

陈亚荣, 钟倩文, 陈谢祺, 等. 基于 MA-TCN 的滚动轴承剩余寿命预测 [J]. 智能计算机与应用, 2025, 15(9): 112-116. DOI: 10.20169/j. issn. 2095-2163. 250918

# 基于 MA-TCN 的滚动轴承剩余寿命预测

陈亚荣<sup>1</sup>, 钟倩文<sup>1</sup>, 陈谢祺<sup>1</sup>, 彭乐乐<sup>1</sup>, 郑树彬<sup>1,2</sup>

(1 上海工程技术大学 城市轨道交通学院, 上海 201620; 2 上海工程技术大学 高等职业技术学院, 上海 200437)

**摘要:** 针对轴承退化信息提取不全面导致轴承剩余寿命预测不精准的问题, 本文提出提取原始振动信号多维度特征建立特征集, 使用融合多头注意力机制的时间卷积网络(MA-TCN)进行轴承的寿命预测。研究中, 提取常用时域特征 15 维、频域特征 10 维作为混合特征集, 并用作输入对轴承进行剩余寿命预测, 采用 MA-TCN 网络, 实现轴承的剩余寿命预测。PHM2012 数据集的轴承预测结果可决系数均达到 91% 以上, 证明该方法能够对轴承的剩余寿命进行精确预测。

**关键词:** 特征提取; 剩余寿命预测; 时间卷积网络; 多头注意力机制

中图分类号: TH133.3; TP183 文献标志码: A 文章编号: 2095-2163(2025)09-0112-05

## Rolling bearing life prediction based on MA-TCN

CHEN Yarong<sup>1</sup>, ZHONG Qianwen<sup>1</sup>, CHEN Xieqi<sup>1</sup>, PENG Lele<sup>1</sup>, ZHENG Shubin<sup>1,2</sup>

(1 School of Urban Railway Transportation, Shanghai University of Engineering Science, Shanghai 201620, China;

2 Advanced Vocational Technical College, Shanghai University of Engineering Science, Shanghai 200437, China)

**Abstract:** Aiming at the problem of imprecise bearing life prediction due to incomplete extraction of bearing degradation information, this paper proposes extracting multidimensional features of the original vibration signals to establish a feature set, and use a Multi-head Attention integrated Temporal Convolutional Network (MA-TCN) to carry out the life prediction of bearings. In the research, 15 dimensions of commonly used time-domain features and 10 dimensions of frequency-domain features are extracted as a hybrid feature set, which are used as inputs for life prediction of bearings using MA-TCN network. The decidability coefficients of the bearing prediction results of the PHM2012 dataset all reach more than 91%, which proves that the method can accurately carry out the life prediction of bearings.

**Key words:** feature extraction; RUL; temporal convolutional network; multiple attention mechanism

## 0 引言

滚动轴承作为轨道交通车辆的关键部件之一, 被广泛应用于车辆的行走部、电机等设备中, 其运行状态的好坏将直接影响轨道交通的安全运行。运行轴承的意外故障会增加机器的停机时间和维护成本, 从而造成重大的经济损失<sup>[1]</sup>。因此, 预测滚动轴承的剩余使用寿命对整个设备的健康评估具有重要意义。

针对滚动轴承状态分析方法主要有振动信号分析法<sup>[2]</sup>、温度分析法<sup>[3]</sup>以及油液分析法<sup>[4]</sup>等, 而轴承在受到损伤后, 会发出一种高频脉冲激励信号, 即振动信号, 振动信号特性稳定且易于采集, 这使得振

动分析成为一种合适且具有发展前景的滚动轴承状态监测技术<sup>[5]</sup>。轴承的振动信号受轨道激励和环境噪声的影响, 表现为复杂的非线性和非平稳信号, 通过传感器收集其振动加速度数据并进行后期分析, 以获得相应的系统故障信息<sup>[6]</sup>。从振动信号中提取的特征包含了机器部件的健康状态信息, 在轴承预测中起着至关重要的作用。但使用传感器采集轴承原始振动信号时, 由于该信号内存在许多噪声信息, 提取能够判别轴承运行状态的信息是轴承寿命预测的关键, 因此不同领域(即时间、频率和时频域<sup>[7]</sup>)的信号处理技术已应用于采集的振动数据研究, 用来提取各种原始特征<sup>[8]</sup>。

