

控制与决策

Control and Decision

一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络

姚家琪, 荆华, 赵春晖

引用本文:

姚家琪, 荆华, 赵春晖. 一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络[J]. *控制与决策*, 2023, 38(7): 1918–1926.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1851>

您可能感兴趣的其他文章

Articles you may be interested in

[基于改进的胶囊网络的行星齿轮箱故障诊断方法](#)

Fault diagnosis method of planetary gearbox based on enhanced capsule network
控制与决策. 2023, 38(3): 661–669 <https://doi.org/10.13195/j.kzyjc.2021.1440>

[基于改进SSA优化MDS-SVM的变压器故障诊断方法](#)

Transformer fault diagnosis method based on improved SSA optimized MDS-SVM
控制与决策. 2023, 38(2): 459–467 <https://doi.org/10.13195/j.kzyjc.2021.1437>

[基于径向基神经网络的新型齿轮故障诊断方法](#)

Novel gear fault diagnosis method based on RBF neural network
控制与决策. 2022, 37(2): 409–416 <https://doi.org/10.13195/j.kzyjc.2020.0836>

[基于W-DenseNet的减压阀不平衡样本故障诊断模型](#)

W-DenseNet-based fault diagnosis model of pressure-reducing valve with unbalanced samples
控制与决策. 2022, 37(6): 1513–1520 <https://doi.org/10.13195/j.kzyjc.2020.1708>

[基于多标签学习的旋转机械分级复合故障诊断](#)

Hierarchical compound fault diagnosis of rotating machinery based on multi-label learning
控制与决策. 2022, 37(7): 1772–1778 <https://doi.org/10.13195/j.kzyjc.2021.0067>

一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络

姚家琪, 荆华, 赵春晖[†]

(浙江大学控制科学与工程学院, 杭州 310027)

摘要: 旋转机械设备是工业生产中的关键性设备, 对其进行高效故障诊断, 对于保障工业安全生产具有重要意义. 传统的旋转机械设备智能故障诊断方法采取人工特征提取策略, 存在依赖专家经验知识、特征泛化性差、特征完备性不足等局限性, 导致故障诊断模型精度差, 特别是在噪声环境下性能下降明显. 对此, 提出一种用于旋转机械故障诊断的多模态耦合输入神经网络模型. 首先, 利用信号分解方法将原始输入信号分解为多个子信号, 并将子信号与原始信号成对组成二维矩阵并输入到神经网络中, 使得网络能够提取其间重要的相关特征; 然后, 利用双通道并行的卷积神经网络和长短期记忆网络分别提取信号中的时空间特征并融合, 大大提高网络模型的特征表达完备性, 实现对旋转机械设备的高精度故障分类. 通过实验验证了所提出模型相较于传统故障模型具有更高的准确率, 并且对于噪声干扰也有较好的适应性.

关键词: 旋转机械; 故障诊断; 深度学习; 时空特征融合; 多模态; 抗噪声

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1851

引用格式: 姚家琪, 荆华, 赵春晖. 一种面向噪声环境中旋转机械故障诊断的多模态耦合输入神经网络[J]. 控制与决策, 2023, 38(7): 1918-1926.

A multimode coupled input neural network for rotating machinery fault diagnosis in noisy environment

YAO Jia-qi, JING Hua, ZHAO Chun-hui[†]

(College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: Rotating machinery equipment is the key equipment in industrial production, which is of great significance to carry out efficient fault diagnosis for industrial safety production. The traditional intelligent fault diagnosis method of rotating machinery adopts the strategy of artificial feature extraction, which has the limitations of relying on expert experience knowledge, poor feature generalization and insufficient feature completeness, leading to poor precision of the fault diagnosis model, especially in the noisy environment. To solve the above problems, a multimode coupled input neural network model for rotating machinery fault diagnosis is proposed. Firstly, the raw input signal is decomposed into several sub-signals using the signal decomposition method, and the sub-signals are paired with the raw signal to form a two-dimensional matrix and input into the network, so that the network can extract important related features between the raw signal and sub-signals. In addition, the two-channel parallel convolutional neural network and long and short-term memory network are used to extract and fuse the time-space features of signals, which greatly improves the feature expression completeness of the network model and realizes the high-precision fault classification of rotating machinery. The results of the experiments show that the proposed model has higher accuracy and better adaptability to noise disturbance than traditional fault models.

Keywords: rotating machinery; fault diagnosis; deep learning; spatio-temporal feature fusion; multimode; anti-noise

0 引言

旋转机械设备在能源、化工、交通运输、航空航天等多个领域都有着重要的应用, 是现代工业中最常

见、最重要的设备之一^[1]. 随着工业水平的提高, 旋转机械设备正向大型化、精密化、高速化、复杂化以及自动化的方向发展, 这给机械设备持续安全平稳运行

收稿日期: 2021-10-28; 录用日期: 2022-03-15.

基金项目: 国家杰出青年科学基金项目(62125306); 国家自然科学基金重点项目(62133003); 工业控制技术国家重点实验室自主课题(ICT2021A15); 中央高校基本科研业务费专项资金项目(浙江大学 NGICS 大平台).

责任编辑: 姜斌.

[†]通讯作者. E-mail: chhzhao@zju.edu.cn.

带来了挑战.在实际工业生产过程中,旋转机械设备经常工作在高负载、高温、腐蚀等极端恶劣环境下,同时由于机械结构复杂、工况多变,旋转机械设备中的部件如轴承、齿轮或叶片等极易产生故障^[2].由于机械设备间存在着强耦合性,一些微小的故障也可能产生连锁反应而导致整个生产系统的瘫痪,轻则影响生产效率与产品质量,重则造成巨大的经济财产损失或人员伤亡^[3].因此,如何对旋转机械进行高效的故障诊断,及时发现并定位设备中存在的故障,减少经济损失与运维成本,避免重大生产事故的发生具有重大的研究意义.

