

DOI: 10.19650/j.cnki.cjsi.J2108410

变转速工况下基于多传感器信号深度特征融合的电机故障诊断研究*

王骁贤^{1,2}, 陆思良³, 何清波⁴, 张世武²

(1. 安徽大学电子信息工程学院 合肥 230601; 2. 中国科学技术大学精密机械与精密仪器系 合肥 230027;
3. 安徽大学电气工程与自动化学院 合肥 230601; 4. 上海交通大学机械与动力工程学院 上海 200240)

摘要:本文提出一种利用多传感器信号深度特征融合的方法实现电机变转速工况下的故障诊断。首先从多传感器节点同步采集电机的多通道振动、声音和漏磁信号。对漏磁信号进行处理获取电机转子的累积转角曲线,随后利用累积转角曲线对振动和声音信号进行阶比分析处理。最后利用双层双向长短期记忆网络从经过预处理的多传感器信号中提取和融合特征以诊断电机故障。实验结果表明,通过提取和融合 8 通道的电机振动和声音信号,本文提出的方法能够有效识别电机的高阻接触、偏心、霍尔断线、相间短路、轴承等 10 类运行状态,分类准确率达到 99.86%。该方法有望部署在物联网边缘计算节点中,实现电机的远程在线状态监测和故障诊断。

关键词:电机故障诊断;多传感器信号;深度特征融合;双层双向长短期记忆网络;阶比分析

中图分类号: TM351 TH133.3 **文献标识码:** A **国家标准学科分类代码:** 460

Motor fault diagnosis based on deep feature fusion of multi-sensor data under variable speed condition

Wang Xiaoxian^{1,2}, Lu Siliang³, He Qingbo⁴, Zhang Shiwu²

(1. College of Electronics and Information Engineering, Anhui University, Hefei 230601, China; 2. Department of Precision Machinery and Precision Instrumentation, University of Science and Technology of China, Hefei 230027, China;
3. College of Electrical Engineering and Automation, Anhui University, Hefei 230601, China; 4. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: This article proposes a method based on the deep feature fusion of multi-sensor data for accurate motor fault diagnosis under varying speed condition. First, vibration, acoustic, and leakage magnetic signals are sampled from the data acquisition node. The accumulative rotating angle of the motor rotor is calculated from the leakage magnetic signal. Then, the order analysis is conducted on the vibration and acoustic signals based on the angle curve. Finally, the features of the pre-processed signals are extracted and fused by using the double-layer bidirectional long short-term memory (DBiLSTM) networks for fault pattern recognition. Experimental results show that the proposed method can identify 10 types of working conditions including high-resistance connection, eccentric, broken wire of the Hall sensor, interphase short circuit, and bearing faults with the accuracy of 99.86%, by extracting and fusing of 8 channels of motor vibration and acoustic signals. The method is promising to be deployed into the internet of things edge computing node for remote online condition monitoring and fault diagnosis.

Keywords: motor fault diagnosis; multi-sensor signal; deep feature fusion; DBiLSTM; order analysis

0 引 言

电机是工业中主要的电能到机械能的转换装置,其

状态监测和故障诊断对于保障安全生产十分重要^[1-3]。电机的故障类型可以分为 3 大类,即机械故障、电气故障、磁故障。典型机械故障包括轴承故障、转子偏心、不对中等。电气故障包括匝间短路、相间短路、高阻接触、

开路故障等。磁故障包括永磁铁退磁失磁、永磁体损坏等。电机故障诊断可以通过分析振动、声音、电流等信号特征实现^[4]。例如,宫文峰等^[5]提出一种基于深度学习网络的方法,从振动信号中提取特征实现电机轴承微小故障的智能诊断方法。贾朱植等^[6]提出一种基于电流信号特征高分辨率谱估计的电机早期转子断条故障诊断方法。蔡文伟等^[7]提出一种通过声音信号分析诊断微型电机故障的方法。

实际工况下,受安装位置和环境噪声的影响,单一传感器捕捉到电机状态信息有限,如何提升传感器信号特征提取的精度和效率是故障诊断的一个挑战和难点^[8]。多传感器信息融合技术能够充分利用信号之间的信息互补,提高电机故障识别的精度。例如,石江波等^[9]提出一种基于电机电流和振动信号融合的故障诊断方法。袁媛等^[10]提出一种基于反向传播神经网络算法和 DS (dempster-shafer) 证据理论的多数据融合电机故障诊断方法。Wang 等^[11]提出一种基于卷积神经网络的多通道振动信号图像融合方法识别机械故障。Chen 等^[12]提出一种基于稀疏自编码和深度置信网络的轴承故障多传感器特征融合诊断方法。以上方法通过融合多个传感器的信号,有效提升了故障诊断的精度。然而,当前大部分基于多传感器信息融合的故障诊断研究主要针对电机恒定转速工况。

