DOI：10. 13382/j. jemi. B2306298

基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究*

王　雷[1]　何　坤[2]　李宗帅[2]　常东润[2]
（1. 中国民航大学工程技术训练中心　天津　300300；2. 中国民航大学电子信息与自动化学院　天津　300300）

摘　要：针对传统深度学习网络模型在变工况条件下的故障诊断泛化能力差的问题，提出一种基于迁移学习的双向长短时记忆网络和注意力机制（TLBA）融合的故障识别方法。将原始故障数据划分为源域及目标域；并构建融合注意力机制的双向长短时记忆网络（BiLSTM-Attention，BA）模型，之后使用此模型学习源域数据特征；最后利用迁移学习通过对目标域数据的学习，进一步优化调整 BA 模型的网络参数，最终得到目标域的故障分类辨识模型。以航空器翼梁故障为案例，结果表明，该方法与传统故障诊断方法 BiLSTM-Attention 相比，其综合评价指标 $F_{1\text{-}score}$ 有 3. 4%的提高，故障平均诊断准确率在 91%以上；同时针对变工况下的故障分类结果较为稳定。

关键词：故障诊断；深度学习；特征提取；迁移学习；Bi-LSTM；注意力机制
中图分类号：TH136；TN98　　**文献标识码**：A　　**国家标准学科分类代码**：D460. 4

Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions

Wang Lei[1]　He Kun[2]　Li Zongshuai[2]　Chang Dongrun[2]
（1. Engineering Technology Training Center，Civil Aviation University of China，Tianjin 300300，China；
2. School of Electronic Information and Automation，Civil Aviation University of China，Tianjin 300300，China）

Abstract：Aiming at the problem of poor generalization ability of fault diagnosis of traditional deep learning network model under variable working conditions，a fault identification method based on the fusion of transfer learning bidirectional long short memory network and attention mechanism（TLBA）is proposed. Divide the original fault data into source domain and target domain，and construct a bidirectional long short-term memory network（BA）model that integrates attention mechanisms，and then use this model to learn source domain data features. Finally，transfer learning is used to further optimize and adjust the network parameters of the BA model by learning the data in the target domain，and finally the fault classification identification model in the target domain is obtained. Taking the aircraft wing beam fault as an example，the results show that compared with the traditional fault diagnosis method BiLSTM-Attention，the comprehensive evaluation index $F_{1\text{-}score}$ of this method is improved by 3. 4%，and the average fault diagnosis accuracy is above 91%. At the same time，the fault classification results under variable operating conditions are relatively stable.

Keywords：fault diagnosis；deep learning；feature extraction；transfer learning；Bi-LSTM；attention mechanism

0　引　言

随着现代工业自动化、智能化程度的提高，各种机械设备也变得愈加精密复杂，但同时带来故障复杂程度高、诊断难度大、特征模糊不易提取等困难，因此对于故障诊断技术提出了更高的要求[1]。

以大数据为驱动的故障预测技术被广大学者应用于故障分类研究领域中[2]，主要分为基于统计分析[3-5]与机器学习的故障诊断方法，但随着计算机技术不断发展，基于机器学习的故障诊断日益成为故障诊断的主流方式[6-8]；雷春丽等[9]提出基于马尔科夫转移场（（Markov transition field，MTF）编码方式，将一维振动数据信号转化为二维特征图，进而通过卷积神经网络（convolutional

收稿日期：2023-03-01　　Received Date：2023-03-01
* 基金项目：中央高校基本科研业务费民航大学专项（3122020025）项目资助

neural networks,CNN)进行分类;Orhan 等[10]通过梅尔频率倒谱系数(Mel-frequency cepstral coefficient,MFCC)对无人机电机音频信号进行特征提取,最后使用支持向量机(support vector machine,SVM)对数据分析进而完成电机故障的分类;黄宇等[11]将 LSTM 与 Self-Attention 融合并成功预测滚动轴承的剩余寿命,首先通过对原始信号处理得到其退化特征,再将其进行归一化处理后作为模型的输入,深度挖掘潜层特征,完成滚动轴承 RUL 预测;赵志宏等[12]提出了一种将原始信号直接导入 Bi-LSTM 模型进行故障分类,并取得良好的分类效果。