传统的旋转机械故障诊断方法利用时频分析技术,如傅里叶变换、小波变换、希尔伯特-黄变换等^[4-6],对旋转机械表面产生的振动信号进行处理,通过观察处理结果判断是否有故障产生或识别出故障的类型与位置.这类故障诊断方法过于依赖专家经验知识,人力成本巨大且实时性较差.近年来,随着机器学习理论的发展,研究人员致力于探索一种智能化的故障诊断与状态监测方法,即从传感器数据中挖掘异常信息,构建传感器数据与设备健康状态间的关系模型,实现对设备健康状态的自动监测或故障识别与定位^[7].此类方法在大量工业场景中得到了成功的应用,例如非平稳变工况运行条件下的设备智能监测^[8-9]以及故障样本缺失情况下的零样本故障诊断^[10].

基于机器学习的旋转机械智能故障诊断主要包括特征提取和故障识别两个环节.其中,特征提取是进行旋转机械设备智能故障诊断的关键性环节,这一环节对故障诊断效果的影响远大于故障诊断模型本身.在传统智能故障诊断方法中,往往采取人工特征提取的方式,即依据机器运作机理设计精细化的特征提取策略,然而这种特征提取方式过于依赖设计者的专业知识,设计成本巨大,也难以应对当下工业环境中时刻产生的海量数据^[11].

近年来,深度学习方法逐渐被运用到旋转机械智能故障诊断中^[12].深度学习方法能够自动地挖掘信号中的故障信息,从而提取出有用的特征,克服了上述人工特征提取的局限性.Ince等^[13]利用一维卷积神经网络自动地对电机振动信号进行特征提取与故障分类,省去了人工手动构建特征的过程,提高了故障诊断的效率,准确率超过97%.Qi等^[14]提出了一种基于稀疏堆叠自编码器的旋转机械故障诊断模型,提取到了旋转机械表面振动信号中更有鉴别性的高级特征,使智能故障诊断模型具有更好的性能.Jiang

等^[15]提出了一种用于风力发电机齿轮箱故障诊断的多尺度卷积神经网络,利用多尺度卷积学习原始振动信号中不同尺度的特征,进一步提高了模型的特征提取能力并增强了模型的准确率.但是,目前关于深度学习方法进行智能故障诊断的方法中,大多围绕某种单一的神经网络结构展开,或将传感器数据以某种单一的形式作为输入,使得数据信息未被充分提取,从而导致故障诊断模型特征表达不够完备,难以发挥分类器的最大性能,最终模型的精度损失较大,尤其在噪声环境下性能下降明显.

本文提出一种多模态耦合输入神经网络模型,并将其应用于基于振动信号的旋转机械智能故障诊断.所提出的模型利用双通道并行的卷积神经网络与长短期记忆网络同步提取振动信号中的时空间特征并进行融合,同时从改进神经网络输入数据的角度出发,提出将原始信号与经过信号分解方法分解得到的子信号组合成多模态耦合输入的形式,该输入形式使得神经网络能够充分利用神经网络提取信号各自的特征以及信号间的相关特征,提高模型特征表达的完备性,从而提升故障诊断的精度,对环境噪声影响也有更好的适应性.

本文的主要贡献如下:

1) 将原始振动信号及其子信号成对组合作为神经网络输入,使神经网络在提取振动信号及其子信号各自内部特征的同时,也提取包含有信号间的相关关系的重要特征来进行故障诊断,进一步提高模型对于振动信号故障特征表达的完备性,提升了基于振动信号的旋转机械故障诊断精度与对噪声的适应能力;

2) 考虑到振动信号中存在的时空间特性,设计一种CNN-LSTM并行特征提取与融合结构,融合了由CNN提取得到的局部空间相关特征与LSTM提取得到的时间相关特征,使模型充分挖掘振动信号中包含的旋转机械故障信息.

1 相关知识

1.1 卷积神经网络

卷积神经网络(convolutional neural network, CNN)一般包括卷积层、池化层、激活层及全连接层.其中:卷积层通过卷积运算对输入数据进行特征提取,卷积后通过激活层的激活函数实现非线性变换;池化层利用预先设定的池化函数实现特征选择与信息过滤,也在一定程度上防止过拟合;而全连接层则负责将卷积层和池化层产生的特征进行非线性组合,得到最终的特征向量.

1.2 长短期记忆网络

长短期记忆网络是循环神经网络 (recurrent neural network, RNN) 的变种, RNN 是一种常用于处理时间序列数据的神经网络^[16], 区别于卷积神经网络, 循环神经网络具有记忆性, 其输出将会受到所有历史输入的影响, 因此, 能够有效提取时间序列中的时序相关特征. 当时间序列长度较大时, RNN 容易出现梯度消失或梯度爆炸问题, 对神经网络训练造成了巨大的困难, 对此, Hochreiter 等^[17] 于 1997 年提出了长短期记忆网络 (long short-term memory networks, LSTM), 并解决了长程依赖问题. LSTM 是一种基于 RNN 的门控算法, 其网络结构与经典 RNN 类似, 区别在于在一个长短期记忆网络单元中有 3 个门控, 分别为记忆门、遗忘门和输出门. 其中: 记忆门负责保留历史有用信息, 遗忘门负责丢弃无用信息, 最后由输出门实现特征的输出. 其计算过程可由下述公式表示:

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

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \quad (2)$$

$$C_t = \tanh(W_C[h_{t-1}, x_t] + b_C), \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * C_t, \quad (4)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o), \quad (5)$$

$$h_t = o_t * \tanh(C_t). \quad (6)$$

2 所提出的 MCINN 网络

本节介绍所提出多模态耦合输入神经网络 (multimode coupled input neural network, MCINN) 模型. 首先, 从两个方面, 即多模态耦合数据输入和时空特征提取与融合网络结构进行介绍; 然后, 对 MCINN 网络进行详细阐述, 包括模型结构、训练过程以及在线应用过程.

