

基于多尺度卷积双向长短期记忆网络与 注意力机制的滚动轴承剩余寿命预测

闻 麒¹,金江涛¹,李 春^{1,2},岳敏楠¹

(1. 上海理工大学 能源与动力工程学院,上海 200093;
2. 上海市动力工程多相流动与传热重点实验室,上海 200093)

摘要:通过卷积神经网络(Convolutional Neural Network, CNN)处理轴承一维时域或频域信号,难以提取具有代表性的非线性特征信息,且易忽略低层次信息。针对这一问题,基于多尺度特征提取,引入一种特征注意力机制,提出一种基于卷积双向长短期记忆网络(MSAM-CNN-BiLSTM)的轴承剩余寿命预测方法。基于西安交通大学(Xi'an Jiao Tong University, XJTU)轴承数据集中的3组数据对MSAM-CNN-BiLSTM、LSTM、CNN-LSTM和MSAM-CNN-LSTM 4种方法的预测误差进行对比分析。结果表明:MSAM-CNN-BiLSTM方法在3组数据集中的预测误差均小于其他3种方法,说明该模型能同时学习数据中的低层次与高层次信息,可有效提高轴承的剩余寿命预测精度。

关键词:卷积神经网络;双向长短期记忆网络;多尺度;注意力机制;轴承;剩余寿命预测

中图分类号:TH133, TP183 文献标识码:A DOI:10.16146/j.cnki.rmdlge.2024.03.024

[引用本文格式]闻 麒,金江涛,李 春,等. 基于多尺度卷积双向长短期记忆网络与注意力机制的滚动轴承剩余寿命预测[J]. 热能动力工程,2024,39(3):189-199. WEN Qi, JIN Jiang-tao, LI Chun, et al. Remaining useful life prediction of rolling bearing based on multi-scale convolutional bidirectional long and short term memory network and attention mechanism[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(3):189-199.

Remaining Useful Life Prediction of Rolling Bearing based on Multi-scale Convolutional Bidirectional Long and Short Term Memory Network and Attention Mechanism

WEN Qi¹, JIN Jiang-tao¹, LI Chun^{1,2}, YUE Min-nan¹

(1. School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai, China,
Post Code: 200093; 2. Shanghai Key Laboratory of Multiphase Flow and Heat Transfer in Power Engineering,
Shanghai, China, Post Code: 200093)

Abstract: Processing the one-dimensional time and frequency domain signals of bearings by convolutional neural network (CNN) was difficult to extract the representative nonlinear characteristic information, and easy to ignore the low-level information. To solve this problem, a feature attention mechanism was introduced based on multi-scale feature extraction, and a prediction method of bearing remaining useful (RUL) life based on convolutional bidirectional long and short term memory network (MSAM-CNN-BiLSTM) was proposed. Based on three groups of data in the Xi'an Jiaotong University (XJTU) bearing data

收稿日期:2023-02-28; 修订日期:2023-04-13

基金项目:国家自然科学基金(51976131, 52006148, 52106262); 上海市IV类高峰学科-能源科学与技术-上海非碳基能源转换与利用研究院建设项目资助

Fund-supported Project: National Natural Science Foundation of China (51976131, 52001648, 52106262); Acknowledges the Non-carbon Energy Conversion and Utilization Institute under the Shanghai Class IV Peak Disciplinary Development Program

作者简介:闻 麒(1999-),男,上海理工大学硕士研究生。

通信作者:岳敏楠(1982-),女,上海理工大学讲师。

set, the prediction errors of four methods including MSAM-CNN-BiLSTM, LSTM, CNN-LSTM and MSAM-CNN-LSTM were compared and analyzed. The results show that the prediction errors of the proposed MSAM-CNN-BiLSTM method in the three data sets are smaller than that of the other three methods, indicating that the model can learn the low level and high level information in the data at the same time, and can effectively improve the prediction accuracy of the remaining useful life of bearings.

Key words: convolutional neural network (CNN), bi-directional long short term memory networks, multi-scale, attention mechanism, bearing, remaining useful life (RUL) prediction

引言

随着科技发展,现代机械设备逐渐变得更大、更集成、更复杂,且广泛应用于高噪声和强冲击的多样化环境,若发生故障可能致使设备停机,引起重大安全事故^[1-2]。因此,为提高设备安全性、可靠性和稳定性,需对机械装备进行预测与健康管理(Prognostics and Health Management, PHM)^[3]。滚动轴承作为机械设备中的关键部件,其性能退化将直接影响整个设备。因此,通过对轴承进行实时PHM,可以尽早制定合适的运行维护计划,避免故障发生时造成机械系统停机。剩余使用寿命(Remaining Useful Life, RUL)预测是PHM技术主要任务之一,近年来受到广泛关注^[4]。

目前,RUL预测方法已广泛应用于滚动轴承。文献[5]提出了一种基于支持向量回归的RUL估计方法,该方法利用时域、频域和时频域的多个统计特征,准确预测了滚动轴承的RUL。文献[6]提出相关系数和BP神经网络相结合的RUL预测模型,通过相关系数法对特征参数进行约简,利用BP神经网络构建健康指标,结果显示,该方法可对轴承进行有效的RUL预测。而深度学习算法层次结构中的非线性处理单元可使数据获得高级表示,具有更高效的处理能力和更出色的性能^[7],该技术应用在基于数据驱动的轴承RUL预测方法中亦具有显著优势^[8]。文献[9]基于深度神经网络建立了一种数据驱动模型,将时域与频域特征结合,实现了较好的轴承RUL预测。文献[10]采用全卷积神经网络的RUL预测方法,相比传统人为构建性能退化指标再进行预测的方法,可提高预测精度。文献[11]将一维CNN和二维CNN融合,该方法可提取轴承退化过程中的关键特征,有效地实现了RUL

预测。

然而在上述研究中,通过CNN处理一维信号时均存在信息损失问题,且传统时频分解方法处理非平稳信号能力较差,参数选择依赖经验选取,致使模型准确性和鲁棒性较差。目前,已有一些方法可挖掘数据中隐含的潜在信息,如长短期记忆网络(Long Short Term Memory Networks, LSTM),在处理序列数据时表现出较好的学习效果,但其对后向数据的学习能力较差^[12],而数据前后的关联信息对预测精度又有一定影响。文献[13]提出双向长短期记忆网络(Bidirectional LSTM, BiLSTM),能够同时考虑前后向信息,充分获取数据关联信息。文献[14]发现,相较传统诊断方法BiLSTM方法对滚动轴承故障识别的准确率得到了极大提高。但该方法尚未应用于RUL预测研究中。