在现有的一些研究中, Sutrisno 等学者<sup>[9]</sup>提取轴

基金项目: 上海市科技计划项目(22010501600); 上海申通地铁集团资助项目(JS-KY20R013-3)。

作者简介: 陈亚荣(1999—), 女, 硕士研究生, 主要研究方向: 轴承运行状态评估及剩余寿命预测。

通信作者: 钟倩文(1986—), 女, 博士, 讲师, 主要研究方向: 轨道交通设备状态分析与评估, 智能检测。Email: qianwen.zhong@sues.edu.cn。

收稿日期: 2023-12-25

哈尔滨工业大学主办 ◆ 系统开发与应用

承的时频域特征并进行PCA降维后,通过使用最小二乘支持向量机(LSSVM)回归方法实现了剩余使用寿命(RUL)预测。Guo等学者<sup>[10]</sup>提取了6个相关相似特征与8个经典时频特征,并根据得分指标选择了最优的10种特征,随后在寿命预测阶段用递归神经网络(RNN)将其映射到RUL标签中。Wang等学者<sup>[11]</sup>在去噪经验模态函数中提取6个时频域特征来表征轴承的退化。特征数量少,包含信息不够全面。

对于轴承的RUL,目前已经有许多神经网络运用到该领域研究中,包括卷积神经网络<sup>[12]</sup>(CNNs)和递归神经网络,如长短期记忆<sup>[13]</sup>(LSTM)、门递归单元(GRU)。Ren等学者<sup>[14]</sup>提出一种基于深度卷积神经网络(DCNN)的轴承RUL预测新方法。Yang等学者<sup>[15]</sup>提出了一种基于不确定性量化的长短期记忆(LSTM)轴承RUL预测新方法,其中该方法可以自适应地提取特征。Eknath等学者<sup>[16]</sup>提出了一种新的预测方法。该方法结合了深度卷积神经网络(DCNN)和门控循环单元(GRU),建立了一个双向循环层,可以专注于过去的数据,同时嵌入未来的信息,以增强GRU模型吸收数据的潜力。Cao等学者<sup>[17]</sup>提出了一种具有残差自注意机制的时间卷积网络(TCN),TCN具有预测精度高、运算速度快的特点,适用于处理时序问题,解决了RNN及其变体网络无法并行处理的问题,实现了端到端的RUL预测。然而,上述方法通常强调振动信息的时间相关性,却忽略了轴承对外部干扰的敏感性增加以及随着轴承的逐渐退化振动信号不稳定性的影晌。振动信号变化幅度和严重程度的复杂性导致网络在学习轴承退化阶段的特性时存在较大误差。

针对以上论述,本文着重解决目前对于轴承退化信息提取不全面导致的轴承RUL预测不精准的问题。在原始振动信号提取时域、频域特征共25维特征,就能够较为充分地挖掘原始振动信号所包含的轴承退化信息。

## 1 TCN原理

TCN<sup>[18]</sup>是一种基于改进的1-D-CNN的新时间序列模型,其核心思想是通过因果卷积来处理时间数据,并引入扩展卷积来解决时间序列模型对长距离依赖的问题。与传统的CNN相比,TCN有以下改进:

(1)卷积层之间存在因果关系,能够根据历史信息预测未来信息,有效减少信息损失。

(2)利用残差连接层和扩展卷积来加深网络层数,使网络具有长期记忆能力,在处理时间序列方面更有优势。本文研发TCN的因果扩张卷积结构如图1所示。

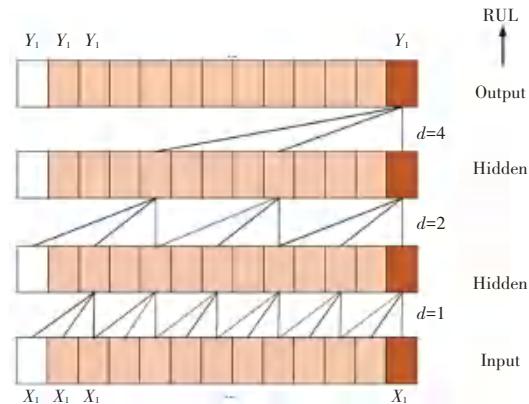


图1 TCN结构图

Fig. 1 TCN structure

在TCN中,输入和输出之间的映射如下所示:

$$Y = F_r(X) \quad (1)$$

其中,  $F_r(\cdot)$  表示TCN模型;  $X = \{x_0, x_1, x_2, \dots, x_{t-1}, x_t\}$  表示  $t$  时刻的输入混合域特征序列;  $Y = \{y_0, y_1, \dots, y_{t-1}, y_t\}$  表示对应的输出序列。

