

基于 AR-CNN-BiLSTM 组合模型的直升机尾减轴承 剩余寿命预测

林翔¹, 毕果^{1*}, 王振忠¹, 刘国亮², 刘芝福²

(1. 厦门大学航空航天学院, 福建 厦门 361102; 2. 中国航发中传机械有限公司, 湖南 长沙 410200)

摘要: [目的] 对于直升机尾减速器轴承的在线剩余使用寿命(remaining useful life, RUL)预测算法,既要能够实现早期损伤的检测,又要满足算法的时效性要求。[方法] 为了较好地反映轴承信号的退化趋势,对剩余使用寿命进行预测,本文选用双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)进行时序特征提取。同时,为了弥补 BiLSTM 训练速度慢,对早期局部特征不敏感的问题,利用自回归模型(autoregressive model, AR)进行数据降维,利用卷积神经网络(convolutional neural network, CNN)提升局部特征的提取性能。[结果] 在直升机尾减试验台数据集及西安交通大学轴承数据集上进行算法测试,相对于 LSTM、BiLSTM、CNN-BiLSTM, AR-CNN-BiLSTM 表现出更高的预测精度和更快的训练速度。[结论] AR-CNN-BiLSTM 能满足尾减轴承在线剩余使用寿命预测对早期损伤识别及时效性的要求。引入 BiLSTM 由于能充分挖掘时序的前向和后向信息,能提高预测精度,但也导致训练时间的增加;CNN 凭借其出色的特征提取能力,既能挖掘深度特征又能降低数据维度,可适当提升算法的预测精度和训练速度;AR 将复杂的时序数据映射为自相关系数和残差组成的特征矩阵,能有效提升算法的预测精度和训练速度。

关键词: 直升机尾减速器;滚动轴承;自回归模型;双向长短时记忆网络;剩余寿命预测

中图分类号: TH 133.33; TP 18

文献标志码: A

文章编号: 0438-0479(2025)04-0653-07

Remaining useful life prediction of helicopter tail gearbox bearings based on AR-CNN-BiLSTM model

LIN Xiang¹, BI Guo^{1*}, WANG Zhenzhong¹, LIU Guoliang², LIU Zhifu²

(1. School of Aerospace Engineering, Xiamen University, Xiamen 361102, China; 2. AECC Zhongchuan Transmission Machinery Co., LTD., Changsha 410200, China)

Abstract: [Objective] The online remaining useful life prediction algorithm of helicopter tail gearbox bearings should secure both the early damage detection and the timeliness. [Methods] To better reflect the degradation trend of bearing signals and predict the remaining useful life, we select bidirectional long short-term memory (BiLSTM) network for temporal feature extraction. For the purpose of addressing issues of the slow training speed and insensitivity to early local features in BiLSTM, autoregressive model (AR) is used for dimensionality reduction, and convolutional neural network (CNN) is employed to enhance the extraction of local features. [Results] The algorithm was tested on the helicopter tail gearbox test bench dataset and the bearing dataset of Xi'an Jiaotong University. Compared to LSTM, BiLSTM, and CNN-BiLSTM, AR-CNN-BiLSTM demonstrated higher prediction accuracies and faster training speeds. [Conclusion] AR-CNN-BiLSTM meets the requirements for early damage detection and the timeliness in the online remaining useful life prediction of helicopter tail gearbox bearings. Introducing BiLSTM, which can improve the prediction accuracy by fully exploiting both the forward and backward temporal information. However, BiLSTM appears slower than LSTM

收稿日期: 2025-01-07 录用日期: 2025-04-15

* 通信作者: guobi@xmu.edu.cn

引文格式: 林翔, 毕果, 王振忠, 等. 基于 AR-CNN-BiLSTM 组合模型的直升机尾减轴承剩余寿命预测[J]. 厦门大学学报(自然科学版), 2025, 64(4): 653-659.

Citation: LIN X, BI G, WANG Z Z, et al. Remaining useful life prediction of helicopter tail gearbox bearings based on AR-CNN-BiLSTM model[J]. J Xiamen Univ Nat Sci, 2025, 64(4): 653-659. (in Chinese)



does in training speed. With its excellent feature extraction ability, CNN can not only excavate deep features but also reduce the dimensionality of the data, thus appropriately improving the prediction accuracy and training speed of the algorithm. Finally, AR can map complex time-series data into a feature matrix consisting of autocorrelation coefficients and residuals, thereby enhancing the prediction accuracy and training speed of the algorithm.

