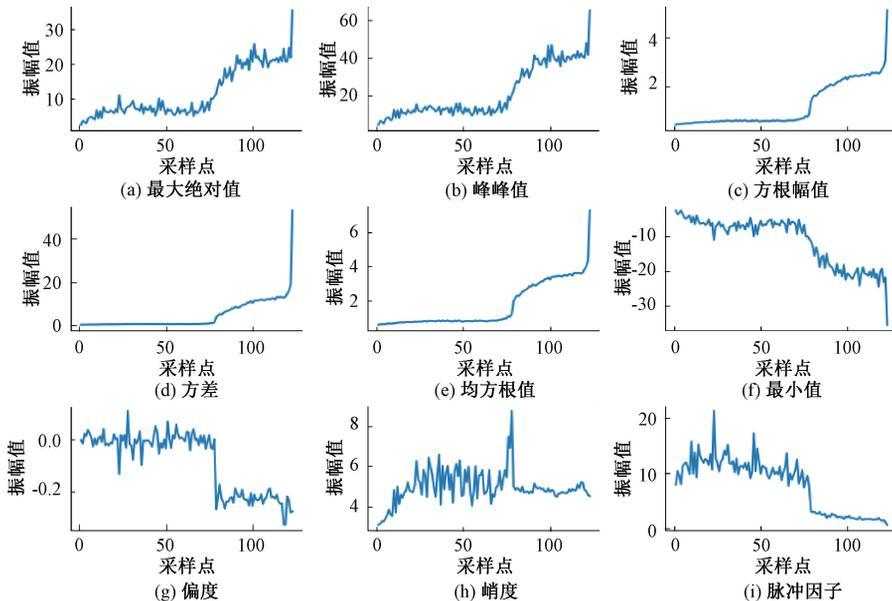


图 4 轴承 Bearing1-1 全周期振动信号时域特征图

将这些特征值归一化后, 输入进 L1 正则化模型中提取上去趋势的特征, 超参数 α 设置为 0.1, 可以得到图 5。

构建 HI 指数, 如式(7)。

$$HI = 1 - D_{\text{Bray-Curtis}} = 1 - \frac{\sum_{i=1}^N |F_{\text{healthy}, i} - F_{\text{degenerative}, i}|}{\sum_{i=1}^N F_{\text{healthy}, i} + \sum_{i=1}^N F_{\text{degenerative}, i}} \quad (7)$$

HI 的区间为 $[0, 1]$, Bray-Curtis 距离值越大, 即 HI 值越小, 轴承的实际状况与标准健康状况之间的差异越小, 轴承的健康状况越好; 反之, HI 值越大, 轴承的健康状况越好。轴承的 HI 曲线是通过计算每次动作的 HI 值来获得的, 依此类推, 可以根据曲线的波动来可视化轴承的退化趋势。

4 系统测试

本系统采用的内核 CPU 为 3.2GHz 8 核的 AMD Ryzen 7, 操作系统为 Windows 10。嵌入式平台采用 RT-thread, Python 中导入 socket 和 http.server 等模块, 来实现基本的网络服务器。训练模型采用 python 的 pytorch 库, HTML 网页开发利用 JavaScript。

4.1 模型的训练与测试

BiGRU 预测需要大量数据, 为了验证本设计的可行性, 数据集采用的是西安交通大学提供的公共轴承数据集^[13], 包含了 15 个轴承在 3 个工况下的全生命周期振动信号。Bearing1-1 共 123 的表格数据, 每个表格 32 768 个采样点, 采样频率为 25.6 kHz, 采样间隔为 1 min, 每次采样时长为 1.28 s。训练采样时从 123 个表格数据中提取各个特征值, 其全周期振动信号的各个时域特征值如图 4。