2.1 多模态耦合输入结构

在人工提取到的振动信号特征中, 互信息和相关系数是智能故障诊断模型在进行故障识别时利用到的关键特征^[18], 分别表征了原始信号和分解得到的固有模态函数 (intrinsic oscillatory modes, IMFs) 间的非线性与线性相关关系. 此处固有模态函数即为经过信号分解方法得到的子信号. 当故障发生时, 信号间的相关关系将发生改变, 所以能从中挖掘重要的故障信息.

现有利用深度学习进行旋转机械故障诊断的方法中, 或者直接将原始信号作为模型的输入, 或者将处理后的信号作为模型输入, 例如文献^[19-21] 利用

一些信号处理方法对信号进行预处理, 使神经网络能够提取到更加细节的特征, 从而提升神经网络模型的故障诊断性能. 但是, 单一地采用此两种输入形式作为输入都会导致原始信号与处理后信号间较为重要的相关特征难以被模型提取, 即模型的特征表达不完备.

针对以上问题, 本文设计一种多模态耦合输入结构, 将输入信号分解为多个模态后与原始信号成对拼接为二维矩阵作为输入, 下面对信号分解方法和输入结构进行具体介绍.

2.1.1 旋转机械振动信号分解

要将旋转机械的振动信号转化成多模态耦合输入, 首先需要将振动信号 x 分解为 N 个固有模态函数 $x_{\text{imf}}^1, x_{\text{imf}}^2, \dots, x_{\text{imf}}^N$, 这一步通过经验小波变换 (empirical wavelet transform, EWT) 方法^[22] 实现, 这是一种建立在小波变换框架上的自适应信号分解方法, 能够将信号自适应地分解为指定个数的固有模态函数, 相对于经典的信号分解方法——经验模态分解, 经验小波变换在小波变换理论框架下建立, 具有理论支撑性强、计算量小等优势.

EWT 首先将信号的傅里叶频谱规范化至 $[0, \pi]$, 再对信号的傅里叶频谱进行分割, 将傅里叶频谱分为 N 个连续片段, N 即为要分解得到的固有模态函数的数量. 要将傅里叶频谱分割为 N 个连续片段, 就需要 $N - 1$ 条边界线, 定义信号的傅里叶频谱相邻局部最大值点间的中点 ω_n 作为边界线, 其中 $\omega_0 = 0, \omega_N = \pi$, 即 0 与 N 分别作为第 1 条和最后一条边界线.

按照确定的边界线对信号的傅里叶频谱进行分割, 得到 N 个连续片段, 其区间可以表示为

$$A_n = [\omega_{n-1}, \omega_n], \quad n = 1, 2, \dots, N. \quad (7)$$

以 ω_n 为中心, 定义宽度为 $2\tau_n$ 的过渡段 T_n , 其中 $\tau_n = \gamma\omega_n$. 在对信号的傅里叶频谱进行分割后即可构建经验小波, 包括经验尺度函数和经验小波函数, 构造方法参照 Meyer 小波^[23] 的构造方法, 其公式如下所示:

$$\hat{\varphi}(\omega) = \begin{cases} 1, & |\omega| \leq \omega_n - \tau_n; \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\tau_n} (|\omega| - \omega_n + \tau_n) \right) \right], & \omega_n - \tau_n \leq |\omega| \leq \omega_n + \tau_n; \\ 0, & \text{otherwise.} \end{cases} \quad (8)$$

$$\hat{\psi}(\omega) = \begin{cases} 1, & \omega_n + \tau_n \leq |\omega| \leq \omega_{n+1} - \tau_{n+1}; \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\tau_n} (|\omega| - \omega_n + \tau_n) \right) \right], & \omega_{n+1} - \tau_{n+1} \leq |\omega| \leq \omega_n + \tau_n; \\ \sin \left[\frac{\pi}{2} \beta \left(\frac{1}{2\tau_n} (|\omega| - \omega_n + \tau_n) \right) \right], & \omega_n - \tau_n \leq |\omega| \leq \omega_{n+1} + \tau_{n+1}; \\ 0, & \text{otherwise.} \end{cases} \quad (9)$$

其中: γ 需要满足 $0 < \gamma < \min_n \left[\frac{(\omega_{n+1} - \omega_n)}{(\omega_{n+1} + \omega_n)} \right]$, 而 $\beta(x) = x^4(35 - 84x + 70x^2 + 20x^3)$.

之后便可参照传统小波变换的方法进行经验小波变换,其中细节系数和近似系数分别由下式定义:

$$\omega_f^\varepsilon(n, t) = \langle f, \psi_n \rangle = \int f(\tau) \overline{\psi_n(\tau - t)} d\tau = (\hat{f}(\omega) \hat{\psi}_n(\omega))^\nu, \quad (10)$$

$$\omega_f^\varepsilon(0, t) = \langle f, \varphi_1 \rangle = \int f(\tau) \overline{\varphi_1(\tau - t)} d\tau = (\hat{f}(\omega) \hat{\varphi}_1(\omega))^\nu. \quad (11)$$

利用下式可以得到固有模态函数 x_{imf}^k :

$$x_{\text{imf}}^k(t) = \omega_f^\varepsilon(k, t) * \psi_k(t). \quad (12)$$

其中: $*$ 为卷积运算, γ 为可调节的系数.