但是在实际生产工作中,由于机械设备工作环境、设备个体、使用时间等复杂多变,往往会导致实际运行时的工况复杂多变。传统机器学习对于变工况下的数据泛化能力差,对新出现的故障类型模式需要重新建模,造成大量时间以及精力浪费,难以将原有工况下建立的模型应用于新出现未知工况下的故障类型。针对这一问题迁移学习应运而生,迁移学习具有故障知识跨领域的特性,其是指从某些已知领域学到的知识信息迁移到相关或者不同领域的一种算法[13]。相关学者在迁移学习方向进行了广泛研究,谢锋云等[14]提出迁移学习与 CNN 相结合的电机故障诊断方法,即通过源域数据对模型进行训练,其次利用目标域数据实现模型参数优化,最后进行电机目标域故障诊断分类;林培等[15]首先对潜在故障特征数据进行提取,并将其导入到一维卷积自编码器中进行源域上的训练,然后将分类器代替原有解码层,同时将编码层参数进行冻结,其次利用目标域数据对分类器参数进行微调,最后实现故障特征分类;Li 等[16]通过在同一台机械设备上,将一种故障模式下训练好的模型,采用另一种故障模式下的数据对模型进行微调,最终模型具有较好的预测效果。

尽管上述方法具有良好的效果,但是对迁移模型部分层参数冻结,势必会造成数据特征的遗失。鉴于此,本文提出一种基于迁移学习的双向长短时记忆网络和注意力机制融合(transfer learning-BiLSTM-Attention,TLBA)的故障识别方法。

1　TLBA 故障诊断方法

1.1　双向长短时记忆网络

双向长短时记忆网络是长短期记忆网络一种变体形式,在前向和后向两个方向上使用两个独立的隐藏层处理时间序列数据,充分利用过去与将来的信息,有效解决 LSTM 只能单向处理数据的问题[17],其网络结构如图 1 所示。

LSTM 是递归神经网络(recursive neural network,RNN)的一种特殊结构,它不仅仅考虑当下信息,同时也

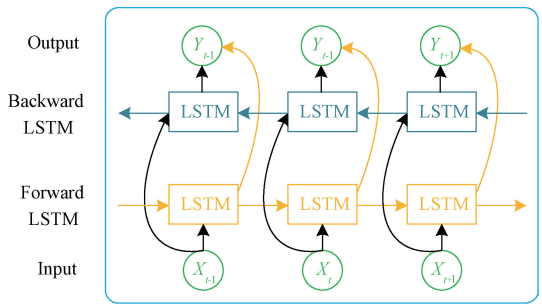

图 1　Bi-LSTM 网络结构

Fig. 1　Bi-LSTM network structure diagram

充分利用先前信息完成对即将到来状态的预测,避免了传统 RNN 网络出现的梯度爆炸与消失问题[18-19],其网络结构如图 2 所示。

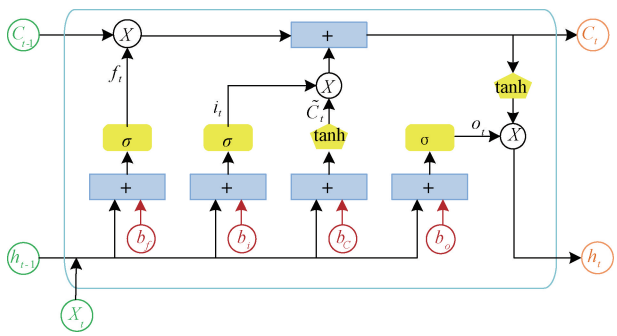

图 2　LSTM 网络神经元结构

Fig. 2　Bi-LSTM network structure diagram

LSTM 主要由 3 个门控制函数对单元状态(cell state)进行调节:遗忘门、输入门、输出门。遗忘门:遗忘门 f_t 的作用是在 t 时刻对 C_{t-1} 特征进行选择性过滤,保留至 C_t 用于长期计算,其计算公式为:

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \\ C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \end{cases} \tag{1}$$

输入门:输入门 i_t 的作用是在 t 时刻完成对输入 X_t 以及先前短时状态 h_{t-1} 有效信息的筛选,用于更新单元状态值 $\tilde{C}_t$,其内部计算公式为:

$$\begin{cases} i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \\ \tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, X_t] + b_C) \end{cases} \tag{2}$$

输出门:输出门 o_t 的作用是在 t 时刻完成对长期信息 C_t 以及 $\tilde{C}_t$ 信息整合保留至短时状态 h_t,其内部计算公式为:

$$\begin{cases} o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \\ h_t = o_t \otimes \tanh(C_t) \end{cases} \tag{3}$$

式中:σ 为 Sigmoid 函数,$\boldsymbol{W}$ 和 b 分别代表门函数的偏移

矩阵和偏置,⊗代表向量相乘。

1.2　注意力机制

视觉注意力是人类大脑长期进化所特有的一种信息处理机制,核心思想为从大量信息中快速关注重要信息而减少对其他信息的关注。注意力机制本质正是借鉴此方式,根据特征信息对最终目标影响程度赋予不同权重,而快速准确实现时间序列的预测精度[20],其结构如图 3 所示。