因旋转机械各部件的振动耦合使时间信号呈多尺度特性,自多个时间尺度提取特征可充分提取信号内潜在时序信息,提升模型预测能力。本文基于多尺度(Multi-Scale)特征提取概念,从一维时域信号中获取多时间尺度子信号,引入一种特征注意力机制(Attention Mechanism),可自适应地对不同尺度上的学习特征进行评分并分配权重,借鉴BiLSTM方法提出基于多尺度卷积双向长短期记忆网络(MSAM-CNN-BiLSTM)的轴承剩余寿命预测系统,该系统可直接应用于振动信号,且无需其他信号处理方法,具有较强的鲁棒性和泛化能力。

1 算法基础

1.1 卷积神经网络

卷积神经网络提供了一种“端到端”的数据处理方法,可自学习潜在特征^[15],而无需依赖专家经验。CNN模型的基本结构由卷积层、池化层和全连接层3部分构成。

1.1.1 卷积层

通过多个滤波器和输入区域进行卷积运算获得响应特征,连接激活函数变换特征映射,提高特征的表达能力,其数学表达式如下:

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} \cdot \omega_{ij}^l + b_j^l\right) \quad (1)$$

式中: X_j^l — l 层卷积层中第 j 个元素; M_j — $l-1$ 层包含的第 j 个特征映射; X_i^{l-1} —元素; ω_{ij}^l —第 j 个滤波器连接的第 i 个对应卷积核; b_j^l —偏置项; $f(\cdot)$ —激活函数。

1.1.2 池化层

虽然卷积层可减少模型参数量,但无法减小特征图大小,致使模型过拟合。因此,常添加池化层分割特征图,对输入特征图进行不同程度的压缩和降维,减小数据规模,避免过拟合,提高模型性能。池化层计算公式为:

$$X_j^l = f(\beta_j^l \cdot \text{down}(X_j^{l-1}) + b_j^l) \quad (2)$$

式中: β —权值矩阵; $\text{down}(\cdot)$ —采样函数。

目前,常用的池化方式有均值池化、最大值池化和随机池化等。其中,最大值池化表达式为:

$$X^r = \max_{(i-1)r+1 \leq t \leq ir} X^{r-1}(t) \quad (3)$$

式中: r —池化区域长度; t —池化区域元素的位置。

1.1.3 全连接层

输入数据经多次卷积、池化操作后,整合提取局部特征并进一步提取总特征,且对输出情况实现分类。为提升卷积神经网络模型性能,全连接层内隐含的激活函数常采用ReLU函数。

1.1.4 损失函数

因本文涉及多分类问题,所以损失函数选取交叉熵函数。交叉熵函数定义如下:

$$J^{(m)} = -\sum_{i=1}^K -y_i^{(m)} \log(\hat{y}_i^{(m)}) \quad (4)$$

式中: $\hat{y}_i^{(m)}$ —第 m 个样本于Softmax层中第 i 个类别的输出; $y_i^{(m)}$ —第 i 个类别的实际标签; K —类别量。

$\hat{y}_i^{(m)}$ 定义如下:

$$\hat{y}_i^{(m)} = e^{\theta_i^T x_1^{(m)}} / \sum_{j=1}^K e^{\theta_j^T x_1^{(m)}} \quad (5)$$

式中: θ_i —模型参数; $x_1^{(m)}$ —第 m 个输入样本。

CNN训练时取 P 个样本作为一个批次,计算其交叉熵损失,以 P 个样本损失的平均值为该批次的

损失计算梯度,可得交叉熵损失函数如下:

$$J = -\frac{1}{m} \left(\sum_{m=1}^m \sum_{i=1}^K y_i^{(m)} \log(e^{\theta_i^T x_1^{(m)}} / \sum_{j=1}^K e^{\theta_j^T x_1^{(m)}}) \right) \quad (6)$$

1.2 长短期记忆网络

为避免循环神经网络梯度消失或爆炸问题,通过对LSTM引入输入门 i_t 、遗忘门 f_t 和输出门 o_t 3个特殊记忆单元结构,使其具备较强的学习能力和信息选择能力。LSTM内部结构见图1。

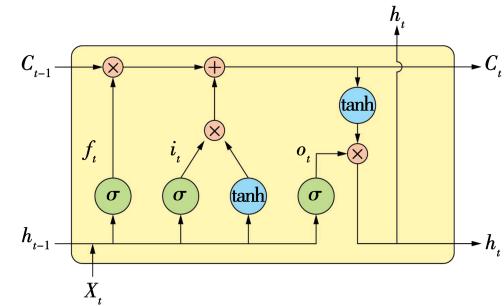


图1 LSTM 内部结构图

Fig. 1 LSTM internal structure diagram

输入门 i_t 控制信息是否应更新到状态向量中,遗忘门 f_t 控制信息是否应从状态向量中删除,输出门 o_t 控制当前状态下信息是否应输出。

记忆单元更新公式如下所示:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (7)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (8)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (9)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (10)$$

$$h_t = o_t \times \tanh(C_t) \quad (11)$$

式中: σ —sigmoid函数; x_t —当前时刻输入; h_{t-1} —上一时刻外部状态; C_t —记忆单元; h_t —外部状态; W_x , W_h —权重矩阵; b —偏置项。

1.3 双向长短期记忆网络

BiLSTM为结合正向和反向传播的LSTM模型,可从输入序列的两个方向进行学习,有效利用序列的前后信息,减少对序列数据的先验假设,提高模型的预测准确性。BiLSTM结构如图2所示。由图2可知,每个时刻的输入分别投入正向与反向LSTM层中,得到和保留各时刻正向与反向隐层输出,结合正、反向输出结果决定输出值。

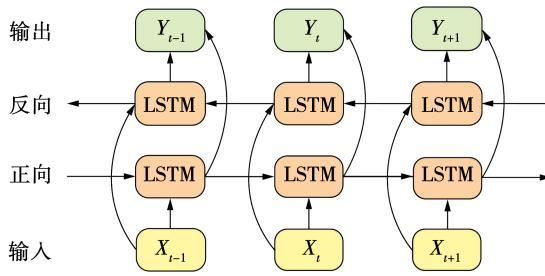


图 2 BiLSTM 结构图
Fig. 2 BiLSTM structure diagram

因 BiLSTM 具有较多参数,为提高模型计算效率,本文通过以下方法提高模型的计算效率:减少 LSTM 层数和隐藏单元的数量,优化网络结构,减少模型参数数量;使用剪枝、量化等技术对模型进行压缩;使用数据增强技术扩充数据集,提高模型的泛化能力;采用批量预测技术,同时对多个数据进行预测,减少模型的计算次数,实现数据增强和批量预测。