2.1.2 多模态耦合输入

多模态耦合输入结构,主要由原始信号 \mathbf{x} 与 N 个固有模态函数 $\mathbf{x}_{\text{imf}}^1, \mathbf{x}_{\text{imf}}^2, \dots, \mathbf{x}_{\text{imf}}^N$ 组成. 其中,固有模态函数利用前述的经验小波变换对原始信号进行分解得到. 所设计的信号输入结构中,将原始信号与所分解得到的固有模态函数分别成对组合,形成二维输入矩阵 \mathbf{X} ,具体结构如图1所示.




图1 多模态耦合输入结构图

2.2 时空特征提取与融合神经网络

基于一维卷积神经网络的旋转机械智能故障诊断模型能够有效地进行故障诊断,但是,振动信号属于时间序列数据,仅采用卷积神经网络对振动信号进行特征提取将会忽略其中重要的时间信息,对故障定位造成了一定的困难. 因此,本文提出一种双通道并行的时空特征融合网络结构,利用长短期记忆网络提

取振动信号中的时序特征并与卷积神经网络所提取到的局部空间特征进行融合,进一步提升故障诊断的准确率.

所提出的时空特征提取与融合神经网络结构如图2所示. 其中卷积神经网络方面由5个一维卷积模块组成,每个一维卷积模块包括一个卷积层、一个池化层和一个激活层. 为了提高训练速度与解决训练过程中协变量偏移的问题,在激活层前设置一个批归一化层. 其中第1个一维卷积层的卷积核宽度较大,这样能够更好地提取信号中的短时特征^[24],所采用的激活函数为ReLU. 长短期记忆网络方面由两层LSTM单元组成,其隐藏状态个数设置为128. 当双通道完成特征提取后,将双通道中提取到的特征进行拼接,利用全连接层进行特征融合.

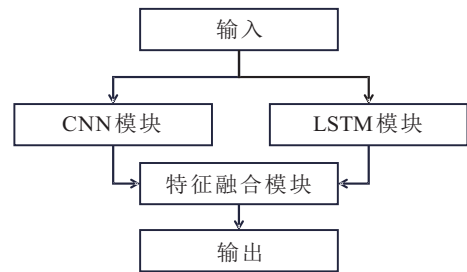


图2 时空特征提取与融合神经网络结构简图

2.3 多模态耦合输入神经网络

多模态耦合输入神经网络 (multimode coupled input neural network, MCINN) 主要包括多模态耦合输入层、特征提取层、特征融合层和输出层,如图3所示.

图3中,多模态耦合输入层负责将输入数据重构为2.1.2节中所述多模态耦合输入结构. 该层首先对输入的旋转机械振动信号 \mathbf{x} 进行经验小波变换分解; 然后,将输入信号 \mathbf{x} 及其分解子信号 $\mathbf{x}_{\text{imf}}^1, \mathbf{x}_{\text{imf}}^2, \dots, \mathbf{x}_{\text{imf}}^N$ 重组为 $2N \times L$ 的输入矩阵 \mathbf{X} . 其中: N 为分解模态数, L 为信号长度.

特征提取层采用2.2节所述的时空特征提取结构,包括卷积神经网络模块和长短期记忆网络模块两大模块,分别提取局部空间特征和时序相关特征. 其中卷积神经网络模块的前两个一维卷积模块需要针对所设计的多模态耦合输入结构作调整.

由于将输入数据处理为二维形式,在卷积神经网络方面,第1层卷积核将使用二维卷积核,并且形状为长方形,如图4所示. 该卷积核是尺寸为 64×2 的长方形卷积核,且在信号排列方向上跨行滑动,以在一个卷积层中每次卷积运算都对原始信号与其子信号进行成对地特征提取,而池化层则仅进行沿行方向进行窗口宽度为2的最大池化.