在TCN中,随着因果展开卷积的引入,网络层数会加深,但其性能反而会逐渐下降,这可能是由于以下原因引起的:首先,由于网络结构更深,训练时间成本更高,网络在反向传播过程中将更难收敛。其次,网络结构越深,常数映射就越难实现,模型优化就越难。为了解决上述问题,在TCN中引入了剩余连接模块。与通过拟合线性叠加网络层形成的常数映射相比,残差映射更容易优化,并且可以使网络更快、更有效地收敛。剩余连接模块的结构,其定义如下:

$$x_{n+1} = \varphi(x_n + F(x_n, \zeta_n)) \quad (2)$$

其中,  $x_n$  表示第  $n$  级的输入序列;  $x_{n+1}$  表示残差块的输出;  $F(x_n, \zeta_n)$  表示残差映射,通常由2~3个因果展开卷积运算  $\zeta_n$  组成;  $\varphi(\cdot)$  表示激活函数。

## 2 多头注意力机制原理

对于轴承振动信号中包含的退化信息在其使用寿命内发生变化,并且这种变化通常随着退化的增加而愈加凸显。注意力模块的目的是促使网络研究与退化过程密切相关的时序数据中的隐藏知识,并抑制特征学习过程中的冗余信息。反映在结构的内部计算中,通过为每个传入的退化数据分配不同的权重来构建注意力矩阵,从而实现矩阵重建。

通常,自注意力机制包括查询矩阵  $\mathbf{Q}$ 、关键字矩阵  $\mathbf{K}$  和数值矩阵  $\mathbf{V}$ 。自注意力的定义如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (3)$$

其中,  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  表示线性映射的形式, 定义为  $\mathbf{Q} = \mathbf{W}^q \mathbf{e}_i, \mathbf{K} = \mathbf{W}^k \mathbf{e}_i$  和  $\mathbf{V} = \mathbf{W}^v \mathbf{e}_i$ ;  $d_k$  表示要投影的尺寸。

多头注意力<sup>[19]</sup>通过式(3)的多重自注意力操作将输入特征投射到不同的子空间, 获取多个子空间的注意力向量, 然后将这些注意力向量集合在一起。通过多头注意力模型, 能够从多个角度探讨不同嵌入方式间的相关性, 以提高模型的性能。多头注意力的具体定义如下所示。

$$\text{Multihead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) \quad (4)$$

$$\text{head}_i = \text{Attention}(\mathbf{Q}\mathbf{W}_i^q, \mathbf{K}\mathbf{W}_i^k, \mathbf{V}\mathbf{W}_i^v) \quad (5)$$

多头注意力的输出级联了单层前馈神经网络(FFNN), 通过残差连接, 将注意力权重  $a_i$  输入到神经网络中, 得到最终输出  $h^{\text{attention}}$ , 定义如下:

$$h^{\text{attention}} = \text{Sigmoid}(\mathbf{W}_{\text{ffnn}} a_i + b_{\text{ffnn}} + a_i) \quad (6)$$

### 3 基于 MA-TCN 的轴承寿命预测方法

#### 3.1 方法流程

滚动轴承寿命预测的具体流程如图 2 所示。

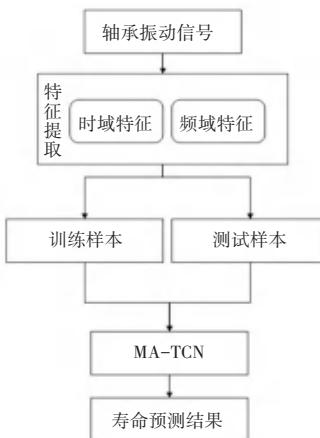


图 2 滚动轴承寿命预测流程图

Fig. 2 Flow chart of rolling bearing life prediction

#### 3.2 PHM2012 数据集

实验数据来自 2012 年 PHM 会议上发布的全寿命数据集, 数据是在 PRONOTIA 实验中收集的。PRONOTIA 实验台如图 3 所示。文献[20]中给出了具体描述, 主要由旋转模块、加载模块和测量模块组成。

收集 3 种不同负载的数据集。第一种是电机转速为 1 800 rpm, 负载为 4 000 N; 其他 2 种工况下的电机转速和负载分别 1 625 rpm 和 4 200 N、

1 500 rpm 和 5 000 N。实验中没有添加人为故障, 所有故障都是轴承的自然降解过程, 与实际工业场景一致。其采样频率为 25.6 kHz, 采样时间为 0.1 s, 每隔 10 s 采集一次。在本文中, 选择了在工况一下数据集中的 4 组轴承来证明所提出的方法的有效性。



