



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于并行双向时间卷积网络和双向长短期记忆网络的轴承剩余使用寿命预测方法

梁浩鹏, 曹洁, 赵小强

引用本文:

梁浩鹏, 曹洁, 赵小强. 基于并行双向时间卷积网络和双向长短期记忆网络的轴承剩余使用寿命预测方法[J]. 控制与决策, 2024, 39(4): 1288–1296.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0152>

您可能感兴趣的其他文章

Articles you may be interested in

[基于卷积长短时记忆神经网络的城市轨道交通短时客流预测](#)

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

[基于深度时序特征迁移的轴承剩余寿命预测方法](#)

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

[考虑退化轨迹差异性与相似性的轴承RUL预测](#)

Prediction of bearing remaining useful life involving difference and similarity of degradation trajectories

控制与决策. 2021, 36(11): 2832–2840 <https://doi.org/10.13195/j.kzyjc.2020.1028>

[改进集成深层自编码器在轴承故障诊断中的应用](#)

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

[一种基于深度学习的时间序列预测方法](#)

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645–652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

基于并行双向时间卷积网络和双向长短期记忆网络的 轴承剩余使用寿命预测方法

梁浩鹏¹, 曹洁^{1,2†}, 赵小强³

(1. 兰州理工大学 计算机与通信学院, 兰州 730050; 2. 兰州城市学院 信息工程学院, 兰州 730050;
3. 兰州理工大学 电气工程与信息工程学院, 兰州 730050)

摘要: 在基于深度学习的轴承剩余使用寿命(RUL)预测方法中,时间卷积网络(TCN)忽略了振动数据中未来时间信息的重要性,长短期记忆网络(LSTM)难以有效地学习振动数据的长时间序列特征. 针对以上问题,提出一种基于并行双向时间卷积网络(Bi-TCN)和双向长短期记忆网络(Bi-LSTM)的轴承RUL预测方法. 首先,对多传感器数据进行归一化处理,并将每个传感器数据进行通道合并,实现多传感器数据的高效融合;然后,采用Bi-TCN和Bi-LSTM构建并行的双分支特征学习网络,其中Bi-TCN提取数据的双向长时间序列特征,Bi-LSTM提取数据的时间相关特征;同时,设计一种特征融合注意力机制,该机制分别计算Bi-TCN和Bi-LSTM的输出权重,以实现两种网络输出特征的自适应加权融合;最后,融合特征通过全连接层并输出轴承RUL的预测结果. 利用西安交通大学轴承数据集和PHM 2012轴承数据集进行RUL预测实验,实验结果表明,与其他先进的预测方法相比,所提出方法可以准确预测更多类型轴承的RUL,同时具有更低的预测误差.

关键词: 滚动轴承; 剩余使用寿命预测; 多传感器融合; 双向时间卷积网络; 双向长短期记忆网络

中图分类号: TH133.3 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2023.0152

引用格式: 梁浩鹏,曹洁,赵小强. 基于并行双向时间卷积网络和双向长短期记忆网络的轴承剩余使用寿命预测方法[J]. 控制与决策, 2024, 39(4): 1288-1296.

Remaining useful life prediction method for bearing based on parallel bidirectional temporal convolutional network and bidirectional long and short-term memory network

LIANG Hao-peng¹, CAO Jie^{1,2†}, ZHAO Xiao-qiang³

(1. College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China; 2. College of Information Engineering, Lanzhou City University, Lanzhou 730050, China; 3. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In remaining useful life (RUL) prediction methods for bearings based on deep learning, temporal convolutional networks (TCNs) does not consider the future time information of vibration data, long and short-term memory (LSTM) networks are difficult to learn long time series data features effectively. To solve the above problems, a bearing RUL prediction method based on the parallel bidirectional temporal convolutional network and bidirectional long and short-term memory network is proposed. First, the multi-sensor data are normalized, and the data of each sensor are merged by channel to achieve efficient fusion of multi-sensor data. Then, a parallel dual network structure is constructed by using the Bi-TCN and Bi-LSTM, in which the Bi-TCN goes to learn the bi-directional long time series features and the Bi-LSTM goes to learn the time-dependent features, so the parallel dual network structure can learn richer vibration signal features. Meanwhile, a feature fusion attention mechanism is developed to fuse the output features of the dual network structure, which calculates the output weights of the Bi-TCN and Bi-LSTM to achieve adaptive weighted fusion of the output features. Finally, the fused features are passed through the fully connected layer to output the prediction results of the bearing RUL. RUL prediction experiments are conducted using Xi'an Jiaotong University bearing dataset and PHM 2012 bearing dataset respectively. The results show that, compared with the advanced prediction methods, the proposed method can accurately predict the RUL of more types of bearings and has lower prediction errors.

Keywords: rolling bearing; remaining useful life prediction; multi-sensor fusion; Bi-TCN; Bi-LSTM

收稿日期: 2023-02-10; 录用日期: 2023-06-16.