变转速工况下,信号特征随着时间和转速变化,降低了信号特征提取的稳定性,从而影响了故障诊断的精度^[13]。阶比分析是解决变转速工况下电机故障诊断的有效方法。通过对时域信号进行等角度重采样,原频域中时变的特征在阶比域中变为近似的平稳^[14]。阶比分析所需的电机转速信息通常采用编码器进行测量,然而部分采用无传感器控制的电机没有预装编码器,因而需要从其他传感器中精确估计电机转速以实现变转速工况下的故障诊断^[15]。

针对以上难点,为了进一步提升变转速工况下的电机故障识别精度,本文研究一种从声音、振动、磁场多传感器信号中提取和融合特征的方法。首先集成多传感器的节点同步采集 3 种类型信号,对磁场信号进行预处理提取电机的累积转角曲线。利用累积转角曲线对共计 8 通道的振动和声音信号进行等角度重采样,得到角域信号。随后设计一种双层双向长短期记忆 (double-layer bidirectional long short-term memory, DBiLSTM) 深度神经网络,把预处理的多通道时序信号的频谱作为网络的输入,不同电机的健康和故障类型作为输出,训练和优化网络。最终,训练好的 DBiLSTM 能够实现 10 类电机健康和故障类型的识别,平均精度达到 99.86%。

本文提出的方法具有精度高、信号预处理计算量小、易于在线实现等优点。同时本文实验中的磁力计、加速

度计、麦克风等传感器具有体积小、高度集成、低功耗等特点。因此本文所提出的算法有望部署于物联网节点中实现电机的远程在线状态监测和实时故障诊断。

1 多传感器信号采集节点硬件电路

本文将同步采集 5 个传感器共计 9 通道的多传感器数据以实现电机故障诊断。如图 1 所示,采集电路的主控制器为主频 120 MHz 的低功耗 STM32L4 处理器。其中 3 轴加速度传感器 IIS3DWB 和 ISM330DHCX,通过串行外设接口 (serial peripheral interface, SPI) 总线与主控制器相连。IIS2MDC 为 3 轴磁力计,通过集成电路总线 (integrated circuit, IIC) 与主控相连。在本文中只采集垂直于电机外壳表面的 Z 轴信号用于估计电机的转角。一个数字麦克风 (IMP34DT05) 和一个模拟麦克风 (IMP23ABSU) 分别安装在信号采集电路板的正反面,用于捕获电机运转时的噪声信号。数字麦克风通过基于调制器的数字滤波器接口 (digital filter for sigma-delta modulators, DFSDM) 与主控相连,模拟麦克风的输出信号直接通过主控的内置模数转换器 (analog to digital converter, ADC) 采集。

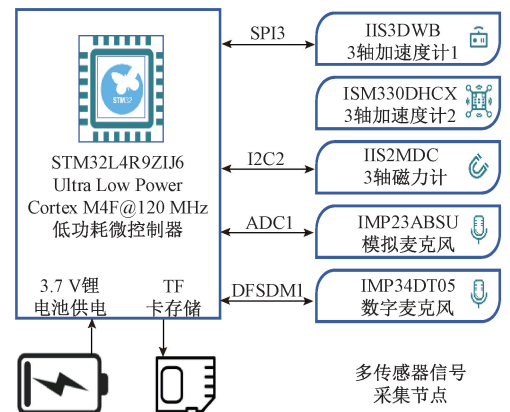


图 1 硬件电路框架

Fig. 1 Framework of the hardware circuit

2 故障诊断算法流程

本文所提方法首先同步采集变转速电机的漏磁、振动和声音信号,对漏磁信号进行处理以估计电机的转角。随后对振动和声音信号进行阶比分析,最后采用深度神经网络提取和融合特征实现电机故障模式识别。

2.1 从电机漏磁信号估计电机转角

同步采集的电机漏磁信号表示为 $M[i]$, $i = 1, 2, \dots, N_1$, 其中 $N_1 = fsm \times T$ 为漏磁信号采样点数, fsm 为

漏磁信号的采样频率, T 为采集时长, 采样时刻表示为 $t[i]$, $i = 1, 2, \dots, N_1$ 。振动和声音信号统一表示为 $VA_k[i]$, $i = 1, 2, \dots, N_2$, 其中 $N_2 = fsva \times T$ 为振动和声音信号采样点数, $fsva$ 为采样频率, 下标 $k = 1, 2, \dots, 8$ 表示第 k 个通道的振动或声音信号。由于漏磁信号的采样频率较低, 其波形不够光滑, 影响了转速估计的精度, 同时 $fsm < fsva$, 因此本文首先对漏磁信号 $M[n]$ 进行三次样条曲线插值以平滑曲线并扩充数据长度^[16]。

漏磁信号的数据采样点可以表示为 $(t[i], M[i])$, 插值的计算步长 $h_i = t[i+1] - t[i]$ 。在 $t[i] < t < t[i+1]$ 区间, 样条曲线方程表示如下:

$$g_i(t) = a_i + b_i(t - t[i]) + c_i(t - t[i])^2 + d_i(t - t[i])^3 \quad (1)$$

式中:

$$\begin{cases} a_i = M[i] \\ b_i = \frac{M[i+1] - M[i]}{h_i} - \frac{h_i}{2}m_i - \frac{h_i}{6}(m_{i+1} - m_i) \\ c_i = \frac{m_i}{2} \\ d_i = \frac{m_{i+1} - m_i}{6h_i} \end{cases} \quad (2)$$