1.4 注意力机制

注意力机制是指注意力分布的概率计算,对关注区域分配较高权重,有针对性地突出关键特征^[16]。由于各尺度时间序列中所蕴含特征的重要性存在差异,为此采用注意力机制方法以便自适应地对不同尺度上学习的特征进行评分并匹配权重。注意力机制层结构见图 3^[16]。

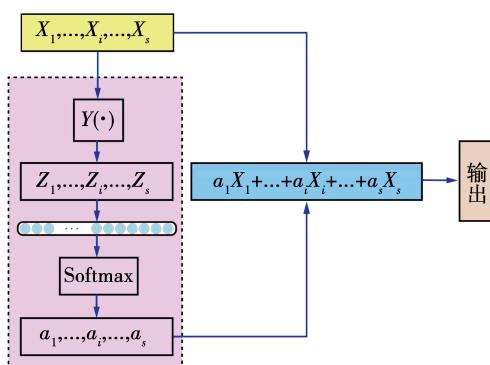


图 3 注意力机制层结构

Fig. 3 Attention mechanism layer structure

由图 3 可知,在具有注意力机制层的特征融合过程中,将从各尺度提取的子信号 $X_1, \dots, X_i, \dots, X_s$ 通过函数 $Y(\cdot)$ 进行求和,得到特征 $Z_1, \dots, Z_i, \dots, Z_s$ 。

$$Z_i = Y(X_i) = \sum_{k=1}^n X_i(k) \quad (12)$$

式中: $X_i(k)$ —第 k 个尺度的输出子信号 X_i ; n —最后一次卷积操作卷积核的数量。

各尺度的特征权重 $\alpha_1, \dots, \alpha_s$ 通过全局池化和 Softmax 函数得到,计算过程如式(13)所示。

$$\begin{cases} \alpha_i = \text{Softmax}(\beta_i) = e^{\beta_i} / \sum_{k=1}^s e^{\beta_k} \\ \sum_{i=1}^s \alpha_i = 1 \end{cases} \quad (13)$$

式中: β_i —全局池化层的输出; s —尺度个数。

通过 Softmax 函数计算各尺度 α_i 的特征权重,并将其映射到概率空间(0, 1)。经注意力机制层后所输出的特征 P 取决于 α_i 和 X_i ,计算过程如式(14)所示。

$$P = \sum_{i=1}^s \alpha_i X_i \quad (14)$$

2 剩余寿命预测方法

由于机械设备在役环境恶劣、载荷形式多样、结构复杂,致使振动信号具有较强非线性和多时间尺度特征。因此,本文提出 MSAM-CNN-BiLSTM 的剩余寿命预测模型,是通过浅层的卷积层和池化层提取振动频率、振动幅值、波形形状等低层次信息,再通过 BiLSTM、傅里叶变换层、深层的卷积层和全连接层来提取信号的时间序列特征、统计特征、频域特征和时间-频域特征等高层次信息。同时,学习数据中的高、低层次信息,可有效提高轴承的剩余寿命预测精度,其模型结构及参数如图 4 和表 1 所示。由图 4 和表 1 可知,输入层样本含 1 024 个数据点,通过均值池化层可提取长度为 256, 512 与 1024 的子序列。模型经过第 1 次卷积后对同尺寸数据获取多尺度特征,针对短序列使用小尺寸卷积核取样,反之采用大尺寸卷积核拓展模型感受野。通过多对卷积与池化的操作提取代表性特征。由于各尺度时间序列中所蕴含特征的重要性存在差异,引入注意力机制将不同尺度上学习的特征按重要程度分配其权重,该方式能突显更为重要的特征。各尺度学习特征汇总至两个 BiLSTM 层中,以充分获取前后位置间的关联信息,最终输入回归层中完成预测。同时,引入 Dropout 与 Batch Normalization 技术以避免过拟合导致 MSAM-CNN-BiLSTM 模型的泛化能力不足。