基金项目: 国家重点研发计划项目(2020YFB1713600); 甘肃省重点研发计划项目(21YF5GA072); 甘肃省教育厅产业支撑计划项目(2021CYZC-02).

†通讯作者. E-mail: haop1115@163.com.

0 引言

滚动轴承作为旋转机械的关键部件,长期工作在噪声干扰和载荷多变的环境中,导致其经常发生故障^[1].滚动轴承的预测和健康管理技术是一类避免轴承在工业生产中发生故障的技术,此类技术不仅可以提高轴承工作系统的稳定性,而且可以降低旋转设备的维护成本.近年来,为了准确地判断滚动轴承的健康状态,学者们对滚动轴承的剩余使用寿命(remaining useful life, RUL)预测方法进行了大量的研究^[2].随着计算机处理技术的快速发展,基于深度学习的数据驱动方法逐渐成为预测方法主流^[3].作为深度学习方法的代表,循环神经网络(recurrent neural network, RNN)、卷积神经网络(convolutional neural network, CNN)以及其变体网络在寿命预测领域获得了广泛应用.例如, Ma等^[4]在长短时记忆网络(long short term memory, LSTM)中引入卷积运算,从而捕获了振动信号的时间和频率信息,并有效预测轴承的RUL.然而, LSTM是一种单向的RNN结构,只能根据过去时间的信息处理当前时间的信息.为了同时分析过去和未来的信息,双向长短时记忆网络(Bidirectional-LSTM, Bi-LSTM)采用一种双网络结构传递隐含层特征,在轴承RUL的测试中表现出更强的性能.例如,申彦斌等^[5]利用Bi-LSTM针对未来时间数据的学习能力,建立了实际工作环境中的轴承退化模型.尽管LSTM及Bi-LSTM可以学习时间序列数据中前后数据的依赖关系,但是它们复杂的链式结构会导致更久的训练时间和对长时序的弱敏感性.为了建立更高效的预测模型,一些研究人员使用CNN实现轴承RUL预测.例如, Li等^[6]提出了一种基于CNN的预测方法,该方法采用循环一致性学习方案训练网络模型,从而使不同轴承的振动数据在类似退化水平上保持一致.尽管CNN具有提取局部相关特征的出色能力,但是CNN对时间信息缺乏敏感性,容易忽略数据中时间信息的前后相关性^[7].针对该问题, Bai等^[8]将因果卷积与空洞卷积相结合,提出了一种时间卷积网络(temporal convolutional network, TCN),它具有与RNN相似的时间特征提取能力,在时间序列建模任务中取得了较好的效果.然而,现有TCN大多使用基于单向特征传递的网络结构,这使得TCN只能提取过去的时间特征信息,无法获得未来时间特征信息.

此外,近年来随着智能制造系统的逐步完善,大量信号传感器被部署在现代工业领域中^[9]. Qiao等^[10]指出多个传感器可以在工业生产过程中采集大量数据,并提高工业设备健康监测系统的可靠性,因

此多传感器数据信息比单传感器数据信息更有研究价值.然而,如何有效地利用多传感器数据并实现特征信息的融合仍是有待解决的问题^[11].综上,尽管深度学习方法在轴承RUL预测领域已经取得了不错的结果,但仍有一些问题需要解决:1)TCN只能根据过去的时间特征信息来判断当前的轴承运行状态,无法利用未来时间特征信息;2)Bi-LSTM可以提取振动数据的时间依赖特征,但是无法提取振动数据的长时间序列特征.鉴于此,本文提出一种基于并行Bi-TCN和Bi-LSTM的轴承剩余寿命预测方法.该方法首先利用通道拼接的方式融合多传感器数据;然后建立一种并行的双分支网络学习多传感器数据特征,其中Bi-TCN分支网络负责学习数据中较长的时间序列特征, Bi-LSTM分支网络负责学习数据中不同时间点的相关性特征.最后设计一种特征融合注意力机制,该机制在融合两个分支网络的输出特征时可以增强有用信息并抑制冗余信息,最终实现两种输出特征的有效融合.

1 基于Bi-TCN和Bi-LSTM的轴承RUL预测方法

在实际工业生产过程中,轴承在任意时刻的真实RUL都是未知的.因此,通过分析现有轴承的历史运行数据,实现其他轴承的寿命预测对于保障工业安全十分重要.为此,提出一种基于并行Bi-TCN和Bi-LSTM的预测方法.该方法主要包括3个部分:多传感器数据融合处理、并行Bi-TCN和Bi-LSTM模型构建、离线模型的训练和在线轴承RUL的预测.

1.1 多传感器数据融合处理

与单传感器相比,多个传感器可以从轴承的不同位置获取振动数据,因此多传感器数据包含更丰富的特征信息.为了提高预测方法的可靠性和稳定性,采用通道融合的方式实现多传感器数据的高效融合,融合过程如图1所示.