Keywords: helicopter tail gearbox; rolling bearing; autoregressive model; bidirectional long short-term memory; remaining useful life prediction

尾减速器(简称:尾减)作为直升机姿态控制重要部件,其运转轴承需要承受复杂载荷,轴承健康状态影响飞行安全,准确地对尾减轴承进行剩余使用寿命(remaining useful life, RUL)预测对尾减的维护节点判断具有重大意义^[1-3].

针对轴承 RUL 预测问题,早期多基于轴承的物理失效机制,构建其失效模型进行 RUL 预测. 如卢光辉^[4]基于断裂力学理论通过分析轴承内圈残余应力、粗糙度等表面完整性指标构建轴承疲劳寿命物理模型,对零件进行 RUL 预测. 然而这类方法一般需要大量的先验知识,尾减轴承通常工作在高速、重载、高温的工况下,失效机理复杂,建立精确模型存在较大困难. 相比之下,基于深度学习的 RUL 预测方法凭借其优秀的特征提取能力以及非线性拟合能力,可以在缺乏先验知识的情况下,通过使用状态监测数据来实现轴承的 RUL 预测^[5]. Giduthuri 等^[6]利用卷积神经网络(CNN)出色的深层特征提取能力实现了对轴承的 RUL 预测. 虽然 CNN 可实现轴承的 RUL 预测,但其主要优势在于特征提取,对于轴承振动预测问题,其时序存在长期退化趋势,而长短时记忆神经网络(long short-term memory, LSTM)的表现会更好. 如 Malhotra 等^[7]利用 LSTM 构建轴承的健康因子,进行 RUL 预测,验证了 LSTM 出色的时序数据处理能力. 但由于 LSTM 的训练基于长序列,训练速度慢,且对硬件资源要求较高. 此外, LSTM 对局部特征的捕捉能力较弱,如 LSTM 可能将早期点蚀产生的瞬态振动信号视为噪声过滤掉,因此需要与其他算法结合提升预测性能. 如王瀚卿^[8]为了缓解振动信号的噪声问题,使用自适应分解算法重构振动信号,并利用深度信念网络(deep belief networks, DBN)提取特征,之后输入到 LSTM 中进行轴承的 RUL 预测. 现有的研究通常会针对不同的研究对象对 LSTM 进行改进:使用双向 LSTM(bidirectional LSTM, BiLSTM)代替 LSTM;融合其他的网络或机制(如 CNN、多头自注意力机制(multi-head self-attention, MHSA)等). 比如:韩允童等^[9]指出结合 CNN 和 LSTM 进行轴承 RUL 预测会受参数数量的影响,通过内嵌鲸鱼算法进行参

数寻优,可以更好地实现轴承 RUL 预测. 武将^[10]提出一种融合 CNN 与 BiLSTM,并融入时间感知多头注意力机制的综合性神经网络模型,通过 MHSA 增强对关键时序特征的识别,在 CNN-LSTM 的基础上进一步提高预测精度.

尾减轴承的性能关系到飞行安全,其较传统轴承对精度、可靠性与寿命的要求更高. 在维护策略上,传统轴承的维护节点通常选在其出现明显损伤(如点蚀、磨损)后;而尾减轴承主要采用预测性维护,维护节点选在轴承出现轻微损伤前. 因此,传统轴承 RUL 预测因训练数据前后期差异大,模型更易习到有效特征表示;而尾减轴承前后期数据分布差异较小,单纯使用 CNN 或 LSTM 方法较难实现早期损伤的在线识别,并满足时效性要求.

为此,本文提出自回归-CNN-BiLSTM(AR-CNN-BiLSTM)模型. 该模型的优势在于结合上述各模型的优点:首先,AR 模型提取的特征主成分突出,相对传统时频域特征提取方法,AR 模型对设备的变化更敏感;其次,CNN 能够进一步挖掘数据中的深层特征;最后,BiLSTM 在处理时序数据时能够考虑全局信息.

1 AR-CNN-BiLSTM 模型

轴承 RUL 预测通常需要结合多种传感器数据(如振动、温度、负载等)信息进行建模. 其中振动信号最能反映其运行状态,因此也最常被用于 RUL 预测.