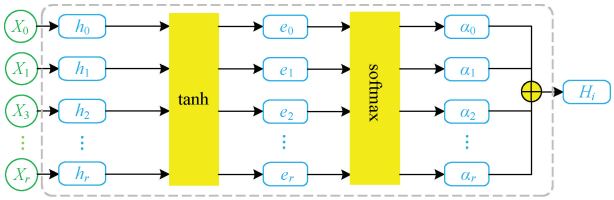

图 3　注意力机制结构

Fig. 3　Attention mechanism structure

其工作过程分为 3 步:首先将查询(Query)与各个键(Key)进行相似相关性计算得到权重系数;然后使用 Softmax 函数对上述权重系数进行标准归一化;最后将权重与对应值(Value)进行加权求和。内部主要计算公式为:

$$\begin{cases} e_t = u\tanh(W * H + b) \\ \alpha_t = softmax(e_t) = \dfrac{\exp(e_t)}{\sum_{j=1}^{t} e_t} \end{cases} \tag{4}$$

式中:u、W 代表权重,b 代表偏置,H 代表 Bi-LSTM 网络的输出,α 代表各输出特征不同权重系数。

注意力机制的引入,可使建模过程中更多关注重要信息,尽可能详细的获取其细节信息,减少无关信息。因此,注意力机制的引入可更关注输入与输出数据时间关联性更强的信息,提高输出质量,减轻运算量。

1.3　迁移学习

迁移学习(transfer learning)是机器学习近些年来产出的一个重要分支,通过已有解决某种问题的能力而应用到其他相关领域或问题中[21],其学习原理图如图 4 所示。

在故障分类任务中,比如设备 A 存在的某一故障类型 α,设备 B 存在类似故障模式 α、β、γ 等,彼此之间可以看作相似领域,通过对设备 A 存在各类故障特征进行分析学习,针对设备 B 情况下的部分相似故障同样适用。通俗来讲,迁移学习指通过在源域 D_s 学习到的知识、模式、特征等转移到目标域 D_t 中,实现目标域 D_t 中目标任务的预测或分类,从而提高学习者的表现能力,改善目标模型的性能与效率。

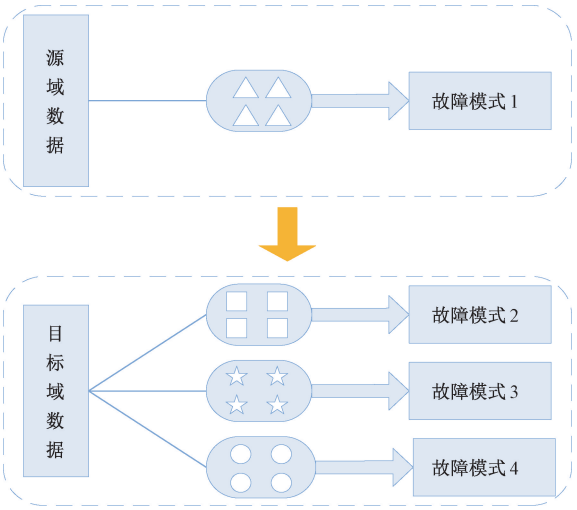

图 4　迁移学习

Fig. 4　Transfer learning

1.4　效果评价指标

为了对所提模型故障诊断分类效果进行量化评估,本文中使用准确率、查准率、召回率以及综合评价指标 $F_{1\text{-}score}$ 作为网络模型的评价指标[22],各个指标具体运算如下:

$$\begin{cases} A_{cc} = \dfrac{TP + TN}{TP + FP + TN + FN} \\ P_{re} = \dfrac{TP}{TP + FP} \\ R_e = \dfrac{TP}{TP + FP} \\ R_e = \dfrac{TP}{TP + FP} \end{cases} \tag{5}$$

式中:TP 为将某一类被正确分类的样本个数,TN 为将其他类被正确分类的样本数目,FP 为将负类诊断为正类的样本数目,FN 为将正类诊断为负类的样本数目;准确率(A_{cc})代表样本正确分类的比例,精确率(P_{re})代表模型诊断为故障的样本被正确识别为故障类别的比例,召回率(R_e)代表在所有的故障样本中被正确识别为故障类别的比例,综合评价指标($F_{1\text{-}score}$)代表精确率与召回率的加权调和平均。

1.5　TLBA 模型构建

基于 TLBA 的变工况故障分类方法整体流程如图 5 所示。

1)对采集到的数据集划分类别及贴标签预处理,并将数据集划分为源域及目标域(详见 2.2 节)。

2)鉴于各故障模式数据差异较小,特征隐藏较深,选择搭建双层 Bi-LSTM 并融合 Attention 机制(BA)对深层故障数据特征的提取筛选,之后连接全连接层完成故障