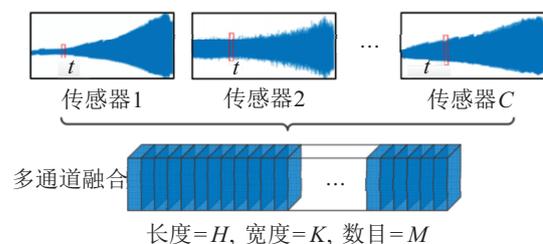


图1 基于通道融合的多传感器数据融合过程

假设存在 M 个滚动轴承及它们的性能退化数据,每个轴承的性能退化数据将通过 C 个传感器采集,并且每个传感器具有相同采样间隔 t ,则第 c 个传感器采集的第 t 个数据样本可以表示为 $X_t^c, X_t^c \in$

$\mathbb{R}^{H \times 1}$, 其中 H 代表每个样本的长度, 并且每个传感器的数据可以作为一个单通道数据. 首先, 为了减少不同轴承之间数据分布差异的影响, 对每个传感器采集的原始数据进行归一化处理. 然后将每个传感器数据按照通道进行拼接, 从而获得多通道融合数据 X_t^m , 可以表示为

$$X_t^m = \{\tilde{x}_t^1, \tilde{x}_t^2, \dots, \tilde{x}_t^K\}. \quad (1)$$

其中: $X_t^m \in \mathbb{R}^{H \times K}$ 为第 m 个轴承经过多通道融合后的第 t 个样本, 第 m 个轴承的全部样本可以表示为 $\{X_t^m\}_{t=1}^N$, N 为总采样时间. 最后第 m 个轴承第 t 个样本的标签可以表示为 y_t^m , 第 m 个轴承的全部样本标签可以表示为 $\{y_t^m\}_{t=1}^N$. 基于以上样本和标签, 第 m 个轴承的多传感器融合数据可以表示为 $\{x_t^m, y_t^m\}_{t=1}^N$. 对于 M 个轴承, 每个轴承的多传感器数据经过通道融合后, 将作为深度学习模型的训练集, 而经过训练后的模型将用于预测其他轴承的 RUL.

1.2 Bi-TCN 和 Bi-LSTM 模型构建

1.2.1 Bi-LSTM

许多研究证明, LSTM 可以有效处理输入与输出之间的时间关系, 并学习时间序列的数据相关性. 然而, LSTM 只能利用先前时间的信息来预测当前时间的状态, 无法利用未来时间的信息^[12]. 针对此问题, Bi-LSTM 采用两个相反方向的 LSTM 构建, 从而实现双向时间信息的处理. 在 Bi-LSTM 中前向 LSTM 沿着时间数据的正向顺序计算隐藏层信息, 后向 LSTM 沿时间数据的反向顺序计算隐藏层信息, 然后融合两个 LSTM 的隐藏层信息, 并获得 Bi-LSTM 的输出信息. Bi-LSTM 可以从历史和未来时间数据中获得双向信息, 并且比 LSTM 具有更强大的特征学习性能.

1.2.2 Bi-TCN

TCN 是一种提取振动信号长时间特征的网络, 然而其只能根据过去时间的振动信息判断当前的轴承运行状态. 为了使 TCN 同时提取过去和未来时间的特征信息, 并实现多层次的双向特征信息融合, 引入一种更有效的 Bi-TCN 模型. Bi-TCN 主要由正向 TCN 模块和反向 TCN 模块构成, 正向 TCN 模块使用过去时间数据作为输入, 反向 TCN 模块使用未来时间数据作为输入. 对两种模块提取的特征进行融合, 并将融合特征与 Bi-TCN 的输入特征进行融合, 构成残差映射, 从而加速梯度的反向传播.

1.2.3 特征融合注意力机制

在大多数双分支网络结构研究中, 每个分支网络的输出通过逐元素相加的方式进行特征融合, 从而使

每个分支网络的权重相同. 如果使用相同的权重对每个分支网络的输出进行融合, 则将导致重要的特征未被突出, 冗余的特征被保留, 最终影响整个网络的性能. 针对此问题, 构建一种新型的特征融合注意力机制加强 Bi-TCN 分支网络和 Bi-LSTM 分支网络的作用和贡献, 融合过程包括以下 3 个步骤.