本方法提取具有上升趋势的特征来做 HI 构建。接下来开始训练模型, 输入前 70% 的数据作为训练集。BiGRU

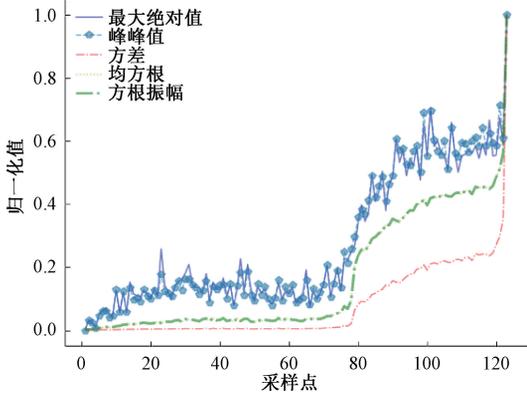


图 5 Bearing1-1 筛选出的特征

模型参数设置如表 2。

表 2 BiGRU 模型参数设置表

参数	参数含义	参数值
Layers	隐藏层	2
LSTM_cells	神经元数	32
input_size	输入样本大小	5
Batch_size	批次大小	256
Learning_rate	学习率	0.001
Step	步长	1

训练 300 轮次,均方误差曲线 Loss 图如图 6 所示。随着迭代次数的增加,训练和验证集的损失值都在不断下降,说明模型在逐渐优化收敛,大约在 70 轮次之后,损失

值趋于 0 不再下降,模型训练完毕。

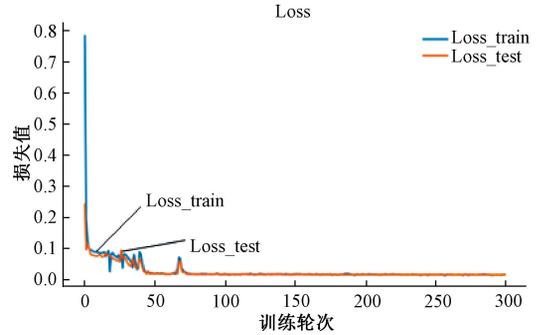


图 6 模型训练误差曲线

后将 30% 的数据作为验证集,输入训练好的 BiGRU 模型中,并与双向长短时记忆网络 (bidirectional long short-term memory, BiLSTM)^[14-16] 模型、双向长短时记忆网络与注意力机制 (bidirectional long short-term memory with attention, BiLSTM-Attention)^[17] 模型做出对比。BiLSTM 由两个 LSTM 组成,LSTM 是一种带有遗忘门、输入门和输出门的循环神经网络单元。BiLSTM-Attention 的结构在 BiLSTM 的输出上应用注意力机制,根据输入序列中每个时间步的重要性聚焦于不同部分,从而捕捉关键信息。

为保证模型对比的公平性,BiLSTM 和 BiLSTM-Attention 模型的隐藏层、神经元数、步长、批大小、学习率设置均与 BiGRU 相同,激活函数采用 tanh 函数,训练次数都设置为 300 轮次。预测完之后利用均值和方差来还原特征值归一化前的值,预测效果如图 7 所示。