式中: m_i 为根据数据采样点和首位端点条件构造的三角对角矩阵方程的解的二次微分值。

根据振动和声音信号长度 N_2 将漏磁信号 $M[i]$ 进行三次样条曲线插值得到插值后的信号为 $IM[i]$, $i = 1, 2, \dots, N_2$ 。随后, 通过希尔伯特变换计算信号 $IM[i]$ 的相位如下:

$$p[i] = \arctan \left\{ \frac{\text{Im}(\mathcal{H}(IM[i]))}{\text{Re}(\mathcal{H}(IM[i]))} \right\} \quad (3)$$

式中: $\mathcal{H}(\cdot)$ 表示希尔伯特变换, $\text{Re}(\cdot)$ 和 $\text{Im}(\cdot)$ 分别表示信号的实部和虚部。随后, 电机转子随时间的累积转角曲线计算如下^[17]:

$$\alpha[i] = \frac{180^\circ}{\pi \times np} \times (\text{unwrap}(p[i]) - p[1]) \quad (4)$$

式中: np 表示电机的极对数, $\text{unwrap}(\cdot)$ 表示 MATLAB 内置的解缠绕函数。该函数使得原来分布在 $[-\pi, \pi]$ 范围的不连续 $p[i]$ 曲线转变为连续递增的曲线, 式(4)最右侧的 $-p[1]$ 项使得转子角度曲线的起始点为 0, 即 $\alpha[1] = 0$ 。

2.2 振动和声音信号重采样与频谱矫正

电机运行在变转速工况时的振动和声音信号特征是时变特征, 在获得电机的累积转角曲线后对振动和声音信号进行阶比分析即可获得角域相对平稳的特征。阶比

分析通过对原时域信号进行等角度重采样实现, 如下所示:

$$RVA_k[i] = \text{resample}(VA_k[i], \alpha[i]) \quad (5)$$

式中: $\text{resample}(\cdot)$ 为 MATLAB 内置的重采样函数, 该函数采用插值方法根据新的坐标向量 $\alpha[i]$ 对时间序列对象 $VA_k[i]$ 进行重采样。

当电机发生故障时, 安装在电机外壳上的传感器采集的信号频谱会出现与故障特征相关的频率, 这些故障特征频率可以作为故障检测和分类的指标。因此, 本文方法将重采样信号的频域特征作为深度神经网络的输入, 如下所示:

$$F_k[i] = |FFT(RVA_k[i])| \quad (6)$$

式中: $F_k[i]$ 表示提取的 k 通道特征, $FFT(\cdot)$ 表示快速傅里叶变换, $|\cdot|$ 表示取模操作。

2.3 多传感器深度特征提取与融合

在提取了多通道振动和声音信号的特征后, 本文搭建 DBiLSTM 深度神经网络模型, 用于实现特征融合和电机故障模式识别。如图 2 所示, DBiLSTM 模型是一个串行结构, 由输入层、双层 BiLSTM、全连接层、Softmax 层和分类层构成。

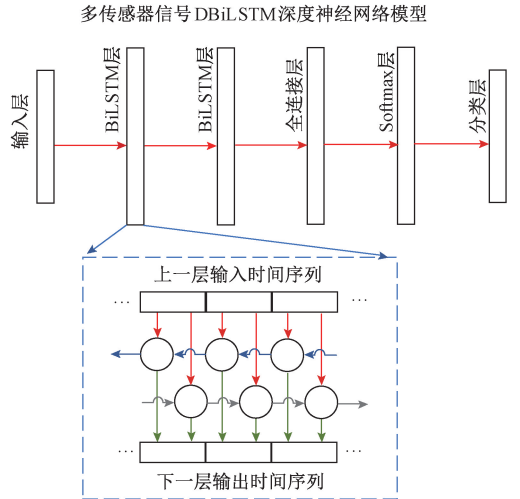


图 2 DBiLSTM 网络模型

Fig. 2 DBiLSTM networks model

输入层信号的特征维度为 $8 \times N_2$, 即 8 通道的振动和声音信号的频谱, 每通道频谱长度为 N_2 点。BiLSTM 为双向长短期记忆网络, 其输入和输出都为时间序列, 如图 2 下方子图所示。BiLSTM 网络由前向 LSTM 网络和后向 LSTM 网络组合而成, 其核心结构和计算过程介绍如下^[18]:

1) 计算遗忘门, 即选择网络中需遗忘的信息: 定义 t 时刻的输入为 x_t , 前一时刻的隐层状态为 h_{t-1} , 则 t 时刻的遗忘门的输出如式(7)所示。

$$f_i = \sigma(\mathbf{W}_f \cdot [h_{i-1}, x_i] + \mathbf{b}_f) \quad (7)$$

式中: σ 、 \mathbf{W}_f 、 \mathbf{b}_f 分别为激活函数、遗忘门的权重和偏置矩阵。

2) 计算记忆门, 即选择网络中需记忆的信息: 定义记忆门在 t 时刻的值为 i_t , 临时细胞状态为 \tilde{C}_t , 计算如下:

$$\begin{cases} i_t = \sigma(\mathbf{W}_i \cdot [h_{i-1}, x_i] + \mathbf{b}_i) \\ \tilde{C}_t = \tanh(\mathbf{W}_c \cdot [h_{i-1}, x_i] + \mathbf{b}_c) \end{cases} \quad (8)$$

式中: \mathbf{W}_i 和 \mathbf{b}_i 分别为记忆门的权重和偏置矩阵, \mathbf{W}_c 和 \mathbf{b}_c 分别为细胞的权重和偏置矩阵。

3) 计算 t 时刻的细胞状态: 定义上一时刻的细胞状态为 C_{t-1} , 则有:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (9)$$

式中: $*$ 表示卷积运算。

4) 计算 t 时刻的输出门的值 O_t 和隐层状态 h_t :

$$\begin{cases} O_t = \sigma(\mathbf{W}_o \cdot [h_{i-1}, x_i] + \mathbf{b}_o) \\ h_t = O_t * \tanh(C_t) \end{cases} \quad (10)$$

式中: \mathbf{W}_o 和 \mathbf{b}_o 分别为输出门的权重和偏置矩阵, 通过以上计算可以得到与输入时间序列等长的隐层状态序列 $(h_0, h_1, \dots, h_{N_2-1})$ 。

5) 双向 BiLSTM 网络的输出合成: 对于输入时间序列 $(x_0, x_1, \dots, x_{N_2-1})$, 前向 LSTM 的输出时间序列表示为 $(h_{L_0}, h_{L_1}, \dots, h_{LN_2-1})$, 后向 LSTM 的输出时间序列表示为 $(h_{R_0}, h_{R_1}, \dots, h_{RN_2-1})$ 。将前向和后向的输出序列合并, 得到 BiLSTM 的时间序列输出表示为 $([h_{L_0}, h_{R_0}], [h_{L_1}, h_{R_1}], \dots, [h_{LN_2-1}, h_{RN_2-1}])$ 。

2.4 本文方法流程总结

本文提出的方法流程如图 3 所示, 该方法主要包含两个步骤。首先通过电机漏磁信号分析, 估计电机转子随时间增长的旋转角度。接着对振动和声音信号进行阶比分析, 利用深度神经网络识别电机故障类型。通过这两个步骤, 能够提升变转速工况下的电机故障识别精度。

3 实验平台与信号采集系统

3.1 实验平台

为了验证本文提出方法的有效性, 设计如图 4 所示的电机测试平台。测试电机为直流无刷电机, 参数如表 1 所示。测试电机通过联轴器对拖 1 个相同型号的电机作为负载发电机, 发电机三相交流输出通过交流-直流 (alternating current-direct current, AC-DC) 整流器转变为直流入电子负载, 直流负载设置为恒定电阻模式。在实验中, 电机的转速通过驱动器实时调节。

本文分别在 10 个电机上设置不同类型的状态, 包括健康、机械故障、电气故障、传感器故障等。随后将不同

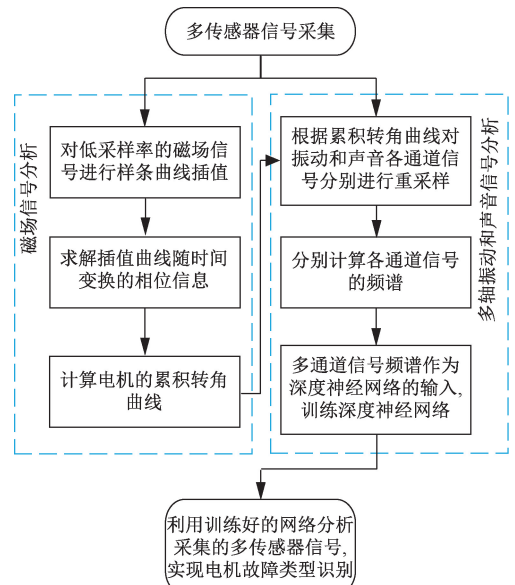


图 3 方法流程

Fig. 3 Flowchart of the method




图 4 实验平台

Fig. 4 Experimental setup

表 1 测试电机参数

Table 1 Parameters of the test motor

电机型号	电机类型	额定电压/V	额定转矩/Nm	额定功率/W
80BL110S50	3 相 2 极对	直流 48	1.6	500

状态的电机分别替换安装到图 4 所示的实验平台上进行测试采集数据。10 种故障类型的标签、简写和说明如表 2 所示。

3.2 信号采集系统

如图 5 所示, 多传感器信号采集节点 (STEVAL-STWINKT1B, 意法半导体) 安装在电机机壳的侧面。该节点同步采集电机的 1 通道漏磁信号、6 通道振动信号