step 1: 特征压缩. 首先, Bi-TCN 分支网络和 Bi-LSTM 分支网络的输出 O 和 M 可以分别表示为

$$O = [O_1, O_2, \dots, O_C], \quad O_i \in \mathbb{R}^{L \times 1 \times C};$$

$$M = [M_1, M_2, \dots, M_C], \quad M_i \in \mathbb{R}^{L \times 1 \times C}.$$

其中: C 为通道数目, L 为特征长度. 考虑到双分支网络受感受野的限制, 网络输出缺乏全局信息, 因此使用全局平均池化运算将双分支网络的输出特征信息压缩到每个通道向量中, 有

$$z_i = \frac{1}{1 \times L} \sum_{j=1}^L O_i(j), \quad (2)$$

$$v_i = \frac{1}{1 \times L} \sum_{j=1}^L M_i(j). \quad (3)$$

其中: $z, v \in \mathbb{R}^{1 \times C}$, z_i 和 v_i 为向量中 z 和 v 的第 i 个向量因子. 将两个通道向量进行融合, 得到向量 s 为

$$s = z \oplus v. \quad (4)$$

其中: $s \in \mathbb{R}^{1 \times C}$, \oplus 代表逐元素相加融合, s 包含两个分支网络的信道信息.

step 2: 特征提取. 使用两个全连接感知器建立跨纬度信道之间的依赖关系, 并强调每个通道的重要性, 有

$$U = \delta_2(\tau(\delta_1(s))). \quad (5)$$

其中: δ_1 和 δ_2 分别为第 1 个和第 2 个全连接感知器, τ 为非线性激活函数. 两个全连接感知器构成编码和解码的结构, 可以放大两个分支网络通道信息之间的关系. 利用 softmax 激活函数计算两个分支网络的输出权重, 即为 Bi-TCN 分支网络和 Bi-LSTM 分支网络的输出特征构建可学习的加权参数, 有

$$W_1 = \frac{e^{U_{1,c}}}{\sum_{i=1}^N e^{U_{1,c}}}, \quad (6)$$

$$W_2 = \frac{e^{U_{2,c}}}{\sum_{i=1}^N e^{U_{2,c}}}. \quad (7)$$

其中: W_1 和 W_2 分别为两种输出特征的加权参数, N 为输出特征数目, $U_{i,c}$ 为第 i 个输出中第 c 个通道向量.

step 3: 特征校准. 将动态的加权参数分别与两个

分支网络的原始输出相乘,实现每个分支网络输出特征的校准,有

$$F_1 = W_1 \otimes O, \quad (8)$$

$$F_2 = W_2 \otimes M. \quad (9)$$

其中: \otimes 代表逐元素相乘, F_1 和 F_2 分别代表加权后的 Bi-TCN 分支网络和 Bi-LSTM 分支网络的输出特征. 将两种加权后的输出特征进行融合,得到并行双分支网络的最终输出 Y 为

$$Y = F_1 \oplus F_2. \quad (10)$$

综上,特征融合注意力机制突出了权重机制的重要性,并在融合过程中自适应地为两个分支网络分配权重,最终有效提高了双分支网络特征融合的效率.

1.2.4 并行 Bi-TCN 和 Bi-LSTM 模型结构

并行 Bi-TCN 和 Bi-LSTM 模型结构如图 2 所示. Bi-TCN 分支网络主要由宽卷积层、最大池化层和多个 Bi-TCN 模块组成. 其中: 宽卷积层具有大尺寸的卷积核,并直接作用在原始信号上,具有抑制原始信号噪声成分的作用;最大池化层主要用来减少特征维度;多个 Bi-TCN 模块主要提取振动信号的双向长时间特征. Bi-LSTM 分支网络主要由 Bi-LSTM 模块组成,考虑到 Bi-LSTM 网络难以训练,只使用两个 Bi-LSTM 模块提取振动信号的时间依赖特征. 最后,通过特征融合注意力机制融合 Bi-TCN 分支网络和 Bi-LSTM 分支网络的输出特征,融合后的特征通过全连接层输出预测结果.

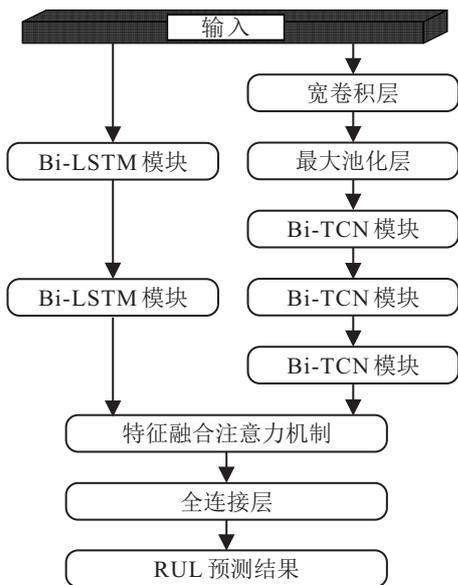


图 2 并行 Bi-TCN 和 Bi-LSTM 网络模型结构

1.3 离线模型的训练和在线轴承 RUL 的预测

首先对多传感器采集到的轴承振动数据进行融合,然后将多传感器融合数据分为训练轴承数据和

测试轴承数据. 在离线建模过程中,将训练数据输入到并行 Bi-TCN 和 Bi-LSTM 模型中,并进行多次训练,训练过程计算损失函数以及反向传播更新模型参数,当训练次数 i 大于总的训练次数 N 时,模型完成训练. 在线预测过程中,将测试数据输入到训练完成的预测网络模型中进行实时预测,并设置评估指标去验证模型的预测性能. 最后通过可视化图展示预测结果. 评估指标包括两个误差指标,定义如下:

$$MAE = \frac{1}{n} \sum_{t=1}^n |er_t|, \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (er_t)^2}. \quad (12)$$

