

基于多通道融合的滚动轴承剩余寿命预测*

车鲁阳^{1,2} 高军伟^{1,2} 付惠琛^{1,2}

(1. 青岛大学自动化学院 青岛 266071; 2. 山东省工业控制技术重点实验室 青岛 266071)

摘要:针对工业生产中滚动轴承剩余使用寿命(RUL)预测任务中数据挖掘不足导致预测精度低的问题,提出了一种多通道融合的滚动轴承剩余寿命预测方法。该方法通过互补集合经验模态分解(CEEMD)对原始振动信号进行降噪化处理和特征增强并将其作为模型输入;构建三通道网络模型,引入3种不同的神经网络:时间卷积网络(TCN)、卷积长短期记忆网络(ConvLSTM)、双向门控循环单元神经网络(Bi-GRU),从时序、空间、感受野等多维度对特征进行差异化提取;在结构基础上添加多头注意力机制(multi-head attention mechanism, MA),重新调整网络输出权重、加快模型收敛速度;最后,设计一个特征融合输出模块,实现对滚动轴承剩余寿命预测。在两种数据集上进行实验验证,并与其他文献中先进模型进行对比。结果表明,所提模型能够更准确地捕捉轴承寿命退化曲线并且在多种评价指标上均优于对比模型。

关键词:滚动轴承;寿命预测;多特征融合;三通道网络模型;多头注意力机制

中图分类号: TN911.7; TH165.3

文献标识码: A

国家标准学科分类代码: 460.1520

Residual life prediction of rolling bearings based on multi-feature fusion

Che Luyang^{1,2} Gao Junwei^{1,2} Fu Huichen^{1,2}

(1. College of Automation, Qingdao University, Qingdao 266071, China; 2. Shandong Provincial Key Laboratory of Industrial Control Technology, Qingdao 266071, China)

Abstract: In order to solve the problem of low prediction accuracy caused by insufficient data mining in the prediction task of remaining useful life (RUL) of rolling bearings in industrial production, a multi-channel fusion method for predicting the remaining life of rolling bearings was proposed. In this method, the original vibration signal is denoised and feature enhanced by complementary ensemble empirical mode decomposition (CEEMD) is taken as input. A three-channel network model was constructed, and three different neural networks were introduced: Temporal convolutional networks (TCN), convolutional long short-term memory network (ConvLSTM), and bidirectional gated recurrent unit neural network (Bi-GRU), which differentially extracts features from multiple dimensions such as time series, space, and receptive field. The multi-head attention mechanism (MA) is added on the basis of the structure to readjust the output weight of the network and accelerate the convergence speed of the model. Finally, a feature fusion output module was designed to predict the remaining life of rolling bearings. Experimental verification was carried out on two datasets and compared with the advanced models in other literatures. The results show that the proposed model can capture the bearing life degradation curve more accurately, and is better than the comparison model in a variety of evaluation indicators.

Keywords: rolling bearings; life prediction; multi-feature fusion; three-branch network model; multi-head attention mechanism

0 引言

滚动轴承作为旋转机械关键部件之一,其健康状态

直接影响生产安全^[1]。因此,发展合理、有效的运营维护技术如剩余寿命(remaining useful life, RUL)预测变得尤为重要^[2]。随着工业互联网的发展,各式传感器监测数据爆发式增长,如何有效地对其加以利用成为了解决问

题的关键。

目前,剩余寿命预测基本分为两种方法:基于物理模型预测^[3]和基于数据驱动预测^[4]。前者只有当模型参数能够轻松准确地得到,并且有足够的计算资源实时实现时,才有可能取得符合预期的理想精度,且模型的泛化能力差、成本高;后者由于采集技术的不断发展,能够充分挖掘数据特征进行预测,不依赖物理模型且精度越来越高,在这些年被广泛研究。