图 3 PRONOTIA 实验台

Fig. 3 PRONOTIA experiment table

#### 3.3 特征提取

对原始振动信号提取 15 维时域特征, 分别为: 最大值、最小值、平均值、峰-峰值、绝对均值、标准差、方差、RMS、峰度、峰值、方根幅值、波形因子、峭度因子、脉冲因子和裕度因子; 对原始振动信号与重构信号提取 10 维频域特征, 分别为: 频谱幅值样本均值、平均频率、频率均方根值、频率方差、表征主频带位置、频率能量集中度、频谱能量集中度、频率偏度、频率峭度和标准化频谱均值。

#### 3.4 时间卷积网络参数设置

为了能精度较高的进行寿命预测, 需要设计时间卷积网络(TCN)结构。通过控制变量法对 TCN 进行实验, 最终来确定网络的结构以及参数。实验分组情况见表 1。

表 1 实验分组情况

Table 1 Experimental groupings

组号	卷积核膨胀率	激活函数	卷积核
1	(1, 2, 4, 8)	LeakyReLU	3×3
2	(1, 2, 4, 8)	LeakyReLU	5×5
3	(1, 2, 4, 8)	ReLU	3×3
4	(1, 2, 4, 8)	ReLU	5×5

通过数据集对表 1 设计的各组网络进行逐一训练、测试对比, 最终确定了网络结构。确定激活函数为 LeakyReLU, 卷积层的卷积核大小为 3×3。

#### 3.5 寿命预测结果评估指标及参数确定

为了评估模型的性能, 选择了 5 个性能指标进行评估, 即均方误差(MSE), 均方根差(RMSE), 平均绝对误差(MAE), 可决系数( $R^2$ ), 以及性能得分(Score)。定义公式如下<sup>[21]</sup>:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (7)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (8)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (10)$$

$$\text{Score} = 1 - \sqrt{\frac{\text{MSE}}{\sum_{i=1}^n (\bar{y}_i - y_i)^2/n} - \frac{\text{MAE}}{\sum_{i=1}^n y_i/n}} \quad (11)$$

其中,  $y_i$  表示真实值;  $\hat{y}_i$  表示预测值;  $\bar{y}_i$  表示真实值的平均数。

在确定了时间卷积网络的结构后, 加入多头注意力机制, 对其头数的设置做了以下实验, 得到结果见表 2。

表 2 多头注意力的数量

Table 2 Number of multi-head attention

方案	多头注意力的数量					
	1	2	4	8	16	32
MA	0.000 3	0.018 5	0.014 2	0.996 0	0.908 8	
Bearing1_1	0.001 3	0.036 8	0.026 2	0.985 2	0.873 9	
Bearing1_3	0.008 7	0.093 1	0.076 3	0.919 5	0.616 2	
Bearing1_4	0.002 8	0.053 5	0.042 4	0.966 7	0.738 5	
Bearing1_7						

为了进行全面的交叉验证, 从 4 个轴承中选择 3 个, 依次训练寿命预测模型, 然后使用另一个轴承来测试模型。

通过实验探究不同多头注意力数量对轴承寿命预测结果的影响, 以测试集 4 个轴承的 MSE, RMSE, MAE,  $R^2$  以及 Score 作为评价指标, 其中前 3 个越接近 0 效果越好, 后 2 个越接近 1 效果越好, 取 5 次实验平均值。实验结果分别如图 4、图 5 所示。

由图 4、图 5 可以看出, 当多头注意力的数量为 8 时, 其 MSE、RMSE、MAE 指标最低,  $R^2$  以及 Score 指标最高。故选择超参数多头注意力的数目为 16。