基于振动信号,本文提出如图 1 所示的 AR-CNN-BiLSTM 模型. 对于 RUL 预测问题,一般的模型结构可以概括为特征提取-寿命预测两个部分,其中特征提取的质量直接决定了后续寿命预测的效果. 为了提升特征提取质量,考虑到 AR 模型的自相关系数和残差可凝聚系统状态的重要信息,且对状态的变化比较敏感^[11],因此本文引入 AR 模型提取振动信号的浅层特征,以感知尾减轴承初期下降趋势不明显的特征. 再利用 CNN 提取深层特征. 最后,使用 BiLSTM 进行 RUL 预测.

1.1 AR 模型

AR 模型的基本假设是将当前时刻的观测值视为

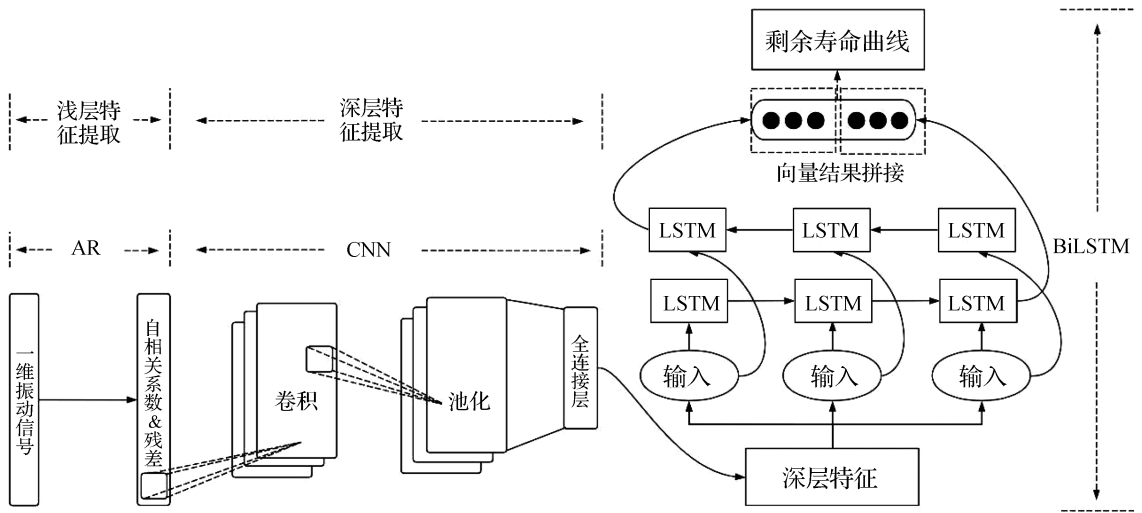


图 1 AR-CNN-BiLSTM 网络模型结构
Fig. 1 AR- CNN-BiLSTM network model structure

其过去观测值的线性组合再加上一个随机误差项^[12-13]。由于尾减轴承的当前损伤情况由之前的使用情况决定,因此本文使用 AR 模型对尾减轴承的振动信号进行拟合。对于 p 阶 AR 模型, t 时刻的观测量可表示为

$$X_t = c + \Phi_1 X_{t-1} + \Phi_2 X_{t-2} + \dots + \Phi_p X_{t-p} + \epsilon_t, \quad (1)$$

式中: c 为常数; $\Phi_1, \Phi_2 \dots \Phi_p$ 为自相关系数; $X_{t-1}, X_{t-2} \dots X_{t-p}$ 为前期观测值, ϵ_t 为白噪声, 即随机误差。由式(1)可知, 通过 AR 模型将时序信号映射为自相关系数和残差组成的特征矩阵, 可实现观测数据的降维。

1.2 CNN

经过 AR 模型预处理后, 每一个样本的特征矩阵是由自相关系数、残差组成的一维序列。因此, 本文采用一维 CNN(1D-CNN)提取序列中的深层特征。

1D-CNN 通过卷积核在序列上滑动, 进行乘积和加法操作, 提取局部特征, 并通过激活函数增强非线性表达能力。多层卷积逐步从低级特征过渡到高级特征, 捕捉复杂序列关系。池化层随后减少特征长度, 降低计算复杂度, 并防止过拟合^[14]。