对于数据驱动方法,早期的机器学习方法,如马尔可夫模型^[5]、支持向量机^[6]、人工神经网络等方法已经展露出不错的数据处理能力,但由于结构简单导致预测精度并不高。随着硬件成熟和人工智能技术发展,深度学习凭借着深层网络结构,能够更好地追踪寿命退化趋势而被广泛应用^[7]。传统的卷积神经网络(convolutional neural networks, CNN)^[8]和长短时间记忆神经网络(long short-term memory, LSTM)^[9]虽然初步实现了对轴承剩余寿命的预测,但存在着对特征时序性不敏感或者模型训练收敛速度慢等问题,导致精度并不高。随着研究的深入,在基础卷积的基础上,Wang 等^[10]引入时间卷积网络(temporal convolutional networks, TCN),利用膨胀卷积和残差结构,获得更大感受野和更快的计算速度。陈维兴等^[11]利用卷积长短时间记忆网络(convolutional long short-term memory network, ConvLSTM)对基础 LSTM 进行改进,不仅有着稀疏连通性和参数共享的优点,还能够捕获数据长期依赖关系,在航空发动机的寿命预测中取得了不错的效果,也提供了一定的思路。多数学者基本都将研究重点放在单一的网络结构的研究,对于数据的挖掘只停留在较浅阶段,忽略了每种网络都有各自的局限性,导致精度难以进一步提升。近几年开始,慢慢有学者关注到了数据挖掘方面工作的重要性。马占伟等^[12]提出了一种多尺度特征,给网络以不同长度的数据,从而使得网络学习到多维度的特征,但是忽略了对神经网络本身的探索,导致学习到的特征其本质上没有差别。Gao^[13]和钟建华等^[14]都提出了一种双通道模型,虽然精度有所提升,但是在两通道网络的选择上相对单一,无法学习多层次的特征。而且多通道网络模型本身由于结构相对复杂,带来的训练时间长等问题也少有提及。

因此,针对上述研究的局限性,提出了一种多通道融合的滚动轴承剩余寿命预测模型。主要贡献有 3 个方面:

1) 引入了一种改进的信号处理方法:互补集合经验分解互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)算法,对振动信号进行模态分解和降噪。

2) 提出了一种多通道网络融合框架并引入 3 种传统网络的改进网络,对输入特征通过时序、时间、空间等多

种维度进行深度挖掘并自适应各自学习到的权重。

3) 为了加快模型训练收敛速度,引入一种目前热门的大语言模型 Transformer 中的注意力机制^[15]:多头注意力机制,将网络学得的多种特征权重映射到子空间,进行权重重构,重点关注对于退化趋势影响大的特征,找到最佳的优化方案。

为了验证所提方法的有效性,分别通过 PHM2012 公开轴承数据集和实验室自采集数据集进行验证。

1 RUL 预测模型

1.1 预测方法整体框架

提出基于多通道融合的滚动轴承 RUL 预测方法框架如图 1 所示,主要包括数据预处理和网络预测两部分。数据预处理包含振动信号时、频域分解、互补集合经验模态分解、标准化及时间窗处理,将预处理后的特征输入到搭建的多通道融合网络中,得到最终的预测值。




图 1 剩余寿命预测步骤

Fig. 1 Residual life prediction steps

1.2 算法介绍

1) 互补集合经验模态分解

为了得到滚动轴承退化特性的完整描述,采用时域、频域方法提取了多个特征。其中包括均方根值、绝对平均值、平方根振幅、方差、峰峰值、偏度、峭度、峰值因子、波形因子和脉冲指数 10 个时域特征以及频域均值、频域方差、频域均方根和歪度 4 个频域特征。这些特征几乎涵盖了轴承退化所有阶段,能够较好地反应轴承健康状态的退化过程。

但是,直接使用上述提取信号噪声干扰大,因此引入 CEEMD 信号分解方法,在振动信号中添加独立同分布的正负白噪声对,以达到抑制模态混叠效应的以及消除噪声的目的。其主要计算过程包括如下 3 方面:

(1) 在原始振动序列 C 上添加 a 组互为相反数的正负噪声对,得到新的序列 I_1, I_2 。

$$\begin{bmatrix} I_1 \\ I_2 \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} C \\ N \end{bmatrix} \tag{1}$$

式中： I_1 、 I_2 分别为加入白噪声对后的正负噪声序列， C 为原始振动序列， N 为添加的白噪声。

(2) 通过 I_1 、 I_2 分解得到 b 个 IMF 分量，并将得到的第 i 个序列第 j 个 IMF 分量记为 $C_{i,j}$ ，其中 $i=1,\cdots,a$ ， $j=1,\cdots,b$ 。