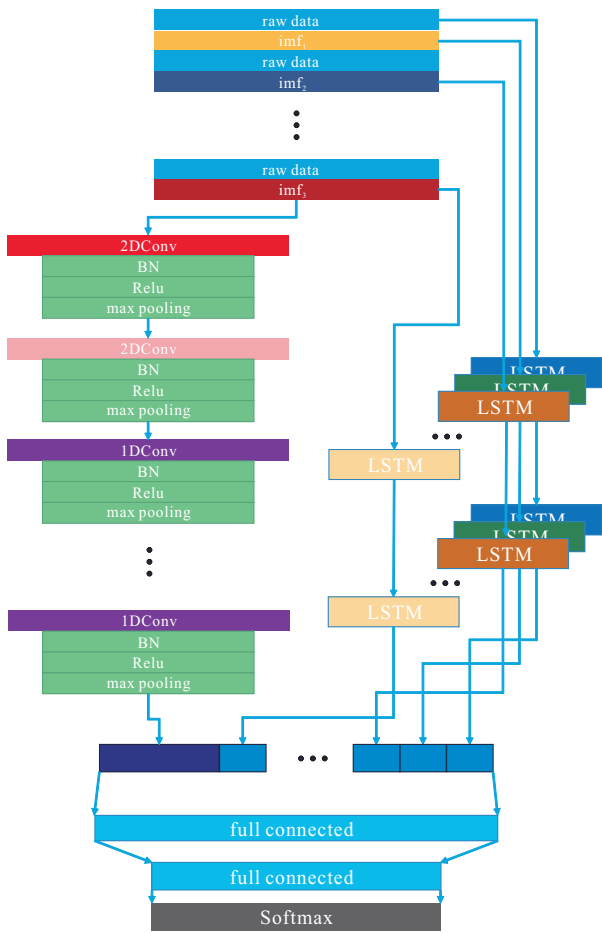


图3 多模态耦合输入神经网络结构示意图

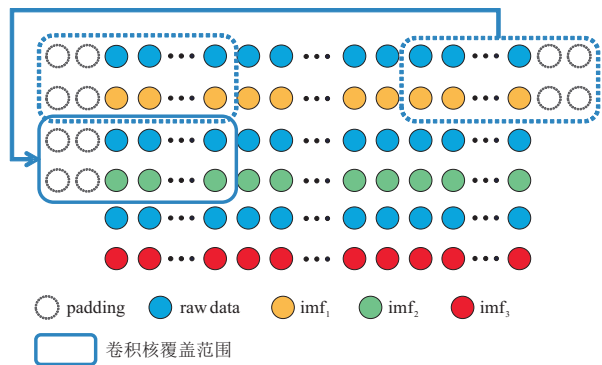


图4 MCINN第1层卷积示意图

经过第1轮的卷积、激活与池化后,假设第1轮卷积的输出通道数为 C_1 ,则将得到 C_1 个行数为3的二维特征输出;接着,在第2个卷积层中利用尺寸为 $N * 3$ 的卷积核继续提取深层特征,如图5所示.经过该轮卷积运算后,将得到 C_2 个一维特征, C_2 为第2轮提取到的特征数.后续继续利用一维卷积层提取抽象层级更高的特征,并将其展平获得一维的空间特征向量 $\mathbf{v}_{\text{spatio}}$.

长短期记忆网络中,有 $N + 1$ 组双层长短期记忆网络单元,分别接受一个原始信号 \mathbf{x} 与 N 个子信号 $\mathbf{x}_{\text{imf}_1}^1, \mathbf{x}_{\text{imf}_1}^2, \dots, \mathbf{x}_{\text{imf}_1}^N$ 作为输入,提取其各自的时序




图5 MCINN第2层卷积示意图

特征,获得时序特征向量 $\mathbf{v}_{\text{temporal}}$.

特征融合层将所提取得到的空间与时序特征向量拼接后,使用全连接层进行特征融合,并输出最终用于分类的特征向量 $\mathbf{v}_{\text{fusion}}$.

输出层接受上述特征融合层输出的特征向量 $\mathbf{v}_{\text{fusion}}$,引入Softmax函数预测输入样本属于各个状态的概率,将概率值最大的所属状态作为故障诊断结果.

2.4 训练过程

首先,采集旋转机械设备在正常以及各个故障状态下的原始振动信号并对其进行处理,制作成原始数据集 $D = \{\mathbf{x}_i, y_i\}_{i=0}^n$.其中: n 为样本数; y_i 为第 i 个样本的标签且 $y_i \in \{0, 1, \dots, k - 1\}$,即共有 k 种健康状态,包括正常与 $k - 1$ 种故障状态.每个样本长度为 L ,即采样点数.对每个样本都进行规范化处理,规范化方法采用最大-最小值规范化法,其公式如下:

$$\tilde{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

然后,对原始数据集中的每个样本进行经验小波变换,获得其分解子信号 $\mathbf{x}_{\text{imf}_1}^1, \mathbf{x}_{\text{imf}_1}^2, \dots, \mathbf{x}_{\text{imf}_1}^N$.其中: i 为样本序号, N 为分解子信号的数量.分解完成后,将原始信号与分解子信号分别重组为输入矩阵,制作为训练集 $T = \{\mathbf{X}_i, y_i\}_i^n$.

获得训练集后,将其随机分为多个小批次(mini-batch),再利用反向传播法对MCINN进行训练.其中,采用Adam作为优化算法,而损失函数则采用交叉熵,其计算公式为

$$\text{Loss} = -\frac{1}{M} \sum_{i=1}^M \sum_{j=1}^N y_{ji} \log(\hat{y}_{ji}) \quad (14)$$

其中: M 为一个mini-batch中的样本数量; N 为类别数; y 表示该样本是否属于该类别,若属于则为1,不属于则为0; \hat{y} 为模型预测该样本属于该类的概率.

需要注意的是,在实际应用故障诊断模型时,输入信号难以保证其相位一致,为了使MCINN学习到与位移无关的特征,必须使最后一个池化层的神经元在输入信号中的感受野大小 R 至少大于一个设备

旋转周期 T ,以保证输出特征内包含有足够的故障信息.因此, L 的选取由传感器采样率 r 、旋转设备的转频 ν 以及网络最后一层感受野大小 R 共同决定,一般要求

$$T \leq R \leq L. \quad (15)$$

其中信号周期 T 由下式计算得到:

$$T = \frac{r}{\nu}. \quad (16)$$

而分解子信号个数 N 一般取值为3,这样就能够较好地包含故障信息的同时降低模型训练与推理时间.

2.5 在线应用

当模型训练完成后,便可在线输入由传感器获取到的振动信号以进行故障识别.其应用过程如图6所示.该应用过程可以分为如下几个步骤.

step 1: 每接收到 L 个数据点即作为一个样本,这个样本称为原始振动信号 x ,经规范化后得到 \tilde{x} ,利用EWT对 \tilde{x} 进行分解,得到 N 个固有模态函数,分别为 $x_{imf}^1, x_{imf}^2, \dots, x_{imf}^N$;

step 2: 将 \tilde{x} 与其分解子信号按照多模态耦合输入结构进行重构,形成 $2N \times L$ 的输入矩阵 X ;

step 3: 将输入矩阵 X 输入至训练好的MCINN进行特征提取与故障识别;

step 4: 模型输出故障诊断结果.