表2 电机故障类型

Table 2 Fault types of the motors

序号及简写	说明
0:高阻	电机定子绕组高阻接触故障
1:霍尔	电机霍尔线断一根
2:健康	电机无故障
3:内圈1	轴承内圈故障宽度 0.5 mm
4:内圈2	轴承内圈故障宽度 1 mm
5:内圈3	轴承内圈故障宽度 1.5 mm
6:偏心	电机转子上安装偏心质量块
7:外圈1	轴承外圈故障宽度 0.5 mm
8:外圈2	轴承外圈故障宽度 1 mm
9:相短	定子绕组相间短路




图5 信号采集系统

Fig. 5 Signal acquisition system

(2个三轴加速度传感器)、2通道噪声信号。信号采集节点采用3.7V锂电池供电,多通道传感器信号同步采集后存储到TF卡中再进行提取分析,也可以通过在采集节点上安装蓝牙或者Wi-Fi模块进行无线信号传输。

5个微机电系统(micro electro mechanical systems, MEMS)传感器在采集节点上的位置如图5所示。此外,为了验证本文方法利用磁场信号估计电机转速的准确性,在健康电机的转轴安装一个100脉冲/圈的增量式编码器,编码器信号通过外部NI USB-4431采集卡采集。

4 实验验证

本章通过对多传感器信号的分析验证提出方法的有效性和优越性。

4.1 信号重采样与频谱矫正结果

为了更好地说明方法对提升变转速工况下电机信号特征稳定性的效果,选取电机轴承外圈故障时采集的振动信号进行分析。图6(a)和(b)分别为信号的波形和包络谱。

络谱。当轴承发生故障时,冲击信号串会出现在波形中。由于电机运行在变转速工况下,相邻冲击之间的间隔也随着时间呈现疏密变化。从图6(b)所示的信号包络谱中可见谱线较密集,但由于电机转速变化,没有明显突出的谱线能够明确地表征电机轴承的故障类型。


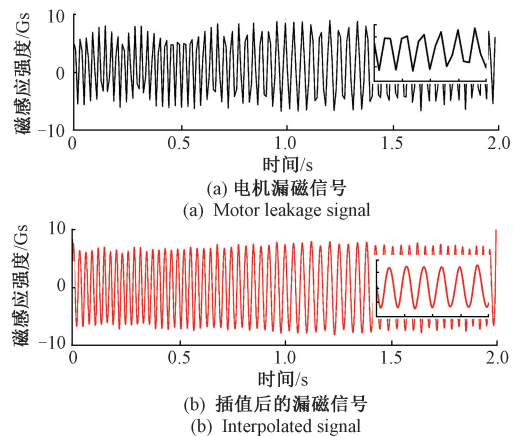


图6 变转速工况下的电机轴承外圈故障信号分析结果
Fig. 6 Analyzed results of the motor bearing outer raceway fault signal under variable speed conditions

本文中测试的直流无刷电机的转子上表贴有永磁体,电机运转时转子和定子绕组气隙间的磁场会泄露到电机外壳从而被磁力计检测。与振动信号同步采集的电机漏磁信号如图7(a)所示,从图中可见电机旋转时其漏磁信号幅值随着转速波动,因此漏磁信号能够反映电机的转速。但是,从图7(a)的波形中可见,由于磁力计的采样频率较低,漏磁信号的波形不够光滑。从局部放大图也可以看出,在波峰和波谷位置的曲线十分尖锐。为了提高电机转角估计的精度,对漏磁信号根据2.1节的方法进行三次样条曲线插值,得到的结果如图7(b)所示。对比图7(a)和(b)可见,插值后的曲线光滑度显著提高,波形接近于正弦波。随后,从插值信号中估计和计算电机的累积转角曲线,结果如图7(c)所示。从曲线形状看见,电机在0~2s的期间内经历了先减速后加速的过程。






图7 电机漏磁信号分析结果

Fig. 7 Analyzed results of the motor leakage signal

为了验证本文利用磁场信号分级计算累积转角曲线的精度,对同步采集的编码器信号进行对齐后分析,得到的电机实际转速曲线如图8(a)所示。从图中可见,电机以近似三角波函数方式进行匀加减速旋转,加减速的范围为690~1 080 rpm,周期为2 s。从编码器信号计算得到的累积转角曲线如图8(b)所示,在电机减速过程中(如区间1所示),角度曲线的上升速率为4 420°/s,加速过程(如区间2所示)的角度曲线上升速率为5 503°/s。对比图7(c)和图8(b)可见,通过磁场信号分析得到的累积转角曲线和通过参考编码器得到的曲线十分接近。通过计算,两根曲线的均方根误差为7.82°,该结果说明了本文提出的方法的精度较高。