(3) 对所有 IMF 分量进行平均得到最后分解结果：

$$IMF_j = \frac{1}{2a} \sum_{i=1}^{2a} C_{i,j} \tag{2}$$

式中： IMF_j 表示得到的第 j 组 IMF 分量。

2) 时间卷积神经网络

CNN 在图像识别领域的应用更加广泛，在处理时间序列的问题上有着局部感知能力有限、学习长期依赖困难等局限性。为了使得神经网络能够对序列数据进行时间建模，引入 CNN 的一种变体即 TCN，其由膨胀因果卷积和残差模块组成。

在解决时序问题上，需要追溯历史信息，历史信息越久远，隐藏层越多，计算量越大。为了既能够增大感受野又不使得隐藏层过多，膨胀因果卷积引入了一个新的超参数—扩张率 d ，在不损失信息的情况下，允许模型间隔采样。残差模块使信息能够跨越层数传递，从而避免层数过多而造成信息损失。

3) 卷积长短时间记忆网络

许多研究证明，LSTM 在剩余寿命预测领域的有效性，但是其本身由于复杂的结构导致计算复杂度高并且对于更加长期的关系依赖建模仍存在不足。因此引入 ConvLSTM，在 LSTM 结构的基础上加入了卷积结构，使其不仅有着稀疏连通性和参数共享的优点，在计算速度提高的同时还能够捕获数据长期依赖关系。

4) 双向门控循环单元神经网络

门控循环单元神经网络 (gated recurrent unit neural network, GRU) 作为 LSTM 的改进，本身就有着计算量少、梯度不易消失和爆炸的优点。然而，GRU 只能利用先前的时间信息进行预测，无法利用未来的信息。针对这个问题，引入双向门控循环单元神经网络 (bidirectional gated recurrent unit neural network, Bi-GRU)^[16]，它在 GRU 的基础上增加了反向循环机制，从而实现双向时间信息的处理。Bi-GRU 能够同时考虑前向和后向的隐藏层信息，比 GRU 具有更强大、更稳定的特征学习能力。

5) 多头注意力机制

自注意力机制同 TCN 类似，能够捕捉发动机剩余寿命退化趋势，使得模型更加关注退化影响权重高的变量。一般来说，自注意力机制有查询矩阵 Q 、关键字矩阵 K 、和关键字矩阵 V 。其定义如下所示：

$$Attention(Q,K,V) = softmax(\frac{QK^T}{\sqrt{d_k}})V \tag{3}$$

式中： Q 、 K 和 V 分别是线性映射格式，定义为 $Q = W^qe_i$ ， $K = W^k e_i$ 和 $V = W^v e_i$ ； d_k 表示投影的尺寸。

$$Multihead(Q,K,V) = Concat(head_1,\cdots,head_h) \tag{4}$$

多头注意力机制通过式 (4) 的多重自注意力操作将输入特征映射到不同的子空间，获取多个子空间的注意力向量，然后将其组合，从而可以多个角度分析嵌入方式之间的相关性，提高模型性能。多头注意力定义如下：

$$head_i = Attention(QW_i^Q,KW_i^K,VW_i^V) \tag{5}$$

式中： W_i^Q 、 W_i^K 、 W_i^V 分别表示 Q 、 K 、 V 在第 i 个注意力头的权重矩阵，利用融合层对多头注意力的输出进行拼接。

1.3 整体网络结构

多通道融合网络整体结构由三通道网络特征提取模块、多头注意力模块及 FNN 预测模块组成，如图 2 所示。3 种网络模型利用各自的优势学得不同的时序特征，由多头注意力模块将学得特征映射到不同的子空间，重新分配特征权重，重点关注对于退化趋势影响大的特征向量，最后将所有特征融合，通过 FNN 模块将特征映射输出得到最终的 RUL 预测值。