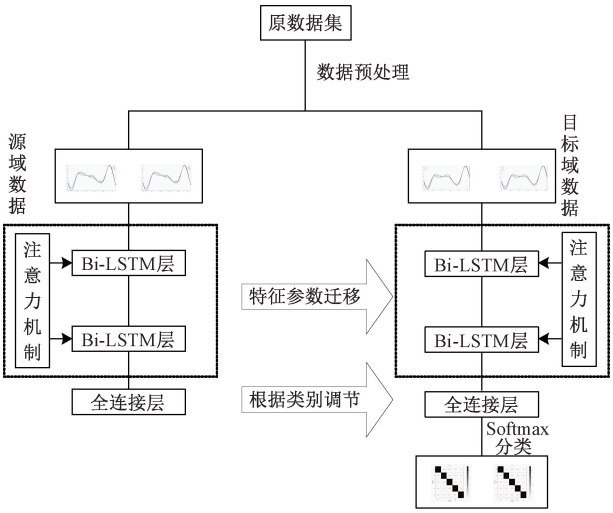

图 5　TLBA 故障诊断整体流程

Fig. 5　Overall process of TLBA fault classification

分类;利用充足的源域数据训练模型,并保存模型网络参数。

3)引入迁移学习,利用目标域数据对步骤 2)中训练的模型进行参数调整;特别地,对于全连接层根据不同目标域下的类别进行调整输出。

4)基于步骤 3)中迁移学习调整完的模型完成目标域测试集的故障模式识别及分类,并对模型识别效果进行评估。

2　实验验证

2.1　数据集介绍

为验证本文所提模型的性能,以航空器机翼大梁不同故障所产生的振动信号变化数据集作为仿真数据,实验装置如图 6 所示。

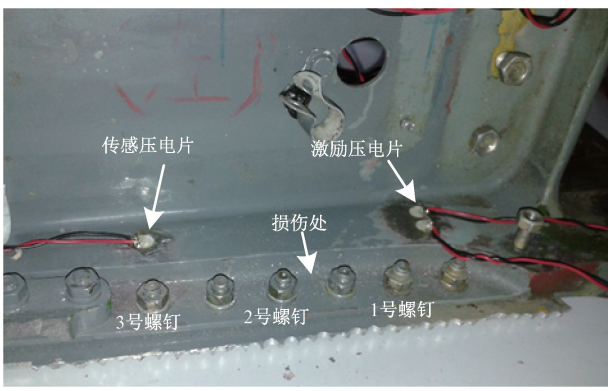

图 6　机翼大梁实验装置

Fig. 6　Wing girder experimental device

实验基于 Lamb 波响应来描述机翼大梁不同螺钉松动拧紧及不同大小模拟损伤引起的信号变化:设置激励压电片与传感压电片,同时在两者之间设置 6 个螺钉及一处模拟损伤点;激励信号由激励压电片产生,传感压电片进行信号的接收,信号传递过程经过 6 个螺钉及模拟损伤处,两片传感器相距间距为 120 mm,激励信号频率为 200 kHz,采样率固定为 10 MHz,采样点数为 10 000 点,平均次数为 100。

数据集是一个 10 000×60×20 的矩阵,10 000 表示信号的采样长度,20 表示一共展开 20 次重复实验,60 代表不同工况下数据采集:

1)无螺钉松动时,在模拟损伤处分别粘贴 0、4、8、12、16 mm 5 种模拟损伤

2)1 号螺钉松动再拧紧后,在模拟损伤处分别粘贴 0、4、8、12、16 mm 5 种模拟损伤

3)2 号螺钉松动再拧紧后,在模拟损伤处分别粘贴 0、4、8、12、16 mm 5 种模拟损伤

4)3 号螺钉松动再拧紧后,在模拟损伤处分别粘贴 0、4、8、12、16 mm 5 种模拟损伤;

对上述 20 种不同工况,每种工况通过采集 3 组 Lamb 波信号来描述不同的故障。

2.2　数据预处理

根据不同工况下的无螺钉松动、1 号螺钉松动再拧紧、2 号螺钉松动再拧紧、3 号螺钉松动再拧紧对其划分 4 种任务数据集 A~D,如表 1 所示。

表 1　任务分类及标签设置

Table 1　Task classification and label setting

	螺钉	裂纹尺寸/mm	标签
A	无螺钉	0	L0
		4	L1
		8	L2
		12	L3
		16	L4
B	1 号螺钉	0	L5
		4	L6
		8	L7
		12	L8
		16	L9
C	2 号螺钉	0	L10
		4	L11
		8	L12
		12	L13
		16	L14
D	3 号螺钉	0	L15
		4	L16
		8	L17
		12	L18
		16	L19