其中: MAE 和 RMSE 分别为平均绝对误差和均方根误差, er_t 为 t 时刻预测 RUL 与真实 RUL 的差值,即 $er_t = Rul_t^{pre} - Rul_t^{act}$, n 为轴承的全部寿命时间,更低的 MAE 和 RMSE 代表更好的预测结果.

2 实验仿真和结果分析

本节包括两个案例,分别使用西安交通大学提供的轴承退化数据集以及电气电子工程师协会提供的 PHM 2012 挑战赛数据集验证所提出方法的预测性能. 实验计算机配置为 i9-9900K CPU、NVIDIA RTX2080Ti 处理器和 64 GB 内存,实验框架为 Keras-python.

2.1 并行 Bi-TCN 和 Bi-LSTM 模型参数设置

在两个案例中,模型使用相同的网络参数,具体如表 1 所示. 在 Bi-TCN 中,核尺寸代表卷积核大小,除了多通道融合层使用的核尺寸为 64×1 ,其余层使用的均是小卷积核,从而减少模型训练负担;通道数代表通道的数目,为 2 的次幂且逐渐增大;步长代表步长大小,即特征经过下采样后的尺寸缩减倍数;空洞率代表空洞扩张率,3 个 Bi-TCN 模块的空洞率分别为 1、2、4,这样可以避免空洞卷积的网格效应问题. 每个 Bi-TCN 模块内部的 Dropout 参数为 0.2, leaky 参数为 0.2,保证参数一致性. 在 Bi-LSTM 中,unit 代表隐藏单元的数目,Dropout 代表参数随机失活率. 并行 Bi-TCN 和 Bi-LSTM 模型采用的训练方式为多批次训练,每个批次的样本数为 128,训练批次数为 50. 模型的初始学习率设置为 0.01. 将预测标签与真实标签之间的均方误差作为模型的目标损失函数. 此外,模型在训练过程中利用 Adam 优化算法进行梯度优化,更新权重、偏置等参数,从而使模型的均方误差达到最小.

表1 并行Bi-TCN和Bi-LSTM模型参数

不同层		参数
宽卷积层		核尺寸=8, 通道数=64, 步长=4
最大池化层		池化步长=4
Bi-TCN	模块1	核尺寸=3, 通道数=16, 空洞率=1, Dropout=0.3
	模块2	核尺寸=3, 通道数=32, 空洞率=2, Dropout=0.3
	模块3	核尺寸=3, 通道数=64, 空洞率=4, Dropout=0.3
Bi-LSTM	模块1	门单元=16, Dropout=0.2
	模块2	门单元=32, Dropout=0.2

特征融合注意力机制和全连接层

2.2 对比方法

为了验证所提出方法的优越性,选择4种先进预测方法作为对比方法,其中DANN^[13]使用对抗性学习方式训练健康数据并估计轴承的RUL;TCN-RSA^[14]在TCN中引入一种自注意力机制,从而可以学习振动信号的时间频率信息和空间信息;TCN-SA^[15]是一种结合了软阈值注意力机制和TCN的预测模型,软阈值注意力机制有效地提高了预测模型的鲁棒性;阈值CNN^[16]使用标准卷积代替TCN的扩张因果卷积,并使用软阈值注意力机制提高预测性能。

2.3 案例1

2.3.1 数据描述

本案例使用的实验数据为XJTU-SY数据集^[17],由西安交通大学机械设备健康监测实验室提供,实验台由交流电机、电机调速控制器、支撑轴承、测试轴承等组成,其中两个相同型号的PCB 352C33单向加速度计传感器被固定在测试轴承的水平轴和垂直轴上。在数据采集阶段,加速度计传感器分别从水平方向和垂直方向采集滚动轴承的全生命周期振动数据,其中传感器的采样频率为25.6kHz,采样间隔为1min,每次采样的时间为1.28s,因此每个传感器在每分钟将采集32768个数据点。传感器从轴承的正常工作状态开始采集振动数据,当振动数据的最大振幅超过20g(1g=9.8m/s²)时,轴承被视为完全失效并终止采集。本文将传感器每分钟采集的振动数据作为一个样本点,样本的长度为32768,水平传感器的第 t 个样本表示为 $x_t^1 \in \mathbb{R}^{32768 \times 1}$,垂直传感器的第 t 个样本表示为 $x_t^2 \in \mathbb{R}^{32768 \times 1}$ 。然后,对水平传感器和垂直传感器采集的数据进行多传感器数据融合处理,两种传感器数据经过归一化、通道拼接