2 实例分析

为验证多通道融合的预测方法在发动机剩余寿命预测中的有效性，基于 Python3.8 和 TensorFlow2.0 框架进行实验验证。

2.1 实例 1: PHM2012 公开数据集

本实验采用 PHM2012 数据挑战发布的轴承完整寿命周期数据集^[17]。如图 3 所示，在 PRONOSTIA 实验平台上通过水平和垂直位置的加速度传感器来收集两个方向的振动信号。设定设备的采样频率为 25.6 kHz，每间隔 10 s 记录一次数据，每次采集数据时长为 0.1 s。从实验安全的角度考虑，当振动数据的振幅超过 20 g (1 g = 9.8 m/s²) 时，停止实验。

如表 1 所示，数据集共采集 3 种工况条件下的 17 组数据。

表 1 轴承工作条件
Table 1 Bearing operating conditions

工况条件	径向力/kN	转速/rpm	轴承序号
条件 1	4	1 800	B1_1-B1_7
条件 2	4.2	1 650	B2_1-B2_7
条件 3	5	1 500	B3_1-B2_3

训练集和测试集包含每个轴承的全寿命历史振动数




图 2 整体网络结构
Fig. 2 Overall network structure




图 3 实验平台
Fig. 3 Experimental platform




图 4 数据标签构建
Fig. 4 Data label building

据,每个采样周期包含 2 560 个振动数据。本次实验对于同一工况的轴承,采用“留一法”,将目标轴承数据作为测试集,将其他轴承数据设为训练集。如图 4 所示,将整个轴承的生命周期定义为从 1~0 的均匀下降直线并以此作为轴承训练的训练标签。

1) 评价指标

为了准确评价模型预测精度,引用了其他相关研究文章常用的平均绝对误差 (mean absolute error, MAE)^[18]、均方根误差 (root mean square error, RMSE)^[19] 两个性能指标。MAE 和 RMSE 由式(6)和(7)定义:

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i)^2} \quad (7)$$

其中, $e_i = RUL_{act} - RUL_{pred}$,即为实际 RUL 与预测

RUL 之间的误差, n 是样本数。
由定义可知,更低的 MAE 和 RMSE 代表更好的预测结果。

2) 参数设置

经过多次实验,模型中 TCN 模块、ConvLSTM、BiGRU 模块的具体结构和参数设置如表 2 所示。表中 K 、 N 、 D 、 N 分别表示卷积核大小、滤镜数、扩张率大小、神经元数目。网络超参数设置:迭代次数 $epochs = 100$,批大小 $Batch\ size = 32$,模型初始学习率 $lr = 0.01$,优化器为 Adam,损失函数为均方误差函数 (mean squared error, MSE),采用早停法进行训练,监控验证集的损失函数,当损失不再下降时提前停止训练,防止模型过拟合并提高泛化能力。

表 2 网络模块参数设置

Table 2 Network module parameter settings		
模块	网络层名称	参数设置
TCN 模块	BatchNormalization	防止梯度消失
	TCN	$K=3, N=16, D=1$
	激活函数	ReLU
	Dropout	丢弃率=0.2
	BatchNormalization	防止梯度消失
	TCN	$K=3, N=32, D=2$
	激活函数	ReLU
	Dropout	丢弃率=0.2
	BatchNormalization	防止梯度消失
ConvLSTM 模块	TCN	$K=3, N=64, D=4$
	激活函数	ReLU
	Dropout	丢弃率=0.2
	ConvLSTM	$K=(3,3), N=16$
BiGRU 模块	Dropout	丢弃率=0.2
	ConvLSTM	$K=(3,3), N=32$
	Dropout	丢弃率=0.2
	激活函数	ReLU

所提模型中的多头注意力机制涉及到注意力头数的选择,不同头数对于预测精度是有一定影响。为了探究精度最高的参数设置方案,本文设置不同注意力头数:1、2、4、8、16、32、64、128 共 8 种情况。为了防止偶然性,对每一种情况运行实验 5 次取平均,得到其预测结果的 MAE 值和 RMSE 值如图 5 所示。可以看到,不同注意力头数对应的预测精度不同且差异较大,注意力头数的增加与准确度的提高没有正负相关性,在本文实验中,当注