以上述 4 种任务数据集 A~D 各自分别作为源域,剩

余其他每种数据集分别作为目标域,共 12 种迁移任务:A-B、A-C、A-D、B-A、B-C、B-D、C-A、C-B、C-D、D-A、D-B 及 D-C。以 A-B 为例,无螺钉松动情况下的数据集 A 作为源域,1 号螺钉松动再拧紧情况下的数据集作为目标域任务 B,通过源域对搭建的模型进行预训练及参数保存,之后利用目标域训练集进行模型微调,最后实现目标域测试集的任务分类。

以迁移任务 A-B 为例,源域数据集下的不同故障时域图如图 7 所示,目标域数据集下不同故障时域图如图 8 所示。

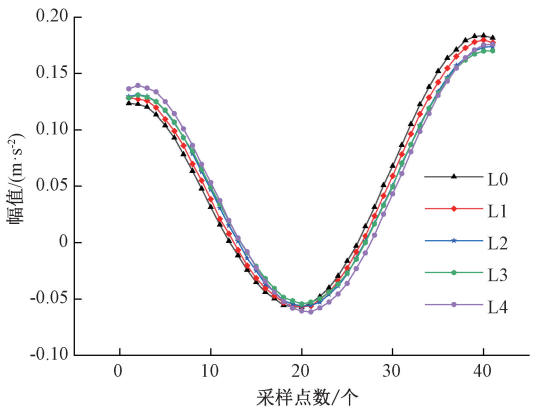

图 7　源域数据集故障对比

Fig. 7　Source domain dataset fault comparison

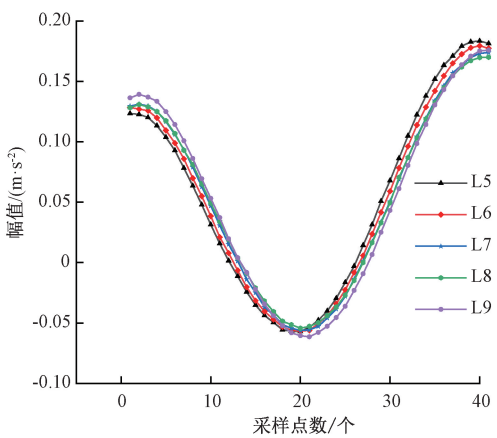

图 8　目标域数据集故障对比

Fig. 8　Target domain dataset fault comparison

2.3　实验设置及分析

实验计算机配置基于 windows 系统、NVIDIA GeForce GTX2080Ti、Intel Core i9-9900、32GRAM;实验使用的编程工具为 Python 3.6,深度学习框架为 Pytorch 1.9.0。为了保持原始数据的可靠性,实验中没有对数据进行进一步处理,直接将原始 Lamb 振动信号作为模型的输入;其中随机选取数据集的 80%作为训练集,剩余 20%作为测试集。之后选择搭建两层对时间序列预测较强的双向长短期记忆网络(Bi-LSTM),同时融合注意力机制;在长短期记忆网络模型中:批量数据 batch_size 大小设置为 128,隐藏层 hidden_size 设置为 64;使用优化器 Adam 加速模型超参数的收敛更新,为了探究学习率对迁移模型调整时存在的影响,通过将全连接层学习率设置为 0.001,其他层设置为[0.001,0.000 5,0.000 1];为了避免实验的偶然性,每个实验运行 10 次,将 10 次平均值用作最终结果,以迁移任务 A-B 为例,其结果如表 2 所示。

表 2　不同学习率的单次模型训练时间及 $F_{1\text{-}score}$

Table 2　Single model training time with different learning rates and $F_{1\text{-}score}$

学习率	单次模型训练时间/s	平均 $F_{1\text{-}score}$
0.001 0	1.06	0.902 9
0.000 5	1.05	0.424 2
0.000 1	1.03	0.362 6

由表 2 可以看出不同学习率对于最终结果影响较大,当设置为 0.001 时,尽管训练时间相比其他稍长,但是对于最终 $F_{1\text{-}score}$ 结果差距近 50%,于是确定学习率为 0.001,迁移任务 A-B 混淆矩阵图 9 所示。