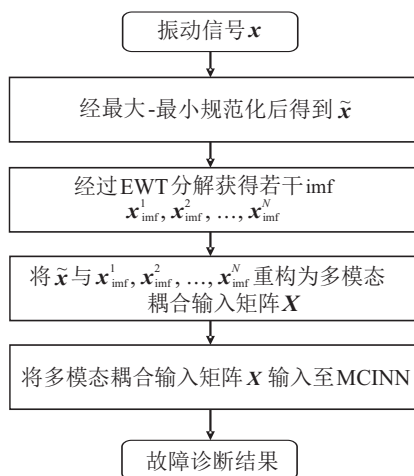


图6 多模态耦合输入神经网络故障诊断模型在线应用流程

3 实验

滚动轴承是旋转机械中常见的关键部件,本节将以滚动轴承故障诊断为例,验证本文所提出方法的有效性.

3.1 数据介绍

本文所使用的数据集为凯斯西储大学(Case Western Reserve University, CWRU)滚动轴承数据中心开源的滚动轴承故障数据集,简称为CWRU数据

集. CWRU滚动轴承数据中心通过对测试台上的滚动轴承施加电火花进行故障植入,分别在滚动轴承的内圈、外圈以及滚动体表面施加了损伤,损伤直径包括0.007 inch、0.014 inch和0.021 inch.其振动信号数据由加速度计采集自测试台轴承的驱动端,数据采样频率为12 kHz,受损轴承型号为SKF6205,采集数据时测试台的工作载荷为0 HP,测试台外形见图7.




图7 CWRU滚动轴承中心测试台

3.2 数据预处理

CWRU数据集仅提供了由加速度计采集到的原始数据,需要对数据进行一定的预处理,按照2.4节所述的处理策略将其转换成适于神经网络训练与测试的样本.

根据设备转频和传感器采样速率计算可知,该批振动信号的周期约为400个采样点对应的时长,为了满足式(15)的要求,将单个原始样本的长度确定为2048个数据点,分解子信号的数量 N 确定为3.为了获取到足够多的训练样本,制作训练集时采用重叠滑窗采样的方式对原始数据集进行分割,即采用滑窗的形式对原始信号进行采样,并且采样时允许样本之间有部分重叠,而制作测试集则不采用重叠采样,以避免信息泄露.

本文所使用的数据可分为正常与9种故障类别,共10种类别,每个类别制作750个训练样本和250个测试样本,最终训练集有7500个样本,测试集有2500个样本,如表1所示.

表1 故障样本描述及其标签

类别	样本数	标签
滚动体损伤 直径0.007 inch	750/250	0
滚动体损伤 直径0.014 inch	750/250	1
滚动体损伤 直径0.021 inch	750/250	2
内环损伤 直径0.007 inch	750/250	3
内环损伤 直径0.014 inch	750/250	4
内环损伤 直径0.021 inch	750/250	5
外环损伤 直径0.007 inch	750/250	6
外环损伤 直径0.014 inch	750/250	7
外环损伤 直径0.021 inch	750/250	8
正常	750/250	9

3.3 实验设计

在本次实验中,神经网络训练迭代次数设置为20,用于训练神经网络的小批量数据集样本数量(mini-batch size)设置为128,训练集样本顺序在输入进神经网络前被随机打乱.用于对比实验的模型选择WDCNN^[24]、XGBoost^[25]、SVM^[26]和KNN^[27].其中:WDCNN是一种用于旋转机械故障诊断的端到端卷积神经网络模型,而XGBoost、SVM和KNN是传统的机器学习分类模型.将本文所提出模型的性能与这些模型进行对比以验证所提出模型的有效性和优越性.

用于训练XGBoost、SVM和KNN模型所构建的特征如表2所示,此处所用到的特征均为利用振动信号对旋转机械进行故障诊断时的常用特征,同时WDCNN的输入为仅经过归一化处理的原始振动信号,令其自动提取特征.

表2 人工构建特征表

名称	公式
平均离差	$\frac{1}{n} \sum_{i=1}^n x_i $
方差	$\frac{1}{n} \sum_{i=1}^n (x_i - x)^2$
峰值	$\max(x_i)$
裕度因子	$\max(x_i) / \left(\frac{1}{n} \sum_{i=1}^n \sqrt{x_i^2} \right)^2$
峰度	$\frac{1}{n} \sum_{i=1}^n x_i^4$
峰值因子	$\max(x_i) / \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$
均方根	$\sqrt{\frac{\sum_{i=1}^n x_i^2}{n}}$
脉冲因子	$\max(x_i) / \sqrt{\frac{1}{n} \sum_{i=1}^n x_i }$
偏度	$\frac{1}{n} \sum_{i=1}^n x_i^3$
形状因子	$\sqrt{\frac{\frac{1}{n} \sum_{i=1}^n x_i^2}{\frac{1}{n} \sum_{i=1}^n x_i }}$

将故障分类准确率作为用于评估模型性能指标,其定义如下式所示:

$$\text{accuracy} = \frac{\text{分类正确样本数}}{\text{测试样本总数}} \times 100\%. \quad (17)$$

在实际工业生产环境中,采集到的数据往往混杂着大量无法避免的噪声,这就要求故障诊断模型具有一定的抗噪能力^[28].由于工业生产环境下的噪声类型与噪声强度是快速变化的,很难为含噪数据标注相应的噪声标签^[29].为了尽可能贴近真实应用场景,在抗噪能力测试环节,模型仍然由原数据训练得到,而


对测试集加入不同强度的加性高斯白噪声,以测试模型在受不同强度噪声影响下的性能.