意力头数为 2 时的预测模型精度最高,因此本文后续的实验都在这个参数的基础上进行。




图 5 不同注意力头数对比

Fig. 5 Comparison of different attention heads

3) 消融实验

为了验证所提多通道融合的预测方法相比于原始模型改进的有效性。将本文模型进行部分模块拆解,构成 4 种消融模型:TCN + MA 模型、ConvLSTM + MA 模型、BiGRU+MA 模型、多通道+普通注意力模型。

本文在工况 1 的条件下,测试 7 个轴承的 RUL,每个轴承的预测实验重复 5 次并取平均值得到最终的预测误差。评价指标对比结果如表 3 所示。可以看到,在 5 种模型的对比中,本文提出模型的有着更低的 MAE 和 RMSE 值,这代表着更加准确的预测性能。值得关注的是,普通注意力和本文引入的多头注意力优化的多通道模型在预测精度上明显高于其他 3 种单通道模型,这说明所提的多通道网络结构对于预测性能提升有效。在多通道模型的基础上,多头注意力机制相比于普通注意力机制在预测准确性上进一步提升,最终达到一个较高的预测水平。

表 3 PHM2012 数据集寿命预测消融实验结果

Table 3 Life prediction ablation experimental results of PHM2012 dataset										
轴承型号	TCN+MA		ConvLSTM+MA		BiGRU+MA		普通注意力		本文模型	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
B1-1	0.085	0.096	0.045	0.077	0.059	0.083	0.044	0.053	0.026	0.032
B1-2	0.114	0.132	0.052	0.060	0.072	0.099	0.049	0.061	0.040	0.046
B1-3	0.102	0.115	0.076	0.081	0.063	0.073	0.039	0.048	0.031	0.037
B1-4	0.212	0.264	0.095	0.113	0.091	0.104	0.071	0.087	0.064	0.082
B1-5	0.196	0.267	0.101	0.107	0.083	0.095	0.061	0.082	0.055	0.074
B1-6	0.153	0.186	0.121	0.139	0.095	0.112	0.063	0.089	0.051	0.070
B1-7	0.170	0.255	0.086	0.096	0.047	0.071	0.042	0.057	0.033	0.045

如图 6 所示,为了能够更加直观地显示本文模型相较于其他消融模型的优越性,以轴承 B1-7 为例,对剩余寿命预测进行可视化分析。可以看到,本文模型对于轴承寿命退化趋势的跟踪拟合效果最好,能够精准地预测

轴承的健康状态。尤其需要注意的是轴承平稳运行的初期和寿命末期,由于信息量少和信号陡变的原因,单通道网络模型对于数据特征挖掘不足,预测结果偏差较大,而本文模型在这两个时间段取得了令人满意的预测效果,

充分证明了其优良的预测能力。




图 6 寿命预测可视化结果
Fig. 6 Visualize life predictions

4) 对比实验

为了验证本文提出模型的优越性,分别构建了其他文献中提出的 4 种优秀深度学习方法进行对比:双通道 BiLSTM 模型^[14]、CNN-BiLSTM 模型^[20]、ConvGRU 模型^[21]、多尺度特征模型^[22],并从 MAE、RMSE、时间 3 个维度进行分析。在 FD001 测试集上进行误差比较,以轴承 1-3 为例,所得结果如表 4 所示。可以看到,本文模型相对于预测精度最高的多尺度特征模型,在 MAE 和 RMSE 两种指标上分别降低了:26.19%、30.19%。其中,CNN-BiLSTM 和 ConvGRU 是对 CNN-LSTM 和 GRU 的改进,两种网络都是单通道网络中较为优秀的改进,但是预测精度在对比模型中最低,这说明单通道网络本身的局限性阻碍了精度的提升。双通道 BiLSTM 模型虽然采用了多通道的结构,但是本身模型改进不足且结构单一,预测精度低于本文模型。多尺度特征模型,是把输入特征进行多尺度划分,搭建多分支结构对不同尺度分开预测再将其预测结果融合,是另一种意义上的多通道结构,但是对于深度学习算法的探索仍存在不足。在时间维度上,除本文模型外,其他多通道、多尺度模型训练时间均高于 CNN-BiLSTM 和 ConGRU 两种单一模型,这是因为复杂的网络虽然能够很好地学习目标特征,但是也带来了计算复杂的问题,本文提出的模型经过多头注意力的优化和网络层的筛选,能够更快地收敛从而减少迭代的时间,训练时间仅略高于 ConvGRU 模型,但模型精度远优于所有对比模型,很好地平衡了训练时间和模型精度。综合上述分析,更能充分证明所提模型的优越性。