1.3 BiLSTM

BiLSTM 由 LSTM 变化而来。对于 RUL 预测来说, LSTM 的信息流动仅为前向, 训练模型时只能结合过去的寿命信息, 而 BiLSTM 在训练模型时则可以结合过去与未来的寿命信息, 使其更好地理解数据的整体结构, 从而提高预测精度。BiLSTM 包含两个相反方向的传输层, 分别处理前向和反向信息^[15-16]:

$$\vec{h}_t = f(\vec{W} \cdot x_t + \vec{v} \cdot \vec{h}_{t-1} + \vec{b}), \quad (2)$$

$$\overleftarrow{h}_t = f(\overleftarrow{W} \cdot x_t + \overleftarrow{v} \cdot \overleftarrow{h}_{t-1} + \overleftarrow{b}), \quad (3)$$

$$y_t = g(U[\vec{h}_t, \overleftarrow{h}_t] + c), \quad (4)$$

式中: \vec{h}_t 为前向层输出, \overleftarrow{h}_t 为后向层输出, 网络的输出状态根据 \vec{h}_t 和 \overleftarrow{h}_t 进行矩阵拼接并输出; y_t 为网络经过叠加后隐藏层的输出。

1.4 RUL 标签设置

为了得到模型训练所需要的 RUL 标签, 本文将轴承全寿命周期划分为多个阶段。首先, 基于 AR 模型得到的自相关系数和残差, 再利用模糊 C 均值聚类 (fuzzy C-means, FCM) 模型^[12] 对自相关系数与残差进行聚类划分, 得到轴承全寿命周期对初始健康数据的隶属度。FCM 是基于模糊集合理论的聚类算法, 属于无监督学习方法。FCM 通过计算数据点隶属于多个类簇的隶属度, 准确地量化数据点对于某一类簇的相似度。其原理主要为最小化以下目标函数:

$$J(U, V) = \sum_{i=1}^N \sum_{j=1}^K u_{ij}^m \|x_i - v_j\|^2, \quad (5)$$

式中: U 为隶属度矩阵; V 为聚类中心矩阵; u_{ij}^m 为样本 x_i 对簇 j 的隶属度, 且每个样本对所有类的隶属度之和为 1, m 是模糊系数; v_j 为簇 j 的聚类中心, $\|x_i - v_j\|^2$ 为样本 x_i 到簇 j 聚类中心的距离。

具体地, 本文先使用 AR 模型作为特征提取器, 输入到 FCM 中进行计算, 输出各阶段对于第 1 阶段的隶属度。因为该模型本质为聚类算法, 第 1 阶段为轴承初始健康状态的数据, 对于某一阶段, 其与第 1 阶段越接近, 则隶属度越高, 同时其性能状态越好。隶属度曲线如图 2 所示, 可以看出数据前期隶属度下降缓慢, 经过某一节点下降速率增加, 该趋势正好

符合一般轴承使用寿命前期平稳下降,后期剧烈下降的特征.所以可以将隶属度曲线作为轴承的 RUL 标签.根据轴承的退化特性,将轴承的 RUL 划分成两个线性阶段,绘制出全寿命 RUL 标签的折线图,如图 3 所示.将隶属度在 $[0.8, 1]$ 区间的第 1 阶段到第 8 阶段拟合为慢速退化线性模型,隶属度小于 0.8 的阶段拟合为快速退化线性模型,将第 8 阶段对应的 800 h 作为退化速率变化的节点用于计算 RUL 标签值.

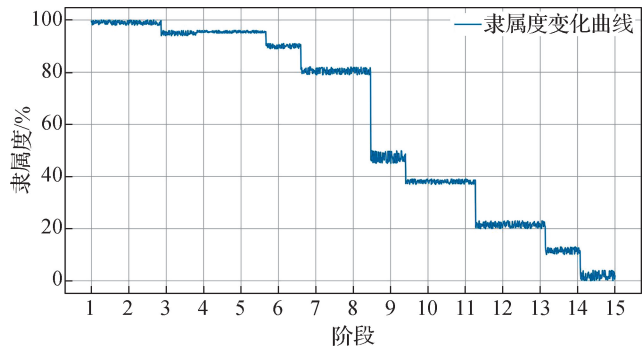


图 2 各阶段对 1 阶段的隶属度曲线

Fig. 2 Membership degree curves for each cycle to the first cycle




图 3 轴承 RUL 拟合曲线

Fig. 3 Fitted curve of bearing RUL

1.5 RUL 预测

AR-CNN-BiLSTM 模型构建的关键在于将 AR 模型引入 CNN-BiLSTM 中,利用 AR 模型的自回归系数和残差对设备状态敏感这一优点解决一般 RUL 预测模型难以提取早期有效特征的问题.同时为了进一步扩大不同阶段数据的差异,使用 CNN 进行深层特征的提取,在特征提取之后再输入到 BiLSTM 中进行 RUL 预测.具体流程为:


首先将采集到的一维振动数据输入到 AR 模型

中,提取其自相关系数与残差作为浅层特征.然后将一维浅层特征输入到 1D-CNN 中进行分类训练,训练完成后提取最后一层全连接层的输出作为深层特征输入到 BiLSTM 中. BiLSTM 根据输入的深层特征与 RUL 标签,同时学习其全局的变化趋势来训练模型.训练完成后的模型相当于建立了从振动信号到 RUL 标签的映射,此时导入测试集的振动信号,模型即可输出测试集的 RUL 标签值,从而得到最终的轴承 RUL 曲线.

2 实验设计

2.1 实验数据获取

为了模拟尾减的真实工况,某公司搭建了一个中尾减(简称中减)试验台,试验台大部分结构和直升机上传动系统一致.其中中减之前的动力由驱动电机和增速箱替代;而尾桨部分,在结构上,保留尾桨距操作杆部分,在受力上,则使用尾桨轴综合加载系统替代.试验台综合加载系统给尾减轴承施加轴向和径向载荷模拟飞行时轴承承受的载荷.这样设计能够保证试验时尾减的工作环境和真实在机情况基本一致.其示意图如图 4 所示.



1-驱动电机,2-增速箱,3-转矩传感器,4-中间减速器,
5-尾减减速器(轴承),6-尾桨距操纵油缸,
7-尾桨轴综合加载系统,8-加载电机.


图 4 试验台结构

Fig. 4 Test bench structure

研究对象为中间减速器 4 到尾减减速器 5 之间的输入轴承.采用 3 个加速度传感器采集该轴承 3 个方向即轴向、径向、垂直方向的振动信号.并选择最常关注的径向振动信号进行研究与分析.

试验主要采用循环试验,每一个循环持续 10 h,包括 3 个不同转速和载荷的工况,来模拟实际飞行中的工作环境.振动传感器采集的振动数据,采样频率为 20 kHz,由于数据量过大,总数据量高达 12 TB,故

采取抽样的形式,每 5 个循环取一个循环的数据,即每 50 h 的数据只取前 10 h 作为实验数据. 排除试验原因导致的部分数据不可用的因素,最终得到了 15 个循环,150 h 的试验数据,总共 2 TB. 图 5 为轴承的全寿命时域波形图,全寿命周期振幅变化较小,提取有效特征较为困难,与前文所述一致.



g 为重力加速度.

图 5 直升机尾减轴承全寿命周期时域波形

Fig. 5 Time domain waveform of the life cycle of helicopter tail gearbox bearing

在得到数据后首先对振动原始信号进行窗口划分,原始信号按照时间段划分为 15 组,每一组划分为 100 份样本,对其中每一个样本都进行 AR 模型的自相关系数与残差的提取. 然后将每一组样本数的 70% 划分为训练集,其余划分为测试集. 然后将训练集的振动信号及标签输入到设置好初始参数的模型中,通过训练过程不断优化参数,直到训练损失小于设定值. 训练完成后冻结参数,将测试集振动信号及标签输入到训练好的模型中,输出 RUL 预测值,再与 RUL 标签进行对比,计算出预测精度. 最后检查预测精度是否满足要求.

2.2 参数设置

模型的具体参数设置如表 1 所示,卷积层采用 ReLU 作为激活函数,解决梯度消失问题,提高训练效率. BiLSTM 选择 tanh 作为激活函数用于处理信息记忆与梯度控制. 其他参数设定的原因如下:考虑到卷积核数目等于其输出的特征数,一般为 2 的 n 次幂,值越大,提取到的特征维度越高,特征数太少可能导致模型学习不到深层特征,特征数太多又会增加模型复杂度和计算规模,因此选为 16. 同理,卷积核的大小设定为 7,因为输入为一维数据,所以设定为 7×1 . 池化层大小设置为常用的 2. 全连接层的参数通过计算得出,输出部分由于是 15 分类问题,因此设定为 15×1 .