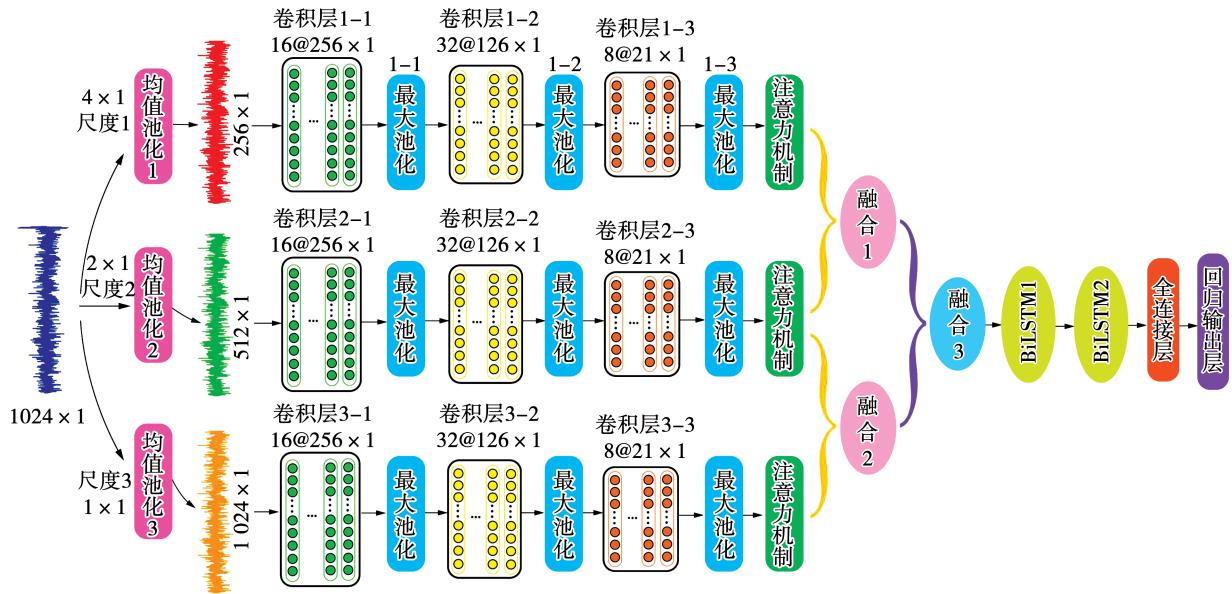


图 4 MSAM-CNN-BiLSTM 模型

Fig. 4 MSAM-CNN-BiLSTM model

表 1 MSAM-CNN-BiLSTM 模型部分参数

Tab. 1 Partial parameters of MSAM-CNN-BiLSTM model

网络层	卷积核 尺寸/步长	卷积核 数量	网络层 输出
均值池化 1	[4×1]/[4×1]	-	256×1
均值池化 2	[2×1]/[2×1]	-	512×1
均值池化 3	[1×1]/[1×1]	-	1024×1
卷积层 1-1	[64×1]/[1×1]	16	256×1
卷积层 2-1	[128×1]/[2×1]	16	256×1
卷积层 3-1	[256×1]/[4×1]	16	256×1
最大池化 1-1	[5×1]/[2×1]	16	126×1
卷积层 1-2	[64×1]/[1×1]	32	126×1
最大池化 1-2	[5×1]/[2×1]	32	61×1
卷积层 1-3	[32×1]/[3×1]	8	21×1
最大池化 1-3	[5×1]/[2×1]	8	9×1
融合 1	-	16	9×1
融合 3	-	32	9×1
BiLSTM1	-	-	128
BiLSTM2	-	-	128
全连接层	-	-	1

注:“-”表示没有数据

3 试验分析

3.1 数据集说明

基于西安交通大学滚动轴承加速度寿命试验数

据^[17]验证 MSAM-CNN-BiLSTM 模型有效性,其轴承加速寿命测试平台如图 5 所示。该平台主要由加速度传感器、电动机转速控制器、转轴、轴承、液压加载系统和交流电动机等组成,用于滚动轴承全寿命周期数据的监测。采样频率设置为 25.6 kHz,采样间隔设置为 1 min,每次采样时长设置为 1.28 s,1 次采样共获得 32 768 个数据点。

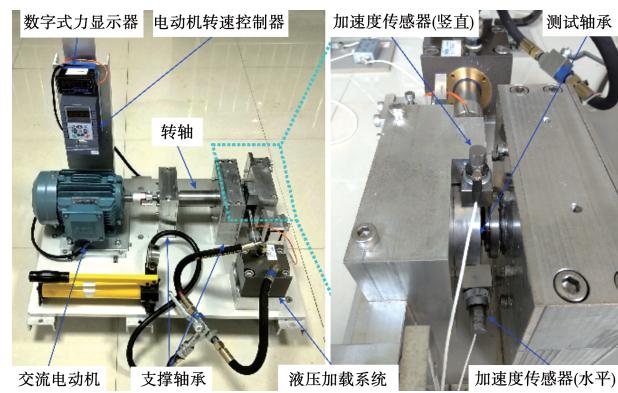


图 5 轴承加速度寿命测试平台

Fig. 5 Bearing accelerated life test platform

采用型号为 LDK UER204 的滚动轴承,其相关参数见表 2。试验共设计了 3 种工况,如表 3 所示。每种工况下有 5 个轴承,共得到 15 组数据。其对应的样本数、实际寿命以及失效位置如表 4 所示。

表 2 LDK UER 204 轴承参数

Tab. 2 LDK UER 204 bearing parameters

参数	数值
内圈滚道直径/mm	29.30
外圈滚道直径/mm	39.80
轴承中径/mm	34.55
基本额定动载荷/N	12 820
滚珠直径/mm	7.92
滚珠个数	8
接触角/(°)	0
基本额定静载荷/N	6 650

表 3 轴承加速度寿命试验工况

Tab. 3 Bearing accelerated life test conditions

工况	转速/r·min ⁻¹	径向力/kN
1	2 100	12
2	2 250	11
3	2 400	10

表 4 XJTU 轴承数据集信息

Tab. 4 XJTU bearing data set information

工况	轴承数据集	样本总数	实际寿命	失效位置
1	1_1	123	2 h 3 min	外圈
	1_2	161	2 h 41 min	外圈
	1_3	158	2 h 38 min	外圈
	1_4	122	2 h 2 min	保持架
	1_5	52	52 min	内圈、外圈
2	2_1	491	8 h 11 min	内圈
	2_2	161	2 h 41 min	外圈
	2_3	533	8 h 53 min	保持架
	2_4	42	42 min	外圈
	2_5	339	5 h 39 min	外圈
3	3_1	2538	42 h 18 min	外圈
	3_2	2496	41 h 36 min	内圈、滚动体、 保持架、外圈
	3_3	371	6 h 11 min	外圈
	3_4	1515	25 h 15 min	内圈
	3_5	114	1 h 54 min	外圈

采用每种工况中的 1 个轴承数据集进行分析, 轴承 1_2, 2_1 和 3_5 对应的全寿命时域图如图 6 所示。

采用平均绝对误差 \bar{e} 、最大绝对误差 e_{\max} 和均方

根误差 RMSE 对 RUL 预测结果的优劣进行评估。

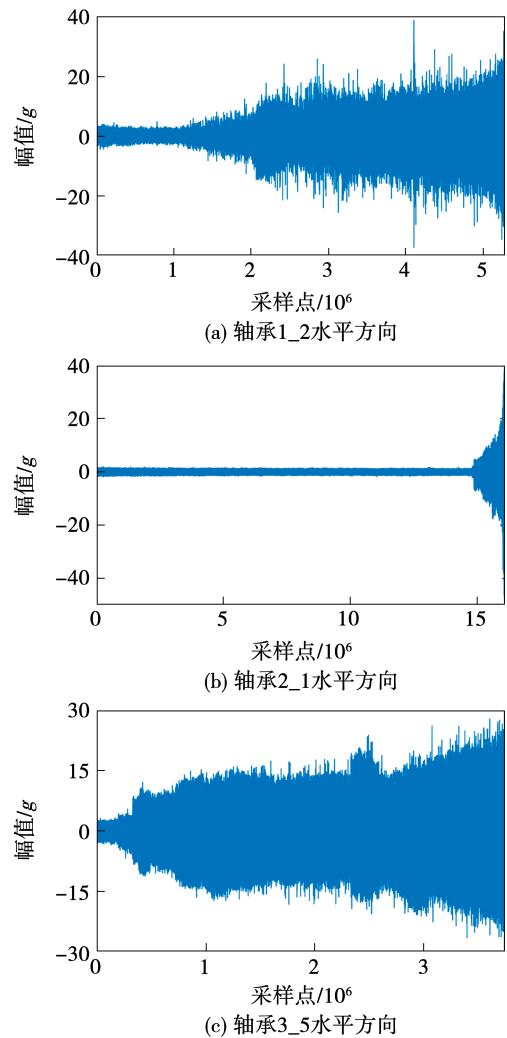


图 6 3 种轴承全寿命周期振动信号

Fig. 6 Vibration signals of three kinds of bearings in the whole life cycle

$$\bar{e} = \frac{1}{n} \sum_{i=1}^n |(P_i - T_i)| \quad (15)$$

$$e_{\max} = \max \{|P_i - T_i|\} \quad (16)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