2.2 实例 2:实验室自采集数据集

在实际生产生活中,轴承型号不一、工况条件多变等往往会造成模型失效,为了验证本文提出的多通道寿命预测模型的泛化性能,运用实验室轴承寿命预测实验平台对测试轴承进行全寿命周期振动信号的数据采集并用于寿命预测。

表 4 对比实验评价指标

Table 4 Compare experimental evaluation indicators

模型方法	MAE	RMSE	训练时间/min
本文模型	0.031	0.037	28.27
双通道 BiLSTM	0.060	0.079	39.53
CNN-BiLSTM	0.089	0.104	32.48
ConvGRU	0.083	0.092	22.84
多尺度特征	0.042	0.053	43.45

实验平台如图 7 所示,该平台由变速驱动电机、轴承、齿轮箱、轴、偏重转盘和调速器等组成。选取轴承型号为 N205,数字信号的采样频率为 12 kHz,间隔 10 s 采样,每次采样 0.1 s。实验安全的角度考虑,当振动数据的振幅超过 20 g(1 g=9.8 m/s²)时,停止实验。




图 7 轴承寿命预测实验平台
Fig. 7 Bearing life prediction experimental platform

在上述工作条件下,共采得 5 组轴承全周期寿命振动数据,如表 5 所示。本实验对数据集的划分以及标签处理与前文实验相同。

表 5 轴承寿命数据信息

Table 5 Bearing life data information

测试轴承	样本长度	寿命周期/10 s
轴承 1	1 200	864
轴承 2	1 200	717
轴承 3	1 200	754
轴承 4	1 200	1 920
轴承 5	1 200	2 332

对 5 个测试轴承进行剩余寿命预测,其可视化结果如图 8 所示,可以看到对于 1、2、3、5 号轴承,预测曲线能够很好地追踪退化趋势,只存在小幅度局部震荡现象。只有轴承 4 预测曲线震荡较为剧烈,对于小部分轴承预测结果较差是可以接受的。综合来看,所提方法对于异型异工况也有着优良的鲁棒性,充分说明其良好的泛化性能。

为了能够更加直观地显示本文模型相较于其他对比模型的优越性,以轴承 5 为例,对剩余寿命预测进行可视化分析。如图 9 所示,传统的 CNN 对于轴承的退化很难




图 8 寿命预测可视化结果

Fig. 8 Visualize life predictions

做到有效的预测,本文引入的其他先进模型,都能够在一定程度上对轴承的剩余寿命退化趋势进行捕捉,其他文献提到的多通道类的模型虽然在部分地方出现了波动大的情况,但预测精度相较于单通道模型有所增加,而本文提出的多通道融合多头注意力机制模型在轴承寿命退化的全过程都能够很好地追踪退化曲线,能够及时对轴承进行维护和更换,对实际的工业生产应用有着一定的借鉴意义。




图 9 寿命预测对比

Fig. 9 Comparison of life expectancy predictions

3 结 论

针对现有数据驱动方法在滚动轴承剩余寿命预测中对振动信号特征挖掘深度不足导致预测精度不高的问题,提出了一种基于多头注意力机制和多通道模型融合的滚动轴承剩余寿命预测方法。该方法,首先将原始振动信号进行时、频域分解并运用 CEEMD 将特征信号进行降噪、增强。然后,构建三通道网络结构:TCN、ConvLSTM、BiGRU,对特征信号从时间、空间、时序等多个维度进行深度挖掘,提取其高维退化特征。最后结合多头注意力机制,将高维特征映射到子空间进行权重调整和融合,最终实现对滚动轴承剩余寿命的回归预测。

通过在 PHM2012 和实验室平台数据集的实验结果表明,相比于 ConvGRU、CNN-BiLSTM、双通道 BiLSTM 等数据驱动方法,本文模型在预测精度上有着明显的提升,在时间维度上,相较引文的双通道、多特征模型也有较大提升,是一种高效的滚动轴承剩余寿命预测方法。