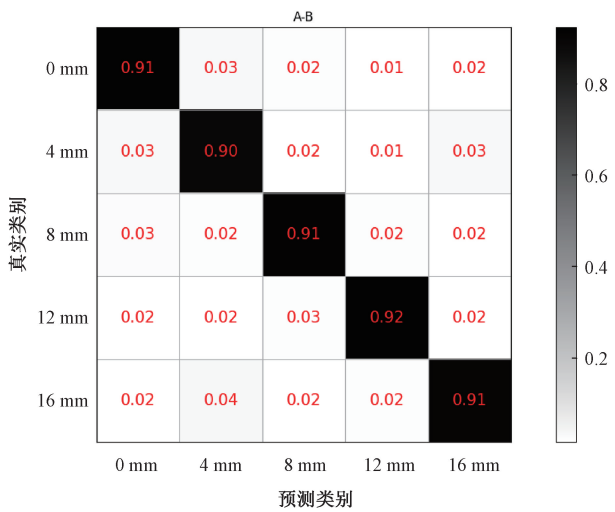

图 9　迁移任务 A-B 混淆矩阵

Fig. 9　Migration task A-B confusion matrix

由图 9 可以看出本文所提模型在目标域测试集多分类任务中其平均识别精度可达到 91%。为了避免实验的偶然性,同时验证模型的泛化效果,将本文所用方法(TLBA)分别与传统 BiLSTM-Attention、基于迁移学习的双向长短时记忆网络(transfer learning Bi-LSTM, TL-BiLSTM)及基于迁移学习的残差神经网络(transfer learning ResNet, TL-ResNet)进行对比[23-24],其各项评价指标结果如图 10 所示,分别代表不同迁移任务及不同模型下的各项评价指标,图中数字代表每一类别平均值:

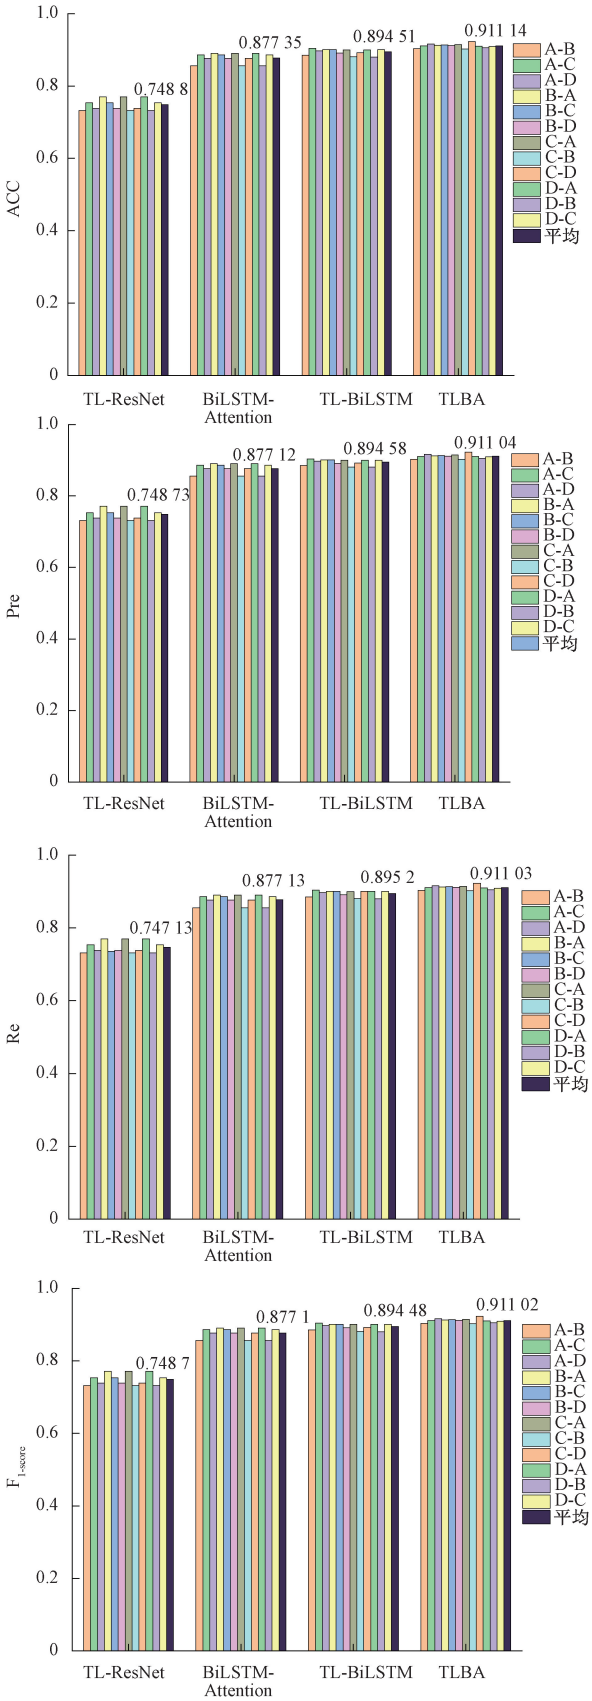

图 10　不同模型指标对比

Fig. 10　Comparison of indicators of different models

根据图 10 对比可以看出,本文所提方法 TLBA 相较于不使用迁移算法的传统 BiLSTM-Attention 对不同类型故障综合评价指标结果提升 3.4%,对于 TL-BiLSTM 及 TL-ResNet 分别有 1.7%及 16.2%的提升。