等处理后,最终得到轴承的多传感器融合数据样本 $X_t^m, X_t^m \in \mathbb{R}^{32768 \times 1}$ 。

实验台通过在测试轴承的轴承座上施加不同的径向力产生不同的工况,实验选用两种工况下LDK UER204滚动轴承数据验证所提出方法性能,其中每种工况下包含5个轴承的全生命周期数据,即A1_1~A1_5和A2_1~A2_5。在某一工作条件下,将使用任意4种轴承的多传感融合数据作为训练集,剩下一种轴承的多传感融合数据作为测试集。考虑到轴承在不同退化状态时可能会产生相同的RUL值,将轴承的实际RUL进行归一化处理,即使用轴承的寿命百分比作为输出标签,标签处理公式如下:

$$y_t^m = \frac{y_t}{y} \times 100\% \quad (13)$$

其中: y_t^m 为输出标签, y_t 为轴承在 t 时刻的真实RUL, y 为总时间的RUL。在标签 y_t^m 中,100%代表轴承状态健康,0%代表轴承状态失效。

2.3.2 预测结果分析

在两种工况条件下,本案例测试10个轴承的RUL,每个轴承预测实验重复5次,选用5次结果的平均值作为最终结果,所有方法的预测误差结果如表2所示。对于大多数的测试轴承,所提出方法具有更低的MAE和RMSE值,这表明所提出方法具有更好的轴承RUL预测性能。值得说明的是,由于轴承在退化过程中常出现不同种类的复杂故障,预测方法几乎不可能对每个轴承都能实现最好的RUL预测结果。相比于先进的预测方法,所提出方法对少数轴承的预测结果较差是可以接受的。另外,通过对比大多数情况下的预测误差值以及最终的平均MAE值和平均RMSE值可以看出,所提出方法在整体的RUL预测方面始终优于其他对比方法。

表2 XJTU-SY数据集的轴承RUL预测结果

测试轴承	DANN		TCN-RSA		TCN-SA		阈值CNN		所提出方法	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
A1_1	21.6	23.1	21.5	25.9	5.2	7.1	14.3	16.6	10.6	12.9
A1_2	28.5	32.3	18.8	23.0	19.0	24.0	8.2	11.8	9.2	15.4
A1_3	18.7	22.4	13.6	16.0	17.0	21.7	16.1	18.9	12.9	16.2
A1_4	32.4	37.1	11.9	14.0	26.8	30.4	18.5	22.2	21.4	25.3
A1_5	28.2	33.5	19.7	22.3	20.3	25.3	28.2	33.6	16.3	19.9
A2_1	7.2	8.4	23.7	29.5	13.6	16.4	23.0	28.3	19.2	23.3
A2_2	16.1	19.3	11.3	13.8	14.5	18.6	14.3	16.7	10.3	12.5
A2_3	21.6	24.5	21.8	24.4	13.6	17.1	11.0	13.4	11.4	13.9
A2_4	28.4	31.2	16.0	19.0	16.6	19.4	16.5	20.8	13.4	17.3
A2_5	32.3	26.5	18.3	22.8	11.1	14.3	14.7	18.1	10.4	13.6
平均值	23.50	25.83	17.66	21.07	15.77	19.43	16.48	20.04	13.51	17.03

2.4 案例2

2.4.1 数据描述

本案例使用PHM 2012数据集^[18],由FEMTO-ST研究所PRONOSTIA实验台提供,PRONOSTIA实验台包括异步电机、测试轴承、加速度计传感器等多种部件.两个相同类型3035B DYTRAN的加速度计传感器分别放置在测试轴承水平和垂直方向上,采集测试轴承的振动数据.传感器的采样频率为25.6kHz,采样间隔为10s,每次采样时长为0.1s,当监测到的轴承振动数据的振幅超过20g时,表明轴承完全失效并终止实验.将传感器每次采集的数据点作为一个样本,样本长度为2560,因此水平传感器和垂直传感器采集的样本可分别表示为 $x_t^1 \in \mathbb{R}^{2560 \times 1}$ 和 $x_t^2 \in \mathbb{R}^{2560 \times 1}$.对两种传感器采集的样本数据进行多传感器数据融合处理,得到轴承的多传感器融合数据样本 $X_t^m, X_t^m \in \mathbb{R}^{2560 \times 2}$.为了加速轴承的退化,实验台在测试轴承上施加径向载荷,并通过载荷调节器进行控制.选用PHM 2012数据集两种工况条件下轴承的退化数据作为实验数据,其中每种工况条件包含7个轴承的退化数据,即B1_1~B1_7和B2_1~B2_7.在某一工况条件下,选取任意6种轴承退化数据作为训练数据,剩下一种轴承退化数据作为测试数据.本案例采用的标签处理方式与案例1相同.