虽然经过实验验证,本文模型在多种工况下都有着良好的预测精度,但是并未考虑到 1 工况训练、2 工况测试这种跨工况问题,这是深度学习在滚动轴承剩余寿命预测领域的难点也是下一步工作应该探究的重点。

参考文献

- [1] 刁宁昆,马怀祥,刘锋. 一种改进 LeNet5 结合 Light GBM 的滚动轴承故障诊断方法[J]. 国外电子测量技术, 2022, 41(1): 140-145.
- [2] DIAO N K, MA H X, LIU F. Bearing fault diagnosis method based on improved LeNet5 and LightGBM[J]. Foreign Electronic Measurement Technology, 2022, 41(1): 140-145.
- [3] YANG D, LIU X. Remaining useful life prediction for bearing based on online oil parameters and vibration signals[C]. 2022 Global Reliability and Prognostics and Health Management (PHM-Yantai). IEEE, 2022: 1-5.
- [4] ZHOU J, MA Y, JIANG B, et al. A bearing remaining useful life prediction method based on residual convolutional network and LSTM[C]. 2023 6th International Symposium on Autonomous Systems (ISAS). IEEE, 2023: 1-6.
- [5] 严帅,熊新. 基于 KPCA 和 TCN-Attention 的滚动轴承退化趋势预测[J]. 电子测量技术, 2022, 45(15): 28-34.
- [6] YAN SH, XIONG X. Prediction of rolling bearing degradation trend based on KPCA and TCN-Attention[J]. Electronic Measurement Technology, 2022, 45(15): 28-34.
- [7] CHADZA T, KYRIAKOPOULOS K G, LAMBOTHARAN S. Contemporary sequential network attacks prediction using hidden Markov model[C]. 2019 17th International Conference on Privacy, Security and Trust (PST). IEEE, 2019: 1-3.
- [8] YANG D, CHHATRE N, CAMPI F, et al. Feasibility of support vector machine gesture classification on a wearable embedded device[C]. 2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE). IEEE, 2016: 1-4.
- [9] LI H, LI Y, WANG Z, et al. Remaining useful life prediction of aero-engine based on PCA-LSTM[C]. 2021 7th International Conference on Condition Monitoring of Machinery in Non-Stationary Operations (CMMNO).