另外,根据图 10 中所得的准确率 Acc 结果,分别计算不同模型准确率的标准差,其结果如图 11 所示。

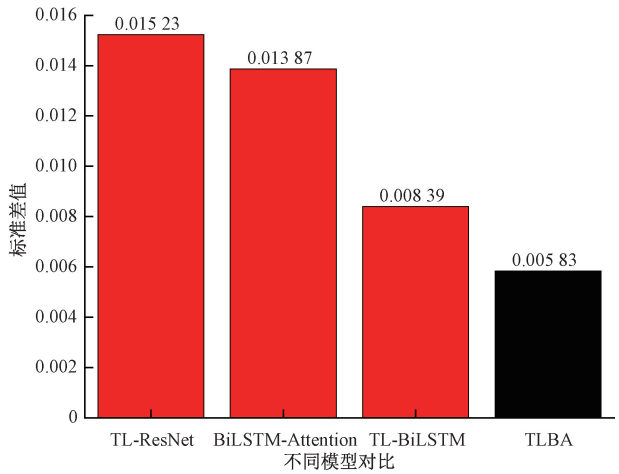

图 11　不同模型准确率标准差

Fig. 11　Standard deviation of accuracy for different models

由图 11 可以看出,针对不同任务,TLBA 故障识别率的标准差远低于其他几种模型。因此本文所提方法,不仅在准确率上高于其他几种方法,同时还具有良好的故障识别的稳定性。

2.4　实验结果分析及总结

由实验结果可知,本文所提神经网络模型 TLBA 在实验验证过程中,其准确率高于其他几种模型,诊断精度均超过 91%,同时针对不同故障识别率的标准差低于其他模型,证明了本文所提方法可以提取较多的有效特征且具有良好的分类稳定性。另外,鉴于实验数据信号直接通过压电片传感器进行信号的发射及采集,在信号传输过程中,两压电片之间金属环境存在一定的影响;同时实验中裂纹故障为模拟损伤,导致不同故障类别的数据信号差异较小,造成不同故障分类的困难;因此对于不同故障分类精度仍有进一步提升空间。为了进一步提高模型分类精度,之后工作考虑以下方法进行实验:

1)通过对数据集进行去噪处理,减少外界环境的影响,提高数据的质量。

2)基于特征工程,原始数据基础上利用小波变换等数学方法和领域知识,提取更加有效的特征,以便更加有效地区分不同故障类型。

3　结　论

本文主要针对传统深度学习模型在变工况条件下的

故障诊断泛化能力差的问题,提出一种基于迁移学习的双向长短期网络和注意力机制融合(TLBA)的故障分类模型,并基于航空器翼梁故障数据完成对该模型的验证。通过实验结果表明,本文所提模型故障平均诊断准确率较高,同时针对变工况下的故障分类结果较为稳定。为了进一步提高模型分类精度,未来工作将从数据集去噪以及特征工程方向开展进一步研究。

参考文献

[1] POPESCU T D, AIORDACHIOAIE D. Fault detection of rolling element bearings using optimal segmentation of vibrating signals[J]. Mechanical Systems and Signal Processing, 2019, 116(FEB. 1):370-391.

[2] 文成林,吕菲亚,包哲静,等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报,2016,42(9):1285-1299.
WEN CH L, LYU F Y, BAO ZH J, et al. Overview of data-driven micro-fault diagnosis methods[J]. Journal of Automation, 2016,42 (9): 1285-1299.

[3] ZHANG Y W, LI S, TENG Y D. Dynamic processes monitoring using recursive kernel principal component analysis[J]. Chemical Engineering Science, 2012, 72: 78-86.

[4] MÁRQUEZ-VERA M A, LÓPEZ-ORTEGA O, RAMOS-VELASCO L E, et al. Adaptive threshold PCA for fault detection and isolation[J]. Journal of Robotics and Control (JRC), 2021, 2(3): 119-125.

[5] LI F Q, FAN Y G, ZHANG Y X. Rolling bearing fault detection method based on wavelet packet energy spectrum-PLS[J]. Advanced Materials Research, 2014, 971-973: 697-700.

[6] LI H, PAN D, CHEN C L P. Intelligent prognostics for battery health monitoring using the mean entropy and relevance vector machine[J]. IEEE Transactions on Systems Man and Cybernetics: Systems, 2014, 44(7): 851-862.

[7] 朱彦军,刘翠荣,吴志生. 深度学习在工业机械表面质量控制方面的应用——评《机器学习与深度学习算法基础》[J]. 机械设计,2020,37(10):154.
ZHU Y J, LIU C R, WU ZH SH. The application of deep learning in the surface quality control of industrial machinery—Review of "Machine learning and deep learning algorithm basis"[J]. Machine Design, 2020, 37 (10): 154.

[8] XIAO J L. SVM and KNN ensemble learning for traffic incident detection[J]. Physica A: Statistical Mechanics and its Applications,2019:29-35.