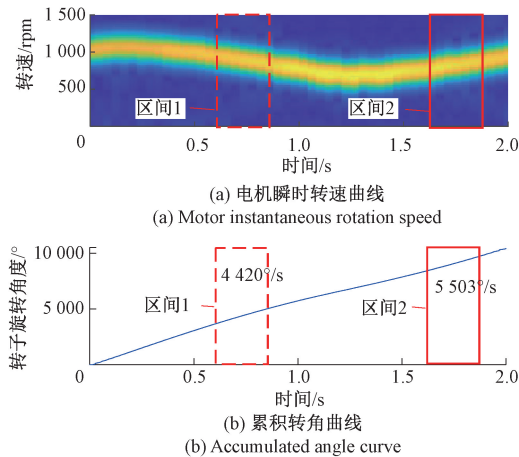


图8 编码器信号分析结果

Fig. 8 Analyzed results of the encoder signal

利用图7(c)中的累积转角曲线对图6(a)中振动信号进行重采样阶比分析,结果如图9所示。经重采样,原时域信号变成角域信号,对信号做包络分析得到频谱如图9(b)所示。从包络阶次谱中可以清晰地分辨出与轴承故障相关的特征阶次。对比图6(b)和图9(b)可见,经过阶比分析,原时域信号的频谱的不平稳特征在角域信号频谱中变为近似平稳。这些故障特征阶次与电机的故障类型紧密相关,经过阶比分析后的信号能够更好地表征电机的运行状态类型。




图9 阶比分析处理后的振动信号

Fig. 9 The vibration signal after order analysis

4.2 网络训练与电机故障识别结果

对10种不同类型的电机故障、每种故障的8通道信号都进行重采样阶比分析预处理后,根据图2搭建DBiLSTM深度神经网络模型进行特征提取融合和故障模式识别。每个训练样本的特征维度为8×5 000,每组共10种电机状态类型的训练样本大小为8×5 000×10,共选取50组样本进行训练。训练的学习率设置为0.001,迭代次数设置为125次。网络训练的硬件平台配置如下:处理器 Intel i9-10900,内存32 GB,系统64位WIN10,显卡 NVIDIA RTX3070 8 GB,环境 MATLAB2021a。训练过程的损失和精度曲线如图10所示,随着迭代次数的增长,损失趋近于0,精度趋近于100%。




图10 DBiLSTM模型的训练精度和损失

Fig. 10 The training accuracy and loss of the DBiLSTM model

DBiLSTM模型训练完成之后,对验证数据集进行验证,10种电机健康和故障类型的分类结果如图11所示。在50 000个时间序列数据点中,只有少量的数据点出现分类错误,经过10次验证测试,得到平均分类精度为99.86%。由此可见,本文提出的方法通过融合多通道的振动和声音信号,能够高精度地实现直流无刷电机故障检测以及不同电气、机械、传感器故障的分类识别。




图 11 分类结果

Fig. 11 Classification results

4.3 方法对比分析

为了进一步验证提出方法的优越性,本节选取不同的深度学习模型进行对比分析。对比分析的模型包括时间卷积网络模型(temporal convolutional network, TCN)^[19]、LSTM模型、门控循环单元模型(gate recurrent unit, GRU)^[20]以及BiLSTM模型。这几类模型的输入向

量维度、训练样本容量、训练迭代次数都设置与DBiLSTM模型的参数一致。另外,为了验证不同传感器数据对分类精度的影响,本文选取分别选取1、2、3通道振动信号,3通道振动信号加1、2通道声音信号,以及6通道振动信号加2通道声音信号进行纵向比较。此外,由于实验电机运行在变转速状态,本文方法首先对变转速信号进行阶比分析预处理。为了说明预处理的必要性,对比实验中也对原始信号进行直接特征提取和分析。每个传感器和方法的组合分别进行10次测试,得到的平均测试精度如表3所示。

从表3的对比分析结果中可以得到3个结论,分析如下:1)对于相同的模型和预处理方法,多通道多传感器数据能够提升故障识别的精度。2)对于相同的数据类型和模型,经过阶比分析预处理后的信号具有较高的分类精度。3)通过堆叠双层双向LSTM模型,在相同条件下获得最高的电机故障识别精度。由此可见,本文提出的方法通过对变转速信号进行预处理,并利用多传感器信号的冗余信息互补,设计适合于时间序列特征的深度神经网络,最终提升了变转速工况下电机故障诊断精度。

表 3 对比实验结果

Table 3 Comparative experimental results

传感器通道 及类型/方法	TCN		LSTM		GRU		BiLSTM		DBiLSTM	
	无处理	重采样	无处理	重采样	无处理	重采样	无处理	重采样	无处理	重采样
6 振动+2 声音	97.55	98.13	86.98	88.47	76.63	78.35	91.69	94.14	99.63	99.86
3 振动+2 声音	96.03	96.38	79.73	80.46	71.44	71.65	86.75	88.78	99.29	99.82
3 振动+1 声音	95.68	95.99	77.47	78.49	69.90	70.63	84.88	85.88	97.34	98.44
3 振动	91.85	92.42	66.34	76.67	62.32	69.01	77.55	81.68	95.15	96.38
2 振动	80.66	89.59	59.76	64.15	50.10	54.41	70.05	76.41	50.55	68.50
1 振动	62.57	74.22	35.14	41.81	33.05	34.56	53.91	50.06	45.18	49.88