本文将信噪比作为衡量噪声强度水平的指标,其表达式为


$$\text{SNR}_{\text{dB}} = 10 \log_{10} \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right). \quad (18)$$

其中: P_{signal} 为纯净信号的有效功率,此处将原信号视作纯净信号; P_{noise} 为噪声的有效功率.

图8为原始信号与加噪信号的时域可视化对比,其中含噪信号的信噪比为 -4 dB .可以看出,原始信号的故障特征完全淹没于噪声之中,噪声对模型特征提取造成了较大的挑战.



(a) 原始振动信号时域可视化图



(b) 加噪振动信号时域可视化图

图8 原始振动信号与加噪振动信号时域可视化对比

3.4 实验结果

在不对测试集加入噪声的情况下对训练好的各种模型进行测试,其实验结果如表3所示.

表3 各模型旋转机械故障诊断准确率(无噪声)

方法	准确率/%
MCINN	99.96
WDCNN	99.64
XGBoost	96.04
SVM	92.84
KNN	95.12

由表3可以看到,所提出模型的准确率大幅超过基于XGBoost等传统机器学习模型的故障诊断方法,其诊断精度接近100%.

对加入不同强度噪声的测试集的实验结果如图9所示,在强噪声影响下,人工提取的特征由于其缺乏泛化性,使得XGBoost等传统机器学习模型的故障相




图9 MCINN在不同噪声水平下与其他算法准确率对比

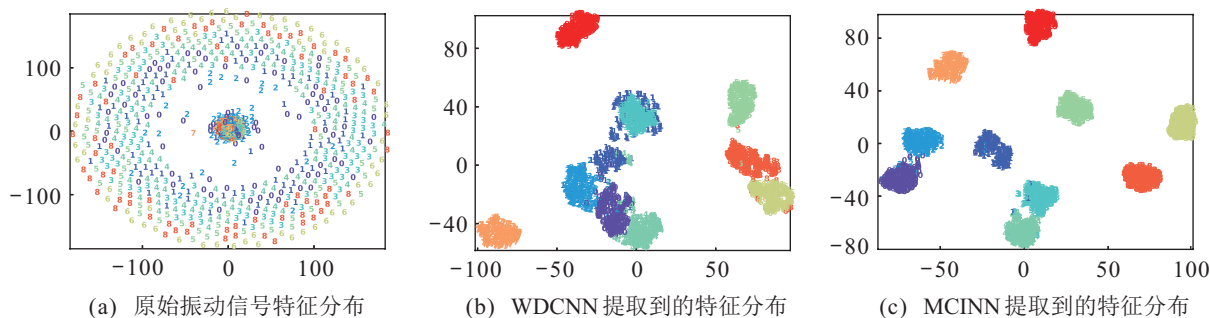


图10 原始振动信号特征分布与两种神经网络提取到的特征分布降维可视化图

通过观察图10可以发现,由于噪声的影响,信号的原始特征分布非常混乱,很难直接通过分类器进行分类,而本文所提出的神经网络相较于一般的仅有原始信号输入的WDCNN明显能够更好地提取特征。MCINN所提取到的同一个类别的特征分布较为紧凑,而不同类别的特征分布比较分散,便于分类器进行故障分类,从而也验证了所提出模型在强噪声环境下故障诊断的有效性。

4 结论

针对应用传统机器学习方法进行旋转机械设备智能故障诊断时依赖专家经验知识、特征泛化性差以及特征提取不完备等问题,本文提出了一种用于旋转机械故障诊断的多模态耦合输入神经网络(multimode coupled input neural network, MCINN)模型。该模型从输入数据的角度考虑,通过改进数据输入的方式提升模型特征表达的完备性,同时利用卷积神经网络与长短期记忆神经网络自动提取振动信号中重要的空间局部特征和时序特征并融合,从而使模型拥有较高的故障诊断精度。本文利用CWRU滚动轴承故障数据集验证了所提出方法提取到的特征分布更适于故障识别,相对于传统智能故障诊断方法,具有高达99.96%的准确率,故障诊断精度提升明显,并且对环境中的噪声影响也具有更好的适应性,在-4 dB的强噪声环境中准确率达到78.68%。未来

较于在无噪声环境下大幅降低,难以满足实际生产需求。而本文所提出的模型能够更加完备地提取信号中的重要特征,因此,其在-4 dB信噪比的强噪声环境中,准确率达到78.68%,接近80%,较WDCNN模型也有大幅的提升。

为了验证所提出方法对于智能故障诊断模型特征表达效果,利用t-SNE方法对信号的原始特征分布以及神经网络提取到的特征进行降维并可视化,所使用的测试集为信噪比为-4 dB的含噪声信号测试集,其可视化结果如图10所示,图中数字为故障标签。

工作将考虑引入迁移学习等方法,针对变工况下的旋转机械故障诊断问题进行进一步的研究。

参考文献(References)