表 1 模型参数设置

Tab. 1 Model parameter settings

层类型	参数大小	激活函数
卷积层 1	16@ 7×1 (卷积数目@卷积核大小)	ReLU
池化层	2(窗口大小)	最大池化(池化类型)
全连接层 1	80@ 64×1 (输出尺寸)	—
全连接层 2	64@ 15×1 (输出尺寸)	—
BiLSTM	1@64(隐藏层数目@隐藏层单元数)	tanh
Adam(优化器)	64@50(批量大小@训练轮数)	MSE(损失函数)

3 实验结果与分析

3.1 尾减轴承实验结果与分析

本文选择均方根误差 (RMSE, E_{RMS}) 和确定系数 (Rsquare, R) 作为模型的评价指标,对每一个样本的真实寿命与模型输出的预测寿命进行计算. RMSE 反映的是模型回归的误差平方的期望值. Rsquare 主要表明模型的拟合效果,其范围为 $[0, 1]$,值越大则说明模型的拟合效果越好,反之亦然.

RMSE 的定义如下:

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{true},i} - y_{\text{pred},i})^2},$$

式中: n 为样本总数, $y_{\text{true},i}$ 是第 i 个样本的真实寿命值, $y_{\text{pred},i}$ 是第 i 个样本的预测寿命值.

Rsquare 的定义如下:

$$R = 1 - \frac{\sum_{i=1}^n (y_{\text{true},i} - y_{\text{pred},i})^2}{\sum_{i=1}^n (y_{\text{true},i} - \bar{y}_{\text{true}})^2},$$

式中: \bar{y}_{true} 是所有真实寿命值的均值.

本文使用 3 种模型 LSTM、BiLSTM、CNN-BiLSTM 与本文提出的 AR-CNN-BiLSTM 模型进行对比,实验结果如图 6 所示.

总的来说,4 种模型由于采用了 LSTM 或 BiLSTM 提取时序变化趋势,均能较好地捕捉到损伤突变的拐点. 但由于仅采用 LSTM 或 BiLSTM,特征挖掘能力有限,对慢速退化与快速退化阶段的拟合能力均不太理想. 而引入 CNN 后,由于提取了更深层次的特征,模型在快速退化阶段的拟合精度上有所提升,但在运行初期即缓慢退化阶段的预测精度依然很低,这是因

为缓慢退化阶段的特征区分度低,区分难度更大。

AR-CNN-BiLSTM 的预测结果不仅解决了其他模型在缓慢退化阶段预测精度差的问题,还进一步提升了快速退化阶段的预测精度,这是因为 AR 模型提取的特征对设备状态的变化更敏感,其退化趋势更明显,所以模型在训练过程中更易习到有效的特征表示。

另外,评价指标及训练时间如表 2 所示,可以看出,本文模型的评价指标最优, RMSE 为 1.344, Rsquare 为 0.998。

在训练耗时方面,4 种模型的耗时从短到长依次为 AR-CNN-BiLSTM、LSTM、CNN-BiLSTM, BiLSTM。这是因为 BiLSTM 需要进行双向计算,因此计算量是 LSTM 的两倍左右。对于 CNN-BiLSTM, CNN 层能够有效降维,从而减少 BiLSTM 部分的计算量,所以运行时间明显低于 BiLSTM。而 AR 模型对输入数据的进一步降维,减少了后续 CNN 和 BiLSTM 的计算量,所以训练耗时明显低于 BiLSTM 与 CNN-BiLSTM,甚至略低于 LSTM。




图 6 RUL 预测结果

Fig. 6 RUL prediction results

表 2 各模型的预测结果对比

Tab. 2 The prediction results of each model are compared

预测模型类型	RMSE	Rsquare	训练耗时/s
LSTM	17.225	0.6824	290.43
BiLSTM	13.379	0.8083	588.62
CNN-BiLSTM	11.589	0.8562	473.19
AR-CNN-BiLSTM	1.344	0.9981	277.31

3.2 西安交通大学滚动轴承数据集实验结果与分析

利用西安交通大学(Xi'an Jiaotong University, XJTU)滚动轴承数据集^[17]进一步验证本文方法的优

越性。实验结果如表 3 所示,需要指出的是,XJTU 数据集结果中的 RMSE 明显低于尾减轴承数据集的结果,这是由于 XJTU 数据集的振幅数值较小。但是从 Rsquare 中仍然可以看出本文模型性能更优。在训练耗时方面,因为数据量小,所有模型的训练时间均较短,模型训练时间的差异与本文数据集一致,AR-CNN-BiLSTM 仍然仅需最短的训练时间。