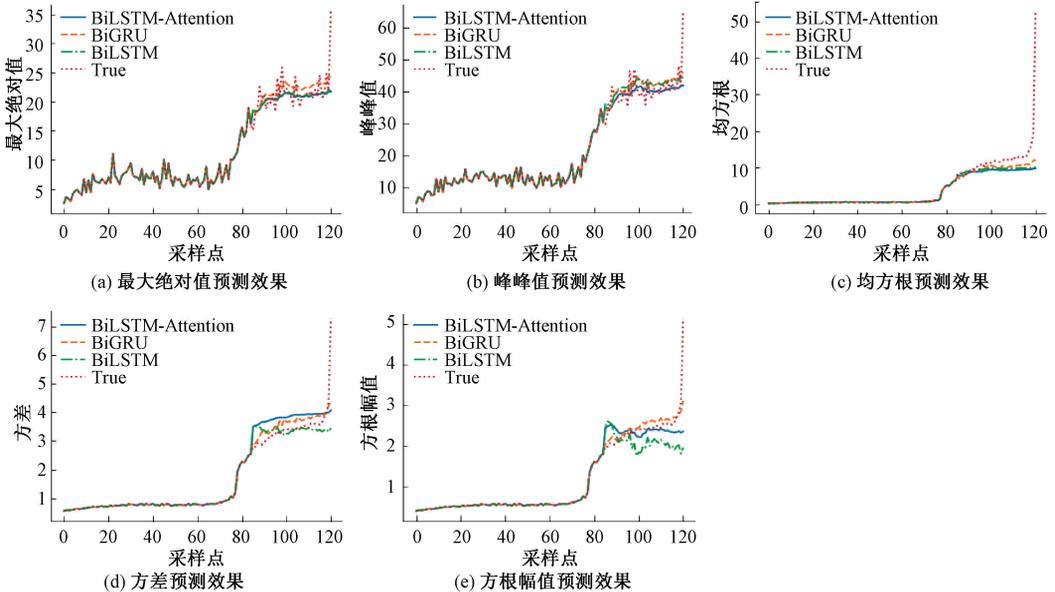


图 7 3 个模型下特征预测值对比图

通过 MSE、RMSE、MAE 3 个回归评价指标来评价模型。

(1) 均方误差 MSE

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{8}$$

(2) 均方根误差 RMSE

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

(3) 平均绝对误差 MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

由式(8)~(10)得出 3 个模型的误差对比, 如表 3 所示。

表 3 误差对比表

模型	MSE	RMSE	MAE
BiGRU	5.216 724	2.284 015	1.063 193 4
BiLSTM	8.004 004 5	2.829 135	1.508 497 6
BiLSTM-Attention	7.815 25	2.795 576 8	1.401 633 9

由表 3 可知 BiGRU 模型的 MSE、RMSE、MAE 相较于 BiLSTM 和 BiLSTM-Attention 有明显的优势。这是因为通过更新门、复位门来控制信息的流动, 有效地避免了长期依赖问题, 并减轻了梯度消失和梯度爆炸的影响, 这使得 BiGRU 模型能够更好地捕捉序列数据中的重要特征, 并对关键信息的传递和保留进行有效的控制。

提取第一段时间窗的健康特征和轴承开始使用后的退化特征, 利用式(7)构建 HI 曲线, 前 70% 的数据为真实, 主要对比后 30% 的预测数据, 即第 85 到第 123 的数据, 仿真对比图如图 7 所示。

从图 8(a)可以看出 HI 模型有效的表征了轴承的退化过程, 从健康的 100% 开始剧烈下降一直到 0.3 左右趋于平缓, 之后又开始剧烈下降直至 0。由于数据相差较小, 不容易看出, 所以图 8(b)放大了第 85 个采样点到第 123 个采样点的验证集数据对比, 可以看出 BiGRU 模型是最贴合实际曲线的, 在其他模型参数不变的情况下, BiGRU 的表现最优, 验证了 BiGRU 模型的优越性。

4.2 实际数据测试

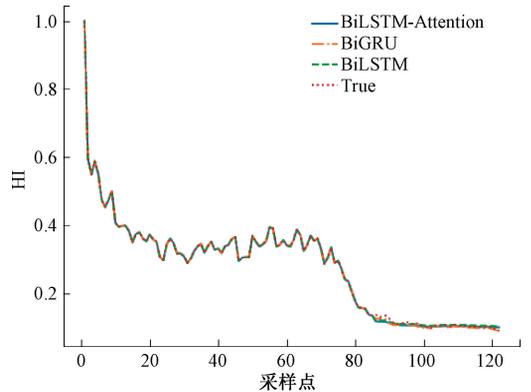
在公共数据集训练和测试模型后, 为保证实际可应用, 接着利用实际数据验证, 本数据来自苏迈特公司实测数据, 采样频率为 12.8 kHz, 每个文件有 4 096 个采样点, 总共 300 个文件数据。将文件输入进模型中, 前 200 个作为训练数据, 后 100 个作为验证数据, 输入模型预测出特征值后, 计算 HI, 得到 HI 退化对比图如图 9 所示。