- [1] 冯志鹏, 宋希庚, 薛冬新, 等. 旋转机械振动故障诊断理论与技术进展综述[J]. 振动与冲击, 2001, 20(4): 36-39.
(Feng Z P, Song X G, Xue D X, et al. Survey of vibration fault diagnosis of rotational machinery[J]. Journal of Vibration and Shock, 2001, 20(4): 36-39.)
- [2] 张志强, 杨清宇. 一种用于机械故障特征提取的多尺度稀疏滤波网络[J]. 控制与决策, 2022, 37(5): 1267-1278.
(Zhang Z Q, Yang Q Y. A multi-scale sparse filtering network for fault feature extraction of machinery[J]. Control and Decision, 2022, 37(5): 1267-1278.)
- [3] 王国彪, 何正嘉, 陈雪峰, 等. 机械故障诊断基础研究“何去何从”[J]. 机械工程学报, 2013, 49(1): 63-72.
(Wang G B, He Z J, Chen X F, et al. Basic research on machinery fault diagnosis — What is the prescription[J]. Journal of Mechanical Engineering, 2013, 49(1): 63-72.)
- [4] Betta G, Liguori C, Paolillo A, et al. A DSP-based FFT-analyzer for the fault diagnosis of rotating machine based on vibration analysis[J]. IEEE Transactions on Instrumentation and Measurement, 2002, 51(6): 1316-1322.
- [5] Yan R Q, Gao R X, Chen X F. Wavelets for fault diagnosis of rotary machines: A review with applications[J]. Signal Processing, 2014, 96: 1-15.
- [6] Peng Z K, Tse P W, Chu F L. A comparison

- study of improved Hilbert-Huang transform and wavelet transform: Application to fault diagnosis for rolling bearing[J]. *Mechanical Systems and Signal Processing*, 2005, 19(5): 974-988.
- [7] Lei Y G, Yang B, Jiang X W, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap[J]. *Mechanical Systems and Signal Processing*, 2020, 138: 106587.
- [8] Zhao C H, Chen J H, Jing H. Condition-driven data analytics and monitoring for wide-range nonstationary and transient continuous processes[J]. *IEEE Transactions on Automation Science and Engineering*, 2021, 18(4): 1563-1574.
- [9] Chen J H, Zhao C H. Exponential stationary subspace analysis for stationary feature analytics and adaptive nonstationary process monitoring[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(12): 8345-8356.
- [10] Feng L J, Zhao C H. Fault description based attribute transfer for zero-sample industrial fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(3): 1852-1862.
- [11] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. *机械工程学报*, 2018, 54(5): 94-104.
(Lei Y G, Jia F, Kong D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. *Journal of Mechanical Engineering*, 2018, 54(5): 94-104.)
- [12] Chai Z, Zhao C H. A fine-grained adversarial network method for cross-domain industrial fault diagnosis[J]. *IEEE Transactions on Automation Science and Engineering*, 2020, 17(3): 1432-1442.
- [13] Ince T, Kiranyaz S, Eren L, et al. Real-time motor fault detection by 1-D convolutional neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(11): 7067-7075.
- [14] Qi Y M, Shen C Q, Wang D, et al. Stacked sparse autoencoder-based deep network for fault diagnosis of rotating machinery[J]. *IEEE Access*, 5: 15066-15079.
- [15] Jiang G Q, He H B, Yan J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3196-3207.
- [16] Elman J L. Distributed representations, simple recurrent networks, and grammatical structure[J]. *Machine Learning*, 1991, 7(2): 195-225.
- [17] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [18] 田峰. 基于高频振动信号与机器学习的旋转机械智能故障诊断[D]. 杭州: 浙江大学, 2020: 15-30.
(Tian F. Intelligent fault diagnosis of rotating machinery based on vibration signal and machine learning[D]. Hangzhou: Zhejiang University, 2020: 15-30.)
- [19] Wang L H, Zhao X P, Wu J X, et al. Motor fault diagnosis based on short-time Fourier transform and convolutional neural network[J]. *Chinese Journal of Mechanical Engineering*, 2017, 30(6): 1357-1368.
- [20] Chen R X, Huang X, Yang L X, et al. Intelligent fault diagnosis method of planetary gearboxes based on convolution neural network and discrete wavelet transform[J]. *Computers in Industry*, 2019, 106: 48-59.
- [21] Xie Y, Zhang T. Fault diagnosis for rotating machinery based on convolutional neural network and empirical mode decomposition[J]. *Shock and Vibration*, 2017, 2017: 1-12.
- [22] Gilles J. Empirical wavelet transform[J]. *IEEE Transactions on Signal Processing*, 2013, 61(16): 3999-4010.
- [23] Daubechies I. Ten lectures on wavelets[M]. Philadelphia: Society for Industrial and Applied Mathematics, 1992: 116-120.
- [24] Zhang W, Peng G L, Li C H, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals[J]. *Sensors*, 2017, 17(2): 425.
- [25] Minhas A S, Singh S. A new bearing fault diagnosis approach combining sensitive statistical features with improved multiscale permutation entropy method[J]. *Knowledge-Based Systems*, 2021, 218: 106883.
- [26] Yan X A, Jia M P. A novel optimized SVM classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing[J]. *Neurocomputing*, 2018, 313: 47-64.
- [27] Pandya D H, Upadhyay S H, Harsha S P. Fault diagnosis of rolling element bearing with intrinsic mode function of acoustic emission data using APF-KNN[J]. *Expert Systems with Applications*, 2013, 40(10): 4137-4145.
- [28] Chai Z, Zhao C H, Huang B. Multisource-refined transfer network for industrial fault diagnosis under domain and category inconsistencies[J]. *IEEE Transactions on Cybernetics*, 2022, 52(9): 9784-9796.
- [29] Zhang W, Li C H, Peng G L, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load[J]. *Mechanical Systems and Signal Processing*, 2018, 100: 439-453.

作者简介

姚家琪(1998—), 男, 硕士生, 从事旋转机械故障诊断的研究, E-mail: yjiaqi@zju.edu.cn;

荆华(1996—), 男, 博士生, 从事工业过程状态监测的研究, E-mail: pzhjh20062006@163.com;

赵春晖(1979—), 女, 教授, 博士生导师, 从事工业大数据分析与应用、状态监测、故障诊断、软测量等研究, E-mail: chhzhao@zju.edu.cn.