式中: P —预测值; T —真实值; y_i, \hat{y}_i —样本的真实值和预测值。

3.2 实验分析与验证

分别采用 LSTM、CNN-LSTM 和 MSAM-CNN-LSTM 和 MSAM-CNN-BiLSTM 4 种方法对轴承 1_2 进行寿命预测, 其结果如图 7 和表 5 所示。RMSE 随迭代次数变化曲线如图 8 所示。

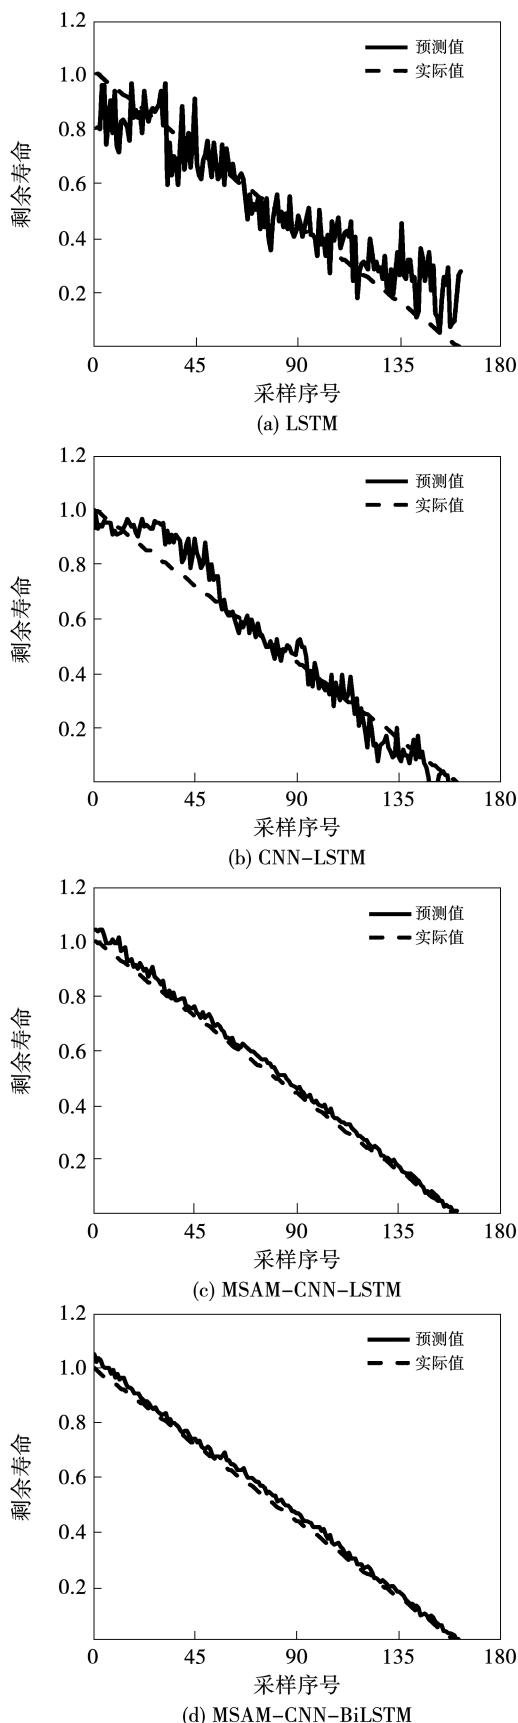


图 7 4 种方法下轴承 1_2 的剩余寿命预测结果

Fig. 7 Remaining useful life prediction results of bearing 1_2 by four methods
of bearing 1_2 by four methods

表 5 4 种方法下轴承 1_2 剩余寿命预测误差

Tab. 5 Remaining useful life prediction errors of bearing 1_2 by four methods

方法	e_{\max}	\bar{e}
LSTM	0.292 9	0.082 4
CNN-LSTM	0.190 2	0.051 6
MSAM-CNN-LSTM	0.080 1	0.023 8
MSAM-CNN-BiLSTM	0.053 1	0.021 9

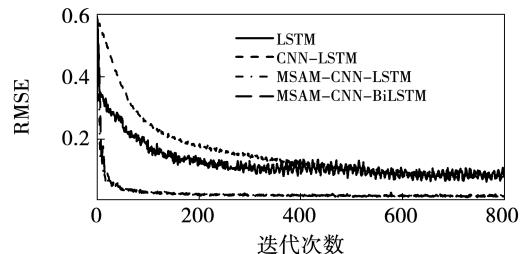


图 8 4 种方法下轴承 1_2 剩余寿命预测值的 RMSE 随迭代次数变化曲线

Fig. 8 RMSE change curve with iterations of remaining useful life prediction value bearing 1_2 by four methods

由图 7 和表 5 可知,对于轴承 1_2 的数据集,MSAM-CNN-BiLSTM 方法的预测值与实际值最为接近,其平均绝对误差和最大绝对误差为 4 种方法中最小的,相比 CNN-LSTM 和 LSTM 方法平均绝对误差分别减小了 135.6% 和 276.3%,相比 MSAM-CNN-LSTM 方法减小了 8.68%。由图 8 可知,采用 MSAM-CNN-BiLSTM 方法和 MSAM-CNN-LSTM 方法的 RMSE 值随迭代次数变化较为接近,均远小于现有 CNN-LSTM 和 LSTM 方法的 RMSE 值。

分别采用 4 种方法对轴承 2_1 进行寿命预测,其结果如图 9 和表 6 所示。RMSE 随迭代次数变化曲线如图 10 所示。由图 9 和表 6 可知,对于轴承 2_1,MSAM-CNN-BiLSTM 方法的预测值与实际值最为接近,其平均绝对误差和最大绝对误差为 4 种方法中最小的,相比 CNN-LSTM 和 LSTM 方法平均绝对误差分别减小了 300.0% 和 557.6%,相比 MSAM-CNN-LSTM 方法减小了 39.4%。由图 10 可知,采用 MSAM-CNN-BiLSTM 方法和 MSAM-CNN-LSTM 方法的 RMSE 值较为接近,均远小于现有 CNN-LSTM 和 LSTM 方法的 RMSE 值。