2.4.2 数据预处理分析

所提出方法在数据预处理过程中对原始数据进行了数据归一化以及多传感器数据融合操作,为了分析数据预处理对所提出方法性能的影响,以测试

轴承B2_1为例,采用不同的数据预处理方式进行对比实验,结果如表3所示.表3中:“水平传感器”代表预测模型只使用轴承水平轴位置传感器采集的数据,“垂直传感器”代表预测模型只使用轴承垂直轴位置传感器采集的数据,轴承两个位置的传感器型号相同,均为3035B DYTRAN,采集的轴承原始数据经归一化处理作为预测模型的输入.“多传感器(归一化)”代表所提出多传感器数据融合方式.可以看出,所提出多传感器融合数据较水平传感器数据的MAE和RMSE误差分别降低了2.0和2.9,较垂直传感器数据的MAE和RMSE误差降低了10.2和12.3,以上结果表明多传感器融合数据比单一传感器的数据更具优越性.“多传感器(无归一化)”代表对水平传感器和垂直传感器采集的数据进行融合,融合过程不使用数据归一化处理.归一化后的多传感器数据较未归一化的多传感器数据的MAE和RMSE误差分别降低了3.9和4.7,原因在于归一化处理减少了不同类型轴承之间的数据分布差异,从而使得所提出方法具有更强的泛化能力和更低的预测误差.

表3 不同的数据预处理方式实验结果

输入数据	MAE	RMSE
水平传感器	21.5	27.3
垂直传感器	29.7	36.5
多传感器(无归一化)	23.4	28.9
多传感器(归一化)	19.5	24.2

2.4.3 预测结果分析

本案例预测了14个轴承的RUL,预测结果如表4所示.对于大多数测试轴承,所提出方法的MAE和RMSE低于对比方法,并且所提出方法的平均MAE和平均RMSE是最低的.以上实验结果表明所提出方法的预测性能最好,原因在于通过多传感器数据融合方法高效地融合了多传感器数据,建立了Bi-TCN分支网络学习振动信号过去和未来时间的特征,以及Bi-LSTM分支网络学习时间相关特征,最后通过设计的特征融合注意力机制融合两种特征,从而使所提出方法具有较强的特征学习能力.图3显示了B1_2和B2_4轴承的RUL预测结果,所提出方法可以精准预测轴承的健康状态.此外,虽然所提出方法的预测曲线存在局部振荡现象,但是能够很好地预测轴承在寿命后期的状态,因此所提出方法具有令人满意的轴承RUL预测能力.

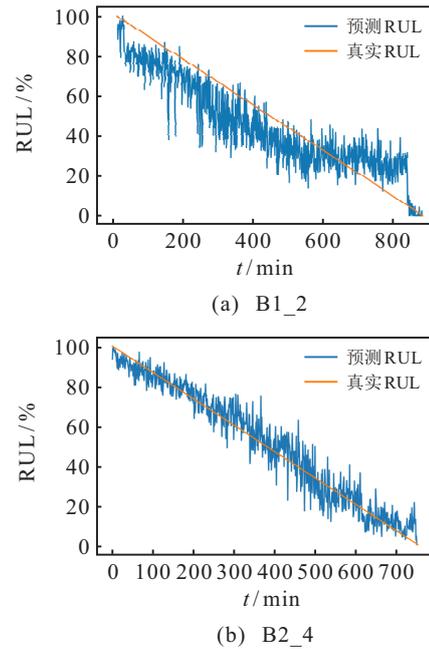


图3 PHM 2012数据集测试轴承的RUL可视化预测结果

表4 PHM 2012数据集的轴承RUL预测结果

测试轴承	DANN		TCN-RSA		TCN-SA		阈值CNN		所提出方法	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
B1_1	13.3	16.0	11.0	13.7	10.4	11.3	8.7	10.9	10.3	13.3
B1_2	15.3	17.2	14.0	16.3	13.0	16.9	12.1	16.1	11.0	15.2
B1_3	28.4	33.5	11.4	14.1	9.7	11.7	15.3	18.2	9.1	11.6
B1_4	22.6	25.1	13.7	15.8	7.1	8.5	5.7	7.4	7.6	10.0
B1_5	13.4	15.6	10.9	13.2	9.1	13.0	9.5	13.0	9.0	12.4
B1_6	13.5	17.7	8.4	11.1	8.3	11.9	12.2	15.3	11.8	14.3
B1_7	15.2	19.3	17.8	23.5	9.0	12.9	17.6	21.9	9.3	11.6
B2_1	16.3	19.0	29.0	35.3	14.3	18.1	33.6	39.9	19.5	24.2
B2_2	26.3	29.4	17.2	21.4	14.5	18.6	17.5	21.6	13.7	17.2
B2_3	13.5	16.8	24.4	30.8	17.9	23.0	19.8	27.0	18.5	24.1
B2_4	12.0	14.3	6.5	8.1	5.2	6.4	6.1	7.6	5.0	6.1
B2_5	22.7	27.5	15.2	18.9	13.3	16.1	17.4	21.7	13.2	16.1
B2_6	20.6	23.3	12.2	14.3	10.9	13.8	14.5	18.6	9.2	12.9
B2_7	12.6	13.9	18.6	24.1	17.5	25.0	8.6	10.4	12.3	14.6
平均值	17.55	20.61	15.02	18.61	11.44	14.80	14.19	17.83	11.39	14.54