为了计算 BiGRU 的准确度, 利用决定系数公式:

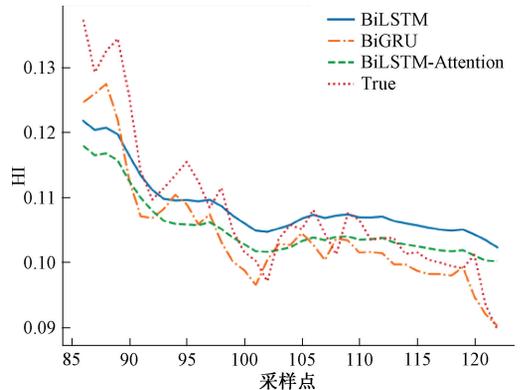
$$r_squared = 1 - \frac{(pred - true)^2}{(pred + true)^2} \quad (11)$$

根据式(11)可知 BiGRU 模型的准确度为 97.52%, BiLSTM 模型准确度为 70.68%, BiLSTM-Attention 模型准确度为 76.32%, 实际数据的测试中, BiGRU 模型仍然表现优异。

$$rate = \frac{data[i] - data[i - 1]}{data[i - 1]}, i \text{ 为采样点数} \quad (12)$$



(a) BiGRU、BiLSTM、BiLSTM-Attention 的 HI 预测对比



(b) BiGRU、BiLSTM、BiLSTM-Attention 的 HI 预测对比

图 8 HI 模型预测对比

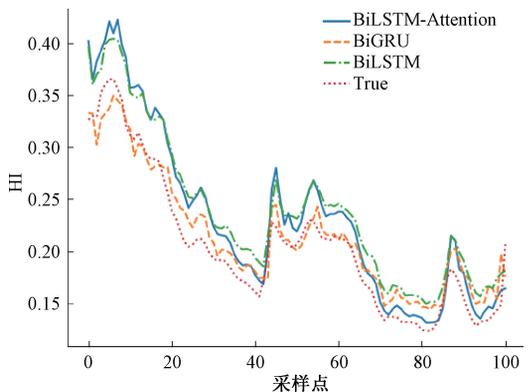


图 9 3 个模型下实测数据 HI 的效果对比图

为了检测轴承故障, 采用变化率判断。根据 HI 退化数据, 利用式(12)计算出 HI 的变化率, 如图 10 所示。

可以看出变化率从第一个数据开始在 0.1 的范围内上下浮动, 到第 270 左右时突然增大到 -0.18, 之后继续剧烈抖动, 可以认为轴承在此时开始故障, 将变化率阈值设置为 ±0.2, 超过阈值即认为轴承出现故障。

4.3 云平台测试

为了实际应用本系统, 对三菱 FX5U 进行了实际测

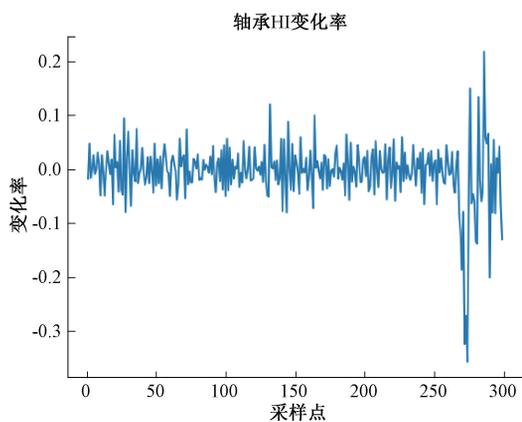


图 10 轴承 HI 变化率图

试。实际上轴承的退化会很缓慢,所以采集数据的频率也会低。轴承开始使用时,记录下最开始的特征信息,每天上传一次振动数据序列。登录物控平台向服务器端发送 http 请求,通过 API 接口获取设备状态信息,监控轴承的状态,PC 终端监控平台界面如图 11 所示。