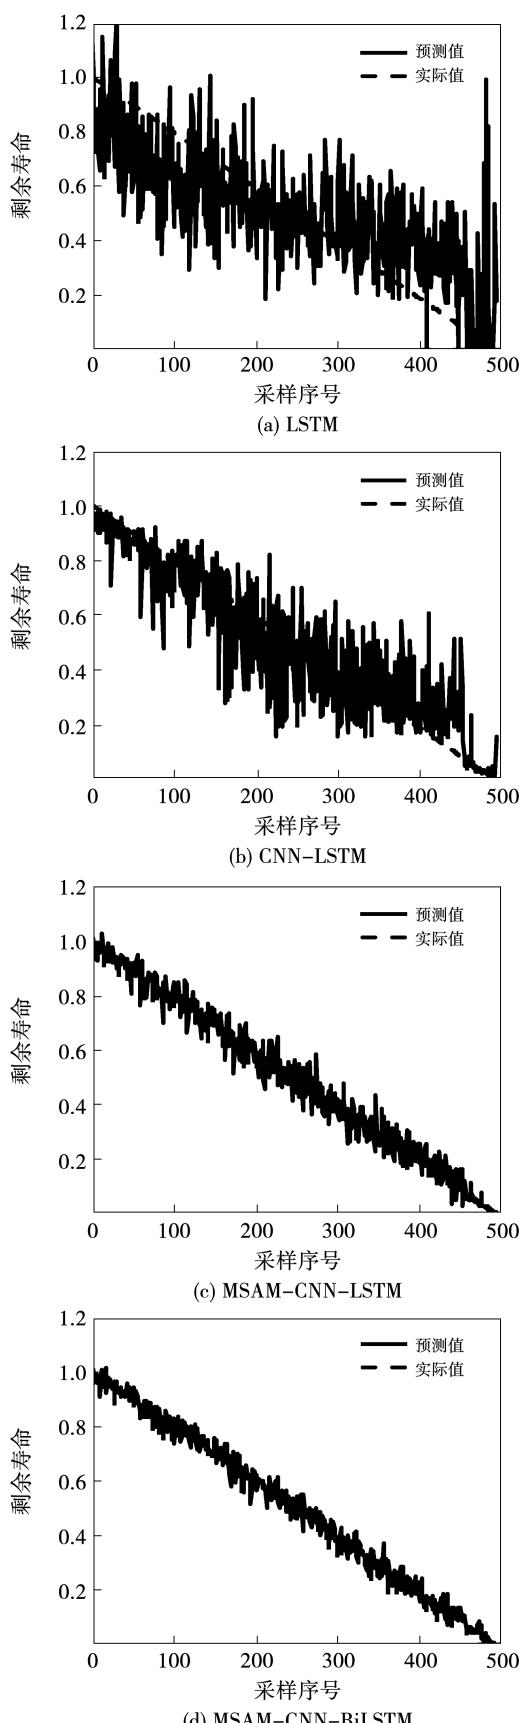


图 9 4 种方法下轴承 2_1 剩余寿命预测结果

Fig. 9 Remaining useful life prediction results of bearing 2_1 by four methods

表 6 4 种方法下轴承 2_1 剩余寿命预测误差

Tab. 6 Remaining useful life prediction errors of bearing 2_1 by four methods

方法	e_{\max}	\bar{e}
LSTM	0.966 9	0.155 2
CNN-LSTM	0.438 8	0.094 4
MSAM-CNN-LSTM	0.145 0	0.032 9
MSAM-CNN-BiLSTM	0.095 4	0.023 6

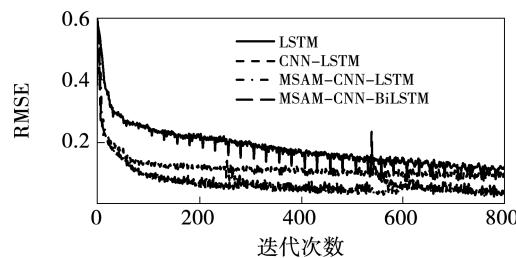
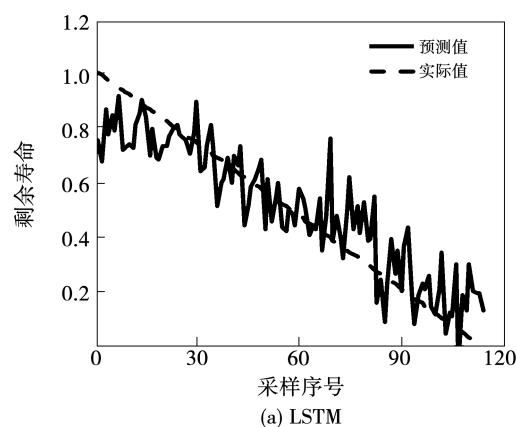
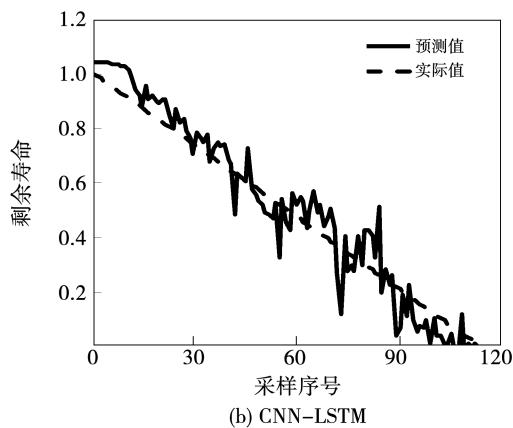


图 10 4 种方法下轴承 2_1 剩余寿命预测值的 RMSE 随迭代次数变化曲线

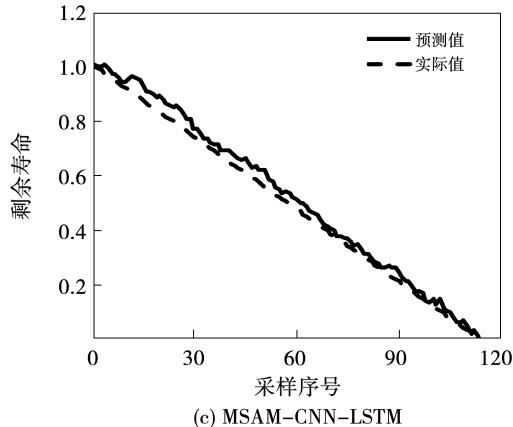
Fig. 10 RMSE change curve with iterations of remaining useful life prediction value of bearing 2_1 by four methods