- IEEE, 2021: 63-66.
- [8] HONG C W, KO M S, HUR K. ConvNet-based remaining useful life prognosis of a turbofan engine[C]. 2021 IEEE 4th International Conference on Knowledge Innovation and Invention (IC-KII). IEEE, 2021: 190-193.
- [9] 张康,丁卫,赵东方,等. 基于 SAM-LSTM 的滚动轴承剩余寿命预测[J]. 工业控制计算机, 2022, 35(5): 82-85.
- ZHANG K, DING W, ZHAO D F, et al. Residual life prediction of rolling bearings based on SA-M-LSTM[J]. Industrial Control Computer, 2022, 35(5): 82-85.
- [10] WANG Y, DENG L, ZHENG L, et al. Temporal convolutional network with soft thresholding and attention mechanism for machinery prognostics [J]. Journal of Manufacturing Systems, 2021, 60: 512-526.
- [11] 陈维兴,常东润,李宗帅. 基于改进生成对抗网络与 ConvLSTM 的航空发动机剩余寿命预测方法[J]. 电子测量与仪器学报, 2023, 37(3): 211-221.
- CHEN W X, CHANG D R, LI Z SH. Aeroengine residual life prediction method based on improved generative adversarial network and ConvLSTM [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 211-221.
- [12] 马占伟,袁逸萍,樊盼盼,等. 基于多尺度卷积神经网络的轴承剩余寿命预测[J]. 机械设计与制造, 2023, 1(1): 5-8.
- MA ZH W, YUAN Y P, FAN P P, et al. Prediction of bearing residual useful life based on multi-scale convolutional neural network [J]. Machinery Design & Manufacture, 2023, 1(1): 5-8.
- [13] GAO H, LI Y, ZHAO Y, et al. Dual channel feature-attention-based approach for RUL prediction considering the spatiotemporal difference of multisensor data [J]. IEEE Sensors Journal, 2023.
- [14] 钟建华,高杨,钟舜聪. 基于 SWT 和双通道 ConvLSTM 的滚动轴承剩余寿命预测[J]. 矿山机械, 2023, 51(3): 46-53.
- ZHONG J H, GAO Y, ZHONG SH C. Prediction of remaining life of rolling bearing based on SWT and dual-channel ConvLSTM [J]. Mining & Processing Equipment, 2023, 51(3): 46-53.
- [15] 陈保家,陈正坤,陈学良,等. 基于注意力 TCN 的滚动轴承剩余使用寿命预测方法[J]. 电子测量技术, 2021, 44(24): 153-160.
- CHEN B J, CHEN ZH K, CHEN X L, et al. Prediction method of remaining useful life of rolling bearing based on attentional temporal convolutional network[J]. Electronic Measurement Technology, 2021, 44(24): 153-160.
- [16] 陈倩倩,林天然. 基于 DRN-BiGRU 模型的滚动轴承剩余寿命预测[J]. 机电工程, 2022, 39(11): 1575-1581.
- CHEN Q Q, LIN T R. Remaining useful life prediction of rolling bearings based on DRN-BiGRU algorithm [J]. Journal of Mechanical & Electrical Engineering, 2022, 39(11): 1575-1581.
- [17] NECTOUX P, GOURIVEAU R, MEDJAHHER K, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests [C]. IEEE International Conference on Prognostics and Health Management, PHM' 12. IEEE Catalog Number: CPF12PHM-CDR, 2012: 1-8.
- [18] NI Q, JI J C, FENG K. Data-driven prognostic scheme for bearings based on a novel health indicator and gated recurrent unit network [J]. IEEE Transactions on Industrial Informatics, 2022, 19(2): 1301-1311.
- [19] 黄庆卿,胡欣堪,韩延,等. 多源域子域自适应的滚动轴承剩余寿命预测方法[J]. 电子测量与仪器学报, 2022, 36(10): 100-107.
- HUANG Q Q, HU X K, HAN Y, et al. Remain useful life prediction of rolling bearing based on multisource subdomain adaption network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 100-107.
- [20] 惠憬明,王健,吴双,等. 基于自注意力 CNN-BiLSTM 的滚动轴承剩余使用寿命预测方法[J/OL]. 轴承: 1-8 [2023-07-20].
- HUI CH M, WANG J, WU SH, et al. Remaining useful life prediction method of rolling bearing based on self-attention-CNN-BiLSTM [J/OL]. Bearing: 1-8 [2023-07-20].
- [21] 赵志宏,李晴,李春秀. 基于卷积 GRU 注意力的设备剩余寿命预测[J]. 振动. 测试与诊断, 2022, 42(3): 572-579, 622.
- ZHAO ZH H, LI Q, LI CH X. Prediction of remaining life of devices based on convolutional GRU attention[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(3): 572-579, 622.
- [22] 莫仁鹏,司小胜,李天梅,等. 基于多尺度特征与注意力机制的轴承寿命预测[J]. 浙江大学学报(工学版), 2022, 56(7): 1447-1456.
- MO R P, SI X SH, LI T M, et al. Bearing life prediction based on multi-scale features and attention mechanism[J]. Journal of Zhejiang University (Engineering Science), 2022, 56(7): 1447-1456.

作者简介



车鲁阳,2020 年于青岛大学获得学士学位,现为青岛大学在读研究生,主要研究方向为机械寿命预测与健康管理。
E-mail: q847232625@ 163. com

Che Luyang received his B. Sc degree from Qingdao University in 2020. He is currently a M. Sc. candidate at Qingdao University. His main research interests include mechanical life prediction and health management.



高军伟(通信作者),2003 年于中国铁道科学研究院获得博士学位。现为青岛大学教授,主要研究方向为模式识别及智能控制。
E-mail: qdgao163@ 163. com

Gao Junwei (Corresponding author) received his Ph. D. degree from China Academy of Railway Sciences in 2003. Now he is a professor in Qingdao University. His main research interests include pattern recognition and intelligent control.