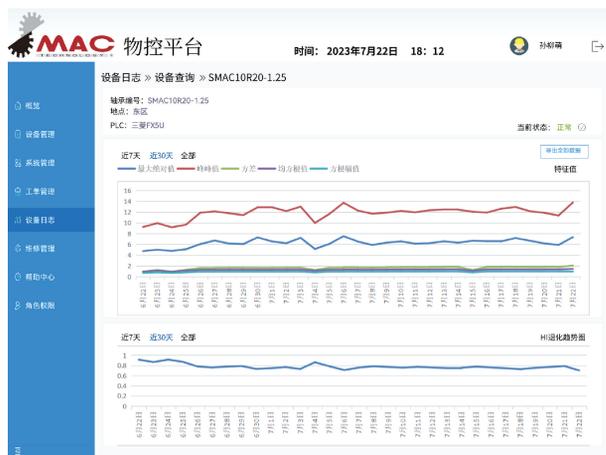


图 11 终端监控页面

打开预测模块,选择设备,训练模型、训练数据以及预测的时长,点击预测后,HTML 会向服务器提供表单信息请求,后端使用 Python 编写服务器端代码,用于接收来自 HTML 页面的请求,使用 Python 中的 PyTorch 库加载训练好的模型,并将请求中的数据输入到模型中进行预测,预测完成后后端服务器将读取图像文件并将其作为字节流响应给前端。在前端的 HTML 页面中,使用标签的 SRC 属性将请求的路径设置为 /image,浏览器会自动加载并显示接收到的图。选择过去全部数据来预测未来 7 天的数据,蓝色线条为历史数据部分,绿色为预测数据部分,如图 12 所示。

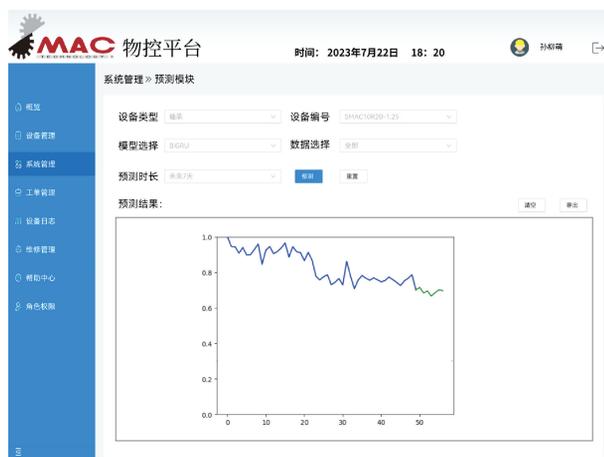


图 12 监控平台预测模块展示图

5 结 论

针对传统神经网络模型无法合理利用在线数据的问题,提出了一种基于 L1 正则化的 BiGRU 模型和 Bray-Curtis 距离的 HI 构建方法,能够监测和预测轴承的健康状态。在用西安交通大学提供的公共轴承数据集来仿真的基础上,通过实际的测试,验证了该方法在可靠性预测领域的适用性。本文方法的优越性如下:

将采集到的数据传输到服务器上运行的 Python 深度学习模型进行推断。这种方式将边缘设备和云端深度学习模型结合起来,具有实时性和低功耗特性。

对上位机通信功能进行开发,将数据传输到应用层,利用云监控平台对轴承的健康指数进行实时监测,并设定变化率阈值,一旦超过平台会报警,让工作人员检修。

本文提出的 BiGRU 模型准确率达到 97.52%, 远超 BiLSTM、BiLSTM-Attention 模型的准确率。

应用此方法可以大大降低了机器设备老化甚至宕机带来的影响,提高了工业作业中的效率,进一步实现工业的自动化、智能化。未来将进一步研究,寻找更多时域和频域的有效特征值,并且增加对更多类型部件的寿命预测,更加精确地监测健康状态。