采用 4 种方法对轴承 3_5 进行寿命预测, 其结果如图 11 和表 7 所示。RMSE 随迭代次数变化曲线如图 12 所示。由图 11 和表 7 可知, 对于轴承 3_5, MSAM-CNN-BiLSTM 方法的预测值与实际值最为接近, 其平均绝对误差和最大绝对误差为 4 种方法中最小的, 相比 CNN-LSTM 和 LSTM 方法平均绝对误差分别减小了 267.2% 和 776.8%, 相比 MSAM-CNN-LSTM 方法减小了 67.2%。由图 12 可知, 采用 MSAM-CNN-BiLSTM 方法和 MSAM-CNN-LSTM 方法的 RMSE 值随迭代次数变化较为接近, 均远小于现有 CNN-LSTM 和 LSTM 方法的 RMSE 值。

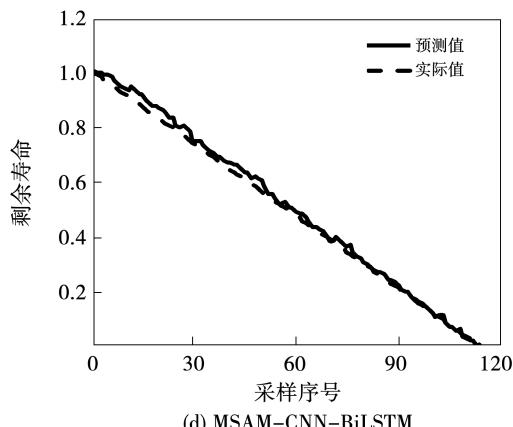




(b) CNN-LSTM



(c) MSAM-CNN-LSTM



(d) MSAM-CNN-BiLSTM

图 11 4 种方法下轴承 3_5 的剩余寿命预测结果

Fig. 11 Remaining useful life prediction results of bearing 3_5 by four methods

表 7 4 种方法下轴承 3_5 剩余寿命预测误差

Tab. 7 Remaining useful life prediction errors of bearing 3_5 by four methods

方法	e_{\max}	\bar{e}
LSTM	0.966 9	0.155 2
CNN-LSTM	0.251 2	0.065 0
MSAM-CNN-LSTM	0.067 8	0.029 6
MSAM-CNN-BiLSTM	0.049 0	0.017 7

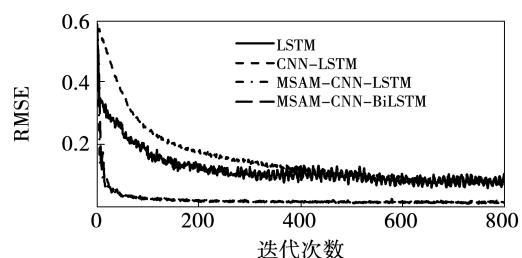


图 12 4 种方法下轴承 3_5 剩余寿命预测值的 RMSE 随迭代次数变化曲线

Fig. 12 RMSE change curve with iterations of remaining useful life prediction value of bearing 3_5 by four methods

3.3 优化器对模型性能的影响

学习率是优化器中的一个超参数,用于控制参数更新的步长,直接影响模型的收敛速度和性能^[18]。本文选取常用的 adam、sgdm 和 rmsprop 3 种优化器针对轴承 1_2 作对比实验,其 RMSE 和损失值随迭代次数的变化结果如图 13 和 14 所示。3 种优化器预测误差如表 8 所示。

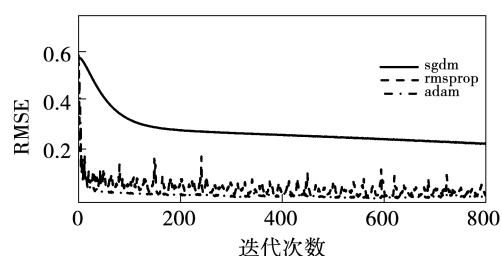


图 13 采用 3 种优化器下轴承 1_2 剩余寿命预测值的 RMSE 随迭代次数变化曲线

Fig. 13 RMSE change curve with iterations of three optimizers of bearing 1_2

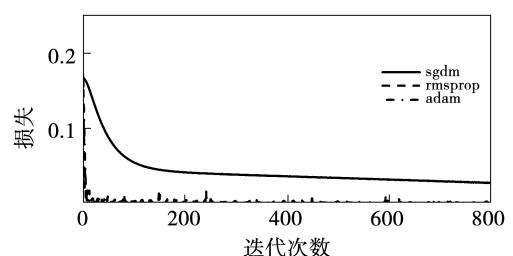


图 14 采用 3 种优化器下轴承 1_2 损失随迭代次数变化曲线

Fig. 14 Losses change curve with iterations of three optimizers of bearing 1_2

表 8 采用 3 种优化器下轴承 1_2 剩余寿命预测误差

Tab. 8 Remaining useful life prediction errors of three optimizers of bearings 1_2

优化器	e_{\max}	\bar{e}
sgdm	0.408 1	0.183 7
rmsprop	0.056 8	0.014 3
adam	0.053 1	0.021 9

由图 13 和 14 可知, sgdm 优化器在收敛速度和损失值上的表现均远差于 rmsprop 和 adam 优化器。rmsprop 优化器的 RMSE 值大于 adam 优化器, 两者随迭代变化在损失值上较为接近, 但 rmsprop 优化器在迭代过程中存在损失逆降现象, 表现不稳定。同时, 由表 8 可知, adam 优化器的最大绝对误差和平均绝对误差都是三者中最小的, 可见 adam 优化器的整体性能最佳。

4 结 论

由于 CNN 模型难以充分提取原始输入信号的潜在非线性特征, 而 BiLSTM 方法可全面学习时间序列前后向关联信息, 提升模型鲁棒性和泛化能力, 因此提出多尺度卷积双向长短时记忆网络(MSAM-CNN-BiLSTM)的滚动轴承剩余寿命预测方法, 针对 XJTU 轴承数据集中的 1_2, 2_1 和 3_5 的预测误差与传统 LSTM, CNN-LSTM 和 MSAM-CNN-LSTM 3 种方法进行对比分析, 得出如下结论:

(1) 针对轴承加速寿命试验数据, 引入多尺度和注意力机制的方法进行特征提取并完成预测的方法, 较直接以原始信号实现端到端的方法, 更能体现轴承性能退化趋势。

(2) MSAM-CNN-BiLSTM 方法在 3 个数据集中的预测值与实际值最为接近, 预测误差均远小于 LSTM、CNN-LSTM 和 MSAM-CNN-LSTM, 同时 RMSE 值在各迭代步中也是最小的。