4 结论

本文提出了一种新的模型,该模型结合了 AR 模型和 CNN-BiLSTM。该方法利用 AR 模型主成分突出,冗余信息少的优势,结合 CNN 的深层特征提取能

表3 各模型的预测结果对比

Tab.3 The prediction results of each model are compared

预测模型类型	RMSE	Rsquare	训练耗时/s
LSTM	0.0607	0.9557	33.59
BiLSTM	0.0541	0.9604	61.25
CNN-BiLSTM	0.0399	0.9784	57.47
AR-CNN-BiLSTM	0.0103	0.9917	31.02

力和 BiLSTM 的时序信息处理优势,显著提升了尾减速轴承的早期 RUL 预测精度。

实验结果表明,提出的 AR-CNN-BiLSTM 模型能够有效捕捉到轴承早期退化过程中的重要特征,预测精度与训练速度较传统模型有可观的提升。并且通过与其他深度学习方法的比较,验证了 AR-CNN-BiLSTM 模型在早期 RUL 预测中的有效性。除此以外,还在其他数据集上验证了方法的优越性。

综上所述,本文的方法为实际工程应用中实现轴承的早期维护决策提供了有效的技术支持。未来的研究可以进一步研究模型可解释性相关的问题,尤其在航空航天这种高可靠性要求的场合,为了确保预测结果可以被工程师理解和信任,引入可解释性技术是很有必要的。此外,考虑到实际工况中往往涉及到多种传感器数据,未来的研究还可以进一步探讨多模态数据融合。通过结合来自不同传感器(如振动、温度、压力等)的数据,以全面提升 RUL 预测的准确性。

参考文献:

- [1] 潘光奇,朱勇. 直升机传动系统现状和发展综述[J]. 舰船电子工程,2009,29(11):33-36,39.
- [2] 丁文强. 直升机传动系统发展概述[J]. 航空动力,2018(3):65.
- [3] 门坤发,夏双满,孙恒,等. 直升机尾减速器连接寿命的确定[J]. 计算机辅助工程,2016,25(3):24-28,33.
- [4] 卢光辉. 基于磨削加工表面完整性的滚动接触疲劳寿命预测[D]. 上海:上海交通大学,2009.
- [5] LIU H Y, MO Z L, ZHANG H, et al. Investigation on rolling bearing remaining useful life prediction: a review [C] // Prognostics and System Health Management Conference. Piscataway: IEEE, 2018: 979-984.
- [6] GIDUTHURI S B, ZHAO P L, LI X L. Deep convolutional neural network based regression approach for estimation of remaining useful life [C] // Database Systems for Advanced Applications. Cham: Springer, 2016: 214-228.
- [7] MALHOTRA P, TV V, RAMAKRISHNAN A, et al. Multi-sensor prognostics using an unsupervised health index based on LSTM encoder-decoder[EB/OL]. [2025-01-01]. <https://arxiv.org/pdf/1608.06154v1>.
- [8] 王瀚卿. 基于 LSTM 网络的滚动轴承寿命预测方法[D]. 西安:西安理工大学,2024.
- [9] 韩允童,王靖岳,侯兴达,等. 改进 CNN-LSTM 模型的滚动轴承剩余寿命预测方法[J]. 车辆与动力技术 2024(2):1-6.
- [10] 武将. 基于卷积神经网络和双向 LSTM 的滚动轴承剩余寿命预测[D]. 沈阳:沈阳工业大学,2024.
- [11] 曾小军,黄宜坚. 基于 AR 模型和支持向量机的故障诊断法[J]. 机械科学与技术,2010,29(7):972-975,980.
- [12] 周建民,郭慧娟,张龙. 基于 AR-FCM 的滚动轴承的性能退化评估[J]. 机械传动,2017,41(12):73-76.
- [13] 周建民,尹文豪,游涛,等. 基于 AR 能量比-FCM 的滚动轴承退化状态定量评估[J]. 机床与液压,2021,49(1):175-179.
- [14] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [15] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. Neural Computation, 2019, 31(7): 1235-1270.
- [16] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. The performance of LSTM and BiLSTM in forecasting time series [C] // International Conference on Big Data. Piscataway: IEEE, 2019: 3285-3292.
- [17] WANG B, LEI Y, LI N. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. IEEE Transactions on Reliability, 2020, 69(1): 401-412.

(责任编辑:任滢滢)