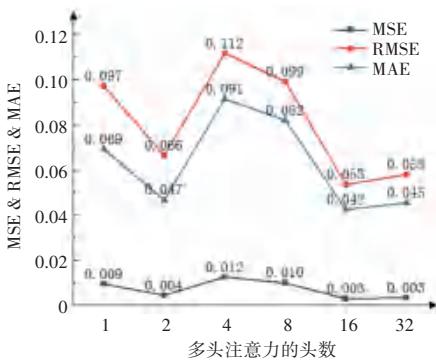


Fig. 4 MSE, RMSE and MAE metrics

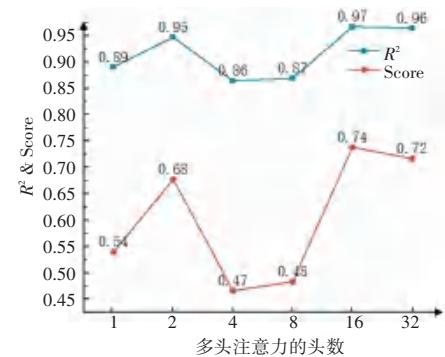


图 5  $R^2$ 、Score 指标

Fig. 5  $R^2$ , Score metrics

### 3.6 预测结果

实验预测结果见表 3。根据预测结果可以看出, Bearing1-1 与 Bearing1-3 的效果最好, 原因可能是 Bearing1-1 与 Bearing1-3 的数据模式最为相似, 而 Bearing1-4 与 Bearing1-7 的数据模式可能与 Bearing1-1 与 Bearing1-3 存在些许差异, 但总体效果较好, 并且可决系数均已达到 0.91 及以上, 说明拟合效果较好。

表 3 实验结果

Table 3 Results of experiments

轴承	MSE	RMSE	MAE	$R^2$	Score
Bearing1_1	0.000 3	0.018 5	0.014 2	0.996 0	0.908 8
Bearing1_3	0.001 3	0.036 8	0.026 2	0.985 2	0.873 9
Bearing1_4	0.008 7	0.093 1	0.076 3	0.919 5	0.616 2
Bearing1_7	0.002 8	0.053 5	0.042 4	0.966 7	0.738 5

为了更好地对比出本文方法, 设置了消融实验以及与其他方法的对比试验, 以 Bearing1-7 为例, 其结果如图 6 所示。

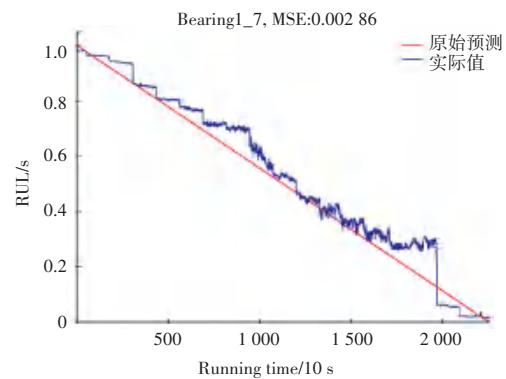


图 6 Bearing1-1 寿命预测结果图

Fig. 6 Bearing1-1 RUL result chart

通过不同方法对比如图 7 所示, 对比结果见表 4。可以发现 TCN 对比 LSTM、CNN、GRU 具有更高的精度, 增加了多头注意力机制后, 其 MSE、RMSE、MAE 均有下降, 且  $R^2$  与性能评分 Score 分数分别提

升了 0.04 和 0.08,有更高的预测精度。

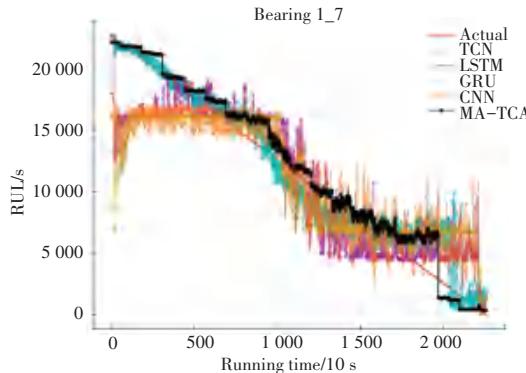


图 7 寿命预测对比图

Fig. 7 Comparison of RUL

表 4 实验结果对比

Table 4 Comparison of experimental results

方法	MSE	RMSE	MAE	$R^2$	Score
TCN	0.004 9	0.07	0.050	0.93	0.65
LSTM	0.016 0	0.13	0.100	0.81	0.36
CNN	0.017 5	0.13	0.100	0.78	0.35
GRU	0.022 7	0.15	0.120	0.72	0.23
MA-TCN	<b>0.002 8</b>	<b>0.05</b>	<b>0.042</b>	<b>0.97</b>	<b>0.73</b>

## 4 结束语

在寿命预测模型中,本文在原始振动信号提取特征,并且采用多头注意力机制的时间卷积网络来展开研究,时间卷积网络具有深层结构,可以捕捉时间序列数据中的长期依赖性。而通过增加多头注意力机制,网络可以更好地关注不同时间步之间的相关性,从而更有效地学习长期依赖关系。并且多头注意力机制可以融合不同时间步的特征,得到更丰富和更有意义的表示。增加了多头注意力机制的时间卷积网络具有更高的预测精度,能够准确地捕捉轴承退化信息,根据预测结果,其可决系数均达到 0.91 以上,轴承 RUL 的预测精度得到了有效提升。