(3) 采用 adam、sgdm 和 rmsprop 3 种优化器对轴承 1_2 数据集作对比实验, 通过对比 RMSE 值、损失值随迭代变化曲线以及最大绝对误差和平均绝对误差, 得出 adam 优化器的整体性能较优。

参 考 文 献:

- [1] LEI Y G, LI N P, GUO L, et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction [J]. Mechanical Systems and Signal Processing, 2018, 104: 799 – 834.
- [2] 何正嘉, 曹宏瑞, 裴艳阳, 等. 机械设备运行可靠性评估的发展与思考 [J]. 机械工程学报, 2014, 50(2): 171 – 186.
HE Zheng-jia, CAO Hong-rui, ZI Yan-yang, et al. Developments and thoughts on operational reliability assessment of mechanical equipment [J]. Journal of Mechanical Engineering, 2014, 50 (2): 171 – 186.
- [3] ZHAO Z, QUAN Q, CAI K Y. A profust reliability based approach to prognostics and health management [J]. IEEE Transactions on Reliability, 2014, 63(1): 26 – 41.
- [4] REZAEIANJOUYBARI B, YI S. Deep learning for prognostics and health management: State of the art, challenges, and opportunities [J]. Measurement, 2020, 163: 107929 – 107957.
- [5] LOUTAS T H, DIMITRIOS R, GEORGULAS G. Remaining useful life estimation in rolling bearings utilizing data-driven probabilistic E-support vectors regression [J]. IEEE Transactions on Reliability, 2013, 62(4): 821 – 832.
- [6] 邱晓梅, 隋文涛, 王峰, 等. 基于相关系数和 BP 神经网络的轴承剩余寿命预测 [J]. 组合机床与自动化加工技术, 2019(4): 63 – 65.
QIU Xiao-mei, SUI Wen-tao, WANG Feng, et al. Remaining life prediction of bearing based on correlation coefficient and BP neural network [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2019(4): 63 – 65.
- [7] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战 [J]. 控制与决策, 2017, 32(8): 1345 – 1358.
REN Hao, QU Jian-feng, CHAI Yi, et al. Deep learning for fault diagnosis: The state of the art and challenge [J]. Control and Decision, 2017, 32(8): 1345 – 1358.
- [8] GUO L, LI N, JIA F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings [J]. Neurocomputing, 2017, 240: 98 – 109.
- [9] REN L, CUI J, SUN Y, et al. Multi-bearing remaining useful life collaborative prediction: A deep learning approach [J]. Journal of Manufacturing Systems, 2017, 43: 248 – 256.
- [10] 张继冬, 邹益胜, 邓佳林, 等. 基于全卷积层神经网络的轴承剩余寿命预测 [J]. 中国机械工程, 2019, 30 (18): 2231 – 2235.
ZHANG Ji-dong, ZHOU Yi-sheng, DENG Jia-lin, et al. Bearing remaining life prediction based on full convolutional layer neural networks [J]. China Mechanical Engineering, 2019, 30 (18):

2231–2235.

- [11] 杨小东,纪国宜. 基于融合 CNN 的滚动轴承剩余寿命预测[J]. 国外电子测量技术,2021,40(3):62–67.

YANG Xiao-dong, JI Guo-yi. Remaining useful lifetime prediction method of rolling bearing based on fusion-CNN[J]. Foreign Electronic Measurement Technology, 2021, 40(3): 62–67.

- [12] 和志强,杨 建,罗长玲. 基于 BiLSTM 神经网络的特征融合短文本分类算法[J]. 智能计算机与应用,2019,9(2):21–27.

HE Zhi-qiang, YANG Jian, LUO Chang-ling. Combination characteristics based on BiLSTM for short text classification[J]. Intelligent Computer and Applications, 2019, 9(2): 21–27.

- [13] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11):2673–2681.

- [14] 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 Zhi-hong, ZHAO Jing-jiao, WEI Zi-yang. Rolling bearing fault diagnosis based on BiLSTM network[J]. Journal of Vibra-

tion and Shock, 2021, 40(1): 95–101.

- [15] 李彦冬,郝宗波,雷 航. 卷积神经网络研究综述[J]. 计算机应用,2016,36(9):2508–2515,2565.

LI Yan-dong, HAO Zong-bo, LEI Hang. Survey of convolutional neural network [J]. Journal of Computer Applications, 2016, 36(9): 2508–2515, 2565.

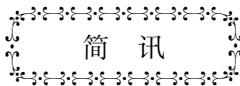
- [16] XU Z, LI C, YANG Y. Fault diagnosis of rolling bearings using an improved multi-scale convolutional neural network with feature attention mechanism[J]. ISA Transactions, 2021, 110:379–393.

- [17] WANG B, LEI Y G, LI N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2020, 69(1):401–412.

- [18] 樊名鲁,王 艳,纪志成. 基于特征生成的轴承不均衡数据故障诊断[J]. 系统仿真学报,2020,32(12):2438–2448.

FAN Ming-lu, WANG Yan, JI Zhi-cheng. Fault diagnosis for bearing of unbalanced data based on feature generation[J]. Journal of System Simulation, 2020, 32(12): 2438–2448.

(丛 敏 编辑)



GE Vernova 和 IHI 联合开发 100% 燃氨 F 级燃气轮机

据官方报道,GE Vernova 公司和日本 IHI 公司签署了一项联合开发协议,以推进一种能够将氨作为燃料的新型燃气轮机燃烧室的开发进展。该合作基于两家公司之间的较早协议,并建立在 IHI 成功开发的燃烧 100% 液态氨的 2 MW 燃气轮机的基础上。该项目将测试氨作为一种可行的燃料选择,与 GE Vernova 的 6F.03、7F 和 9F 级燃气轮机兼容,并旨在减少 99% 以上氨燃烧产生的温室气体。

GE 公司的一份声明强调,“在不更换现有燃气轮机的情况下,使用传统燃料的发电厂可以通过将天然气燃烧器更换为新的氨燃烧器,并对燃料系统进行升级以及对电厂系统进行相关平衡,从而升级为使用燃烧时不产生碳排放的燃料。”IHI 业务发展总部副总裁兼氨价值链项目部门总经理 Kensuke Yamamoto 也对该公告发表了评论,“在各种氢载体中,氨对日本等燃料进口国来说是一种真正可行的脱碳途径。IHI 的氨燃烧技术可以直接使用氨作为碳中和燃料。”

(孙嘉忆摘译自 <https://www.powerengineeringint.com>)