参考文献

- [1] 赵国威,曾静. 基于 EMD-GAF 和改进的 SERE-DenseNet 的滚动轴承故障诊断方法[J]. 电子测量技术, 2023, 46(20): 170-176.
- [2] 赵志宏,李乐豪,杨绍普,等. 一种无监督的轴承健康指标及早期故障检测方法[J]. 中国机械工程, 2022, 33(10): 1234-1243.
- [3] 汤武初,吕亚博,刘佳彬,等. 基于特征融合和 ResNet 的滚动轴承故障诊断[J]. 机电工程, 2023, 40(8): 1167-1175.
- [4] 刘湘楠,赵学智,上官文斌. 强背景噪声振动信号中滚动轴承故障冲击特征提取[J]. 振动工程学报, 2021,

- 34(1):202-210.
- [5] 崔玲丽,金瓯,王鑫.滚动轴承寿命预测的相似性匹配优化方法研究[J].振动工程学报,2023,36(3):854-860.
- [6] 黄庆卿,胡欣堪,韩延,等.多源域子域自适应的滚动轴承剩余寿命预测方法[J].电子测量与仪器学报,2022,36(10):100-107.
- [7] 薛林,王豪,王云森,等.基于Autoformer的滚动轴承剩余使用寿命预测[J].电子测量技术,2023,46(13):169-175.
- [8] 陈帝旭,郑滢,王晓峰.基于边云协同的设备数据采集及振动故障分析应用[J].制造技术与机床,2023(9):88-94.
- [9] 陈辉,缪炳荣,赵浪涛,等.基于L1范数正则化和最小二乘优化的冲击载荷识别研究[J].噪声与振动控制,2023,43(1):62-67,99.
- [10] 朱凌建,陈剑虹,王裕鑫,等.基于GRU神经网络的脉搏波波形预测方法研究[J].电子测量与仪器学报,2022,36(5):242-248.
- [11] 张朝龙,罗来劲,刘惠汉,等.基于增量能量法和BiGRU-Dropout的锂电池健康状态估计[J].电子测量与仪器学报,2023,37(1):167-176.
- [12] 叶壮,余建波.基于多通道加权卷积神经网络的齿轮箱振动信号特征提取[J].机械工程学报,2021,57(1):110-120.
- [13] 雷亚国,韩天宇,王彪,等.XJTU-SY滚动轴承加速寿命试验数据集解读[J].机械工程学报,2019,55(16):1-6.
- [14] 杨洋,黄罗杰,李平,等.基于多维度特征提取的电弧故障检测方法[J].电子测量与仪器学报,2021,35(10):107-115.
- [15] 刘伟,黄海波,范大力,等.一种基于LSTM的汽车路噪预测方法[J].噪声与振动控制,2023,43(3):145-152.
- [16] 张怀洲,行鸿彦,李浩琪,等.融合LSTM和改进A*算法的火灾逃生路径规划方法[J].电子测量与仪器学报,2023,37(4):69-79.
- [17] 王雷,何坤,李宗帅,等.基于BiLSTM-Attention的迁移学习变工况故障识别方法研究[J].电子测量与仪器学报,2023,37(7):205-212.

作者简介

孙柳萌,硕士,主要研究方向为嵌入式系统开发、深度学习。

E-mail:liumeng_s@stmail.ntu.edu.cn

杨永杰(通信作者),博士,教授,主要研究方向为嵌入式系统开发。

E-mail:yang_yj@ntu.edu.cn

张宁涛,硕士,主要研究方向为嵌入式系统开发。

E-mail:zhang.nt@stmail.ntu.edu.cn