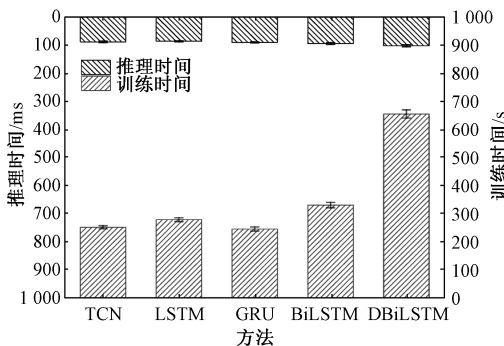


图 12 不同方法的训练和推理时间对比

Fig. 12 Comparison of the training and inference time for different methods

为了进一步比较不同深度学习模型的性能,本文对不同模型的训练和推理时间进行分析,带误差棒的测试结果如图12所示。从图12中可见,由于本文设计的DBiLSTM模型层数和参数较多,因此训练用时约11min,其他模型的训练用时在4~5min之间。另外,不同模型对于一帧信号的推理时间都在100ms左右,因此深度神经网络模型能够较快地识别电机故障。在后续的研究中可以进一步优化模型参数以提升训练效率和分类精度。

5 结 论

本文提出一种两步骤多传感器信号处理方法实现了电机变转速工况下的故障检测和识别。首先对电机的漏磁信号进行处理以估计电机的累积转角曲线。利用累积

转角曲线对同步采集的多通道振动和声音信号进行阶比分析,将原时域信号转变为角域信号以消除转速对信号特征稳定性的干扰。最后设计以多通道信号的频谱向量作为输入的 DBiLSTM 模型实现电机相间短路、霍尔传感器断线、轴承故障、高阻接触故障等 10 种不同健康和故障状态的分类识别。本文提出的方法精度高、计算效率高、能够解决变转速工况引起的信号特征不稳定性问题。同时本文实验的多传感器信号采集电路节点具有芯片高度集成、低功耗高效能等优点。本文方法有望部署应用于基于物联网技术的电机远程状态监测和实时故障诊断中。

参考文献

- [1] NANDI S, TOLIYAT H A, LI X D. Condition monitoring and fault diagnosis of electrical motors-A review [J]. IEEE Transactions on Energy Conversion, 2005, 20 (4): 719-729.
- [2] LU S L, QIAN G, HE Q B, et al. Insitu motor fault diagnosis using enhanced convolutional neural network in an embedded system [J]. IEEE Sensors Journal, 2020, 20 (15): 8287-8296.
- [3] 汤永清, 张新红, 陈虹微. 基于无参数监督核局部保持映射降维的故障诊断 [J]. 电子测量与仪器学报, 2019, 33 (7): 159-165.
TANG Y Q, ZHANG X H, CHEN H W, et al. Fault diagnosis based on parameter-less supervised kernel locality preserving projections for dimension reduction [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(7): 159-165.
- [4] 蒋爱国, 符培伦, 谷明, 等. 基于多模态堆叠自动编码器的感应电机故障诊断 [J]. 电子测量与仪器学报, 2018, 32 (8): 17-23.
JIANG AI G, FU P L, GU M, et al. Induction motor fault diagnosis based on multimodal stacked auto-encoder [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(8): 17-23.
- [5] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法 [J]. 仪器仪表学报, 2020, 41 (1): 195-205.
GONG W F, CHEN H, ZHANG M L, et al. Intelligent diagnosis method for incipient fault of motor bearing based on deep learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 195-205.
- [6] 贾朱植, 杨理践, 祝洪宇, 等. 基于高分辨率谱估计的早期转子断条故障诊断 [J]. 仪器仪表学报, 2017, 38 (2): 279-287.
JIA ZH ZH, YANG L J, ZHU H Y, et al. High-resolution spectral analysis for incipient broken rotor bar diagnosis [J]. Chinese Journal of Scientific Instrument, 2017, 38(2): 279-287.
- [7] 蔡文伟, 黄键, 李伟光, 等. 基于声音信号的微型电机故障诊断方法研究 [J]. 机床与液压, 2020, 48 (23): 190-195.
CAI W W, HUANG J, LI W G, et al. Research on fault diagnosis method for micro motor based on sound signal [J]. Machine Tool & Hydraulics, 2020, 48(23): 190-195.
- [8] LI Q C, DING X X, HE Q B, et al. Manifold sensing-based convolution sparse self-learning for defective bearing morphological feature extraction [J]. IEEE Transactions on Industrial Informatics, 2021, 17 (5): 3069-3078.
- [9] 石江波, 杨兆建, 郭伟杰, 等. 电流与振动信号融合的转子系统故障诊断研究 [J]. 机械设计与制造, 2018, 8: 19-21, 25.
SHI J B, YANG ZH J, GUO W J, et al. Study on the fault identification of rotor system with fusion of current and vibration signal [J]. Machinery Design & Manufacture, 2018, 8: 19-21, 25.
- [10] 袁媛, 方红彬, 殷忠敏. 基于多数据融合的电机故障诊断方法研究 [J]. 电气传动, 2021, 51 (9): 75-80.
YUAN Y, FANG H B, YIN ZH M. Research on motor fault diagnosis method based on multi data fusion [J]. Electric Drive, 2021, 51(9), 75-80.
- [11] WANG H Q, LI S, SONG L Y, et al. A novel convolutional neural network based fault recognition method via image fusion of multi-vibration-signals [J]. Computers in Industry, 2019, 105: 182-190.
- [12] CHEN Z Y, LI W H. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network [J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66 (7): 1693-1702.
- [13] 罗鹏, 胡葛庆, 程哲, 等. IPSW 方法及其在变工况滚动轴承退化状态跟踪中的应用 [J]. 仪器仪表学报, 2021, 42 (2): 33-44.
LUO P, HU N Q, CHENG ZH, et al. IPSW method and its application in the state tracking of rotating bearing degradation under variable working conditions [J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 33-44.
- [14] 林京, 赵明. 变转速下机械设备动态信号分析方法的回顾与展望 [J]. 中国科学:技术科学, 2015, 45: 669-686.
LIN J, ZHAO M. Dynamic signal analysis for speed-varying machinery: A review [J]. Science China