[9] 雷春丽,夏奔锋,薛林林,等. 基于 MTF-CNN 的滚动轴承故障诊断方法[J]. 振动与冲击,2022,41(9):151-158.
LEI CH L, XIA B F, XUE L L, et al. Fault diagnosis method of rolling bearing based on MTF-CNN [J]. Vibration and Shock, 2022,41(9): 151-158.

[10] ORHAN Y M, FERHAT Y, AYHAN A. A fault detection method based on embedded feature extraction and SVM classification for UAV motors [J]. Microprocessors and Microsystems,2022:104683.

[11] 黄宇,冯坤,高俊峰,等. 结合 LSTM 和 Self-Attention 的滚动轴承剩余使用寿命预测方法[J/OL]. 振动工程学报: 1-11. http://kns. cnki. net/kcms/detail/32. 1349. TB. 20220922. 0942. 002. html.
HUANG Y, FENG K, GAO J F, et al. Prediction method of residual service life of rolling bearing based on LSTM and Self-Attention [J/OL]. Journal of Vibration Engineering: 1-11.

[12] 赵志宏,赵敬娇,魏子洋. 基于 BiLSTM 的滚动轴承故障诊断研究[J]. 振动与冲击,2021,40(1):95-101.
ZHAO ZH H, ZHAO J J, WEI Z Y. Research on fault diagnosis of rolling bearing based on BiLSTM [J]. Vibration and Shock, 2021,40(1):95-101.

[13] 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.

[14] 谢锋云,董建坤,符羽,等. 迁移学习和 CNN 的电机故障诊断方法[J/OL]. 机械科学与技术:1-7. [2023-08-01]. DOI:10. 13433/j. cnki. 1003-8728. 20220196.
XIE F Y, DONG J K, FU Y, et al. Migration learning and CNN motor fault diagnosis method [J/OL]. Mechanical Science and Technology: 1-7. [2023-08-01]. DOI:10. 13433/j. cnki. 1003-8728. 20220196.

[15] 林培,许杨剑,傅军平,等. 基于 1D-DCGAN 和 1D-CAE 的小样本轴承故障跨域诊断方法[J]. 机电工程,2023,40(3):326-334.
LIN P, XU Y J, FU J P, et al. Cross domain diagnosis method for small sample bearing faults based on 1D-DCGAN and 1D-CAE [J]. Mechanical and Electrical Engineering, 2023,40 (3): 326-334.

[16] LI Z, KRISTOFFERSEN E, LI J. Deep transfer learning for failure prediction across failure types[J]. Computers & Industrial Engineering, 2022, 172: 108521.

[17] GRAVES A. Generating sequences with recurrent neural networks[J]. arXiv preprint arXiv:1308. 0850, 2013.

[18] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[19] 余金锁,卢先领. 基于分割注意力的特征融合 CNN-Bi-

LSTM 人体行为识别算法[J]. 电子测量与仪器学报, 2022,36(2):89-95.
YU J S, LU X L. Feature fusion CNN-Bi-LSTM human behavior recognition algorithm based on segmented attention [J]. Journal of Electronic Measurement and Instrumentation, 2022,36 (2): 89-95.

[20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30.

[21] WEISS K, KHOSHGOFTAAR T M, WANG D D. A survey of transfer learning [J]. Journal of Big Data, 2016, 3(1): 1-40.

[22] 胡茑庆,陈徽鹏,程哲,等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报,2019,55(7):9-18.
HU N Q, CHEN H P, CHENG ZH, et al. Fault diagnosis method of planetary gearbox based on empirical mode decomposition and deep convolution neural network [J]. Journal of Mechanical Engineering, 2019, 55 (7): 9-18.

[23] LIU Z J, GUO B S, WU F H, et al. An improved burr size prediction method based on the 1D-ResNet model and transfer learning [J]. Journal of Manufacturing Processes, 2022,84:183-197.

[24] 雷春丽,薛林林,焦孟萱,等. 结合改进 ResNet 与迁移学习的风力机滚动轴承故障诊断方法[J/OL]. 太阳能学报:1-10.
LEI CH L, XUE L L, JIAO M X, et al. Fault diagnosis method of wind turbine rolling bearing combined with improved ResNet and transfer learning [J/OL]. Journal of Solar Energy: 1-10.

作者简介

王雷,2010 年于河北工业大学获得学士学位,2013 年于中国民航大学获得硕士学位,现为中国民航大学实验师,主要研究方向为数据分析,智能故障诊断。
E-mail:695220661@qq.com

Wang Lei received his B. Sc. degree from Hebei University of Technology in 2010, M. Sc. degree from Civil Aviation University of China in 2013. Now he is an experimenter in Civil Aviation University of China. His main research interests include data analysis and intelligent fault diagnosis.