## 参考文献

- [1] EL-THALJI I, JANTUNEN E. A summary of fault modelling and predictive health monitoring of rolling element bearings [J]. Mechanical Systems and Signal Processing, 2015, 60-61: 252-272.
- [2] 徐斌. 城轨转向架轴承故障诊断与运行维护[J]. 机械工程与自动化, 2021(6): 221-223.
- [3] 邵明伟. 基于 NSET 的高速列车轴箱轴承温度预警研究[D]. 兰州: 兰州交通大学, 2020.
- [4] 张春福, 徐丽娟, 于海波, 等. 基于油温与油液分析法的滑动轴承故障诊断[J]. 黑龙江工程学院学报(自然科学版), 2009, 23 (3): 60-62.
- [5] 隋文涛, 张丹, 金亚军, 等. 滚动轴承的退化状态划分与剩余寿命预测[J]. 机械设计与制造, 2022(12): 301-304.
- [6] HENG A, TAN A C C, MATHEW J, et al. Intelligent condition-based prediction of machinery reliability[J]. Mechanical Systems and Signal Processing, 2009, 23(5): 1600-1614.
- [7] WANG H, DU W. An improved spectrum correlation time-frequency analysis method and its application in fault diagnosis of rolling element bearing [J]. Journal of Vibroengineering, 2020, 22(1): 792-803.
- [8] LEI Yaguo. Signal processing and feature extraction [M]// Intelligent Fault Diagnosis and Remaining Useful Life Prediction of Rotating Machinery. New York: Elsevier Inc., 2017: 17-66.
- [9] SUTRISNO E, OH H, VASAN A S S, et al. Estimation of remaining useful life of ball bearings using data driven methodologies[C]// Proceedings of 2012 IEEE Conference on Prognostics and Health Management. Piscataway, NJ: IEEE, 2012: 1-7.
- [10] GUO Liang, LI Naipeng, JIA Feng, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98-109.
- [11] WANG Wenbo, ZHAO Jiaojiao, Ding G. RUL prediction of rolling bearings based on improved empirical wavelet transform and convolutional neural network [J]. Advances in Mechanical Engineering, 2022, 14(6): 16878132221106609.
- [12] YU Wen, PI Dechang, XIE Lingqiang, et al. Multiscale attentional residual neural network framework for remaining useful life prediction of bearings[J]. Measurement, 2021, 177: 109310.
- [13] DONG S, XIAO J, HU X, et al. Deep transfer learning based on Bi-LSTM and attention for remaining useful life prediction of rolling bearing [J]. Reliability Engineering & System Safety, 2023, 230: 108914.
- [14] REN Lei, SUN Yaqiang, WANG Hao, et al. Prediction of bearing remaining useful life with deep convolution neural network [J]. IEEE Access, 2018, 6: 13041-13049.
- [15] YANG J, PENG Y, XIE J, et al. Remaining useful life prediction method for bearings based on LSTM with uncertainty quantification [J]. Sensors, 2022, 22(12): 4549.
- [16] EKNATH K G, DIWAKAR G. Prediction of remaining useful life of rolling bearing using hybrid DCNN-BiGRU model[J]. Journal of Vibration Engineering & Technologies, 2023, 11(3): 997-1010.
- [17] CAO Yudong, DING Yifei, JIA Minping, et al. A novel temporal convolutional network with residual self-attention mechanism for remaining useful life prediction of rolling bearings [J]. Reliability Engineering & System Safety, 2021, 215: 107813.
- [18] 胡勇, 李孝忠. 基于 EMD 和改进 TCN 的滚动轴承剩余寿命预测方法[J]. 天津科技大学学报, 2023, 38(6): 62-68.
- [19] VASWANI A, SHAZER N, PARMAR N, et al. Attention is all you need [C]// Advances in Neural Information Processing Systems. Long Beach, USA: NIPS Foundation, 2017: 5998-6008.
- [20] NECTOUX P, GOURIVEAU R, MEDJAHER K, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests [C]// Proceedings of the IEEE International Conference on Prognostics and Health Management. Piscataway, NJ: IEEE, 2012: 1-8.
- [21] GUO Runxia, WANG Yu, ZHANG Haochi, et al. Remaining useful life prediction for rolling bearings using EMD-RISI-LSTM [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3509812.