Technological Sciences, 2015, 45: 669-686.

- [15] LU S L, YAN R Q, LIU Y B, et al. Tachless speed estimation in order tracking: A review with application to rotating machine fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68 (7): 2315-2332.
- [16] 王文博, 马琳, 王永鹏, 等. 基于三次样条曲线插值的压力传感器温度补偿研究 [J]. 机电信息, 2020, 23: 33-35.
WANG W B, MA L, WANG Y P, et al. Temperature compensation of pressure sensor based on cubic spline interpolation [J]. Mechanical and Electrical Information, 2020, 23: 33-35.
- [17] WANG X X, LU S L, ZHANG S W. Rotating angle estimation for hybrid stepper motors with application to bearing fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69 (8): 5556-5568.
- [18] QIN Y, XIANG S, CHAI Y, et al. Macroscopic-microscopic attention in LSTM networks based on fusion features for gear remaining life prediction [J]. IEEE Transactions on Industrial Electronics, 2020, 67 (12): 10865-10875.
- [19] YANG W S, YAO Q F, YE K J, et al. Empirical mode decomposition and temporal convolutional networks for remaining useful life estimation [J]. International Journal of Parallel Programming, 2019, 48 (1): 61-79.
- [20] NIE X Y, XIE G. A novel framework using gated recurrent unit for fault diagnosis of rotary machinery with noisy labels [J]. Measurement Science and Technology, 2021, 32 (5): 055107.

作者简介




王骁贤, 2010年于山东科技大学获得学士学位, 2013年于中国科学技术大学获得硕士学位, 现为安徽大学工程师, 同时在中国科学技术大学攻读博士学位, 主要研究方向机电系统多维信息感知及智能运维。

E-mail: wx612@mail.ustc.edu.cn

Wang Xiaoxian received her B. Sc. degree from Shandong University of Science and Technology in 2010, and received her

M. Sc. degree from University of Science and Technology of China (USTC) in 2013. She is currently an engineer at Anhui University, and she is also a Ph. D. candidate at USTC. Her main research interests include multi-dimensional information sensing and intelligent maintenance of electromechanical system.



陆思良(通信作者), 分别在2010年和2015年于中国科学技术大学获得学士学位和博士学位, 现为安徽大学副教授, 主要研究方向为机电系统状态监测与故障诊断, 工业自动化和机器人。

E-mail: lusliang@mail.ustc.edu.cn

Lu Siliang (Corresponding author) received his B. Sc. degree and Ph. D. degree both from USTC in 2010 and 2015, respectively. He is currently an associate professor at Anhui University. His main research interests include electromechanical system condition monitoring and fault diagnosis, industrial automation and robotics.



何清波, 分别在2002年和2007年于中国科学技术大学获得学士学位和博士学位, 现为上海交通大学教授, 博士生导师, 主要研究方向为机电系统状态监测与故障诊断, 智能结构和材料等。

E-mail: qbhe@sjtu.edu.cn

He Qingbo received his B. Sc. degree and Ph. D. degree both from USTC in 2002 and 2007, respectively. He is currently a professor and a Ph. D. advisor at Shanghai Jiao Tong University. His main research interests include electromechanical system condition monitoring and fault diagnosis, smart structures and materials.



张世武, 分别在1997年和2003年于中国科学技术大学获得学士学位和博士学位, 现为中国科学技术大学教授, 博士生导师, 主要研究方向为精密仪器、智能材料、机器人等。

E-mail: swzhang@ustc.edu.cn

Zhang Shiwu received his B. Sc. degree and Ph. D. degree both from USTC in 1997 and 2003, respectively. He is currently a professor and a Ph. D. advisor at USTC. His main research interests include precision instrumentation, smart materials, and robotics.