2.4.4 并行的双分支网络结构效果分析

为了验证所提出方法中并行的双分支网络结构的有效性,以轴承B1_7为测试轴承,与不同网络结构的方法进行对比实验,结果如表5所示.表5中:“双分支网络串联”代表Bi-TCN与Bi-LSTM串行连接的方法;“膨胀卷积验证”代表去除了所提出方法的膨胀卷积;Bi-TCN和Bi-LSTM分别代表不同的单分支网络结构方法;TCN+LSTM代表由TCN和LSTM组成的并行网络方法;Bi-TCN+LSTM代表由Bi-TCN和

LSTM组成的并行网络方法;TCN+Bi-LSTM代表由TCN和Bi-LSTM组成的并联网络方法;Bi-TCN+Bi-LSTM代表所提出的双分支并联网络方法.由表5对比实验结果可以看出:

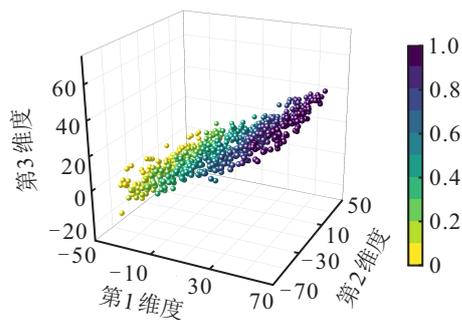
1) 双分支网络串联的MAE和RMSE比所提出的双分支并联网络的MAE和RMSE分别高2.5和4.6,这表明并行连接模型的性能更具优越性.另外,去除了所提出方法的膨胀卷积后,预测误差明显上升,表明膨胀卷积的宽感受野有助于网络提取数据中的长

表5 不同的数据预处理方式实验结果

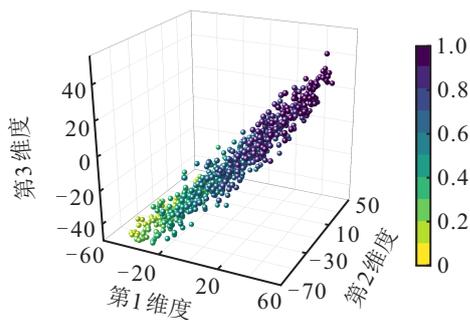
不同方法	MAE	RMSE
双分支网络串联	11.81	6.2
膨胀卷积验证	13.2	18.5
Bi-TCN	12.5	16.5
Bi-LSTM	23.5	29.1
TCN+LSTM	16.3	22.6
Bi-TCN+LSTM	10.9	14.0
TCN+Bi-LSTM	14.1	18.7
Bi-TCN+Bi-LSTM	9.3	11.6

时间序列特征,从而提升所提出方法的预测性能。

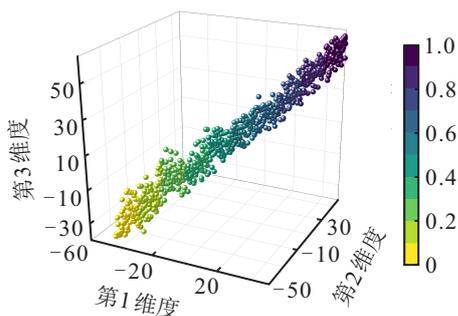
2) Bi-TCN和Bi-LSTM都是单分支网络方法,它们的预测误差明显高于所提出方法,表明单分支网络方法的特征提取能力具有局限性,而多分支网络可以从数据中提取更全面的特征,实现更好的预测结果。



(a) Bi-LSTM输出特征



(b) Bi-TCN输出特征



(c) Bi-LSTM和Bi-TCN融合输出特征

图4 双分支并联网络的特征融合可视化

3) TCN+LSTM、Bi-TCN+LSTM、TCN+Bi-LSTM、Bi-TCN+Bi-LSTM代表不同网络组合方法,其中Bi-TCN+Bi-LSTM具有最小的MAE和RMSE误差,原因是Bi-TCN和Bi-LSTM都可以从“过去”和“未来”两个方向提取数据中的特征信息,而TCN和LSTM只能单向提取特征信息,导致TCN、LSTM及其组合方法的性能受到了限制。另外,Bi-TCN可以提取数据中的长时间特征信息,Bi-LSTM可以提取数据中的时间相关特征信息,本文通过结合Bi-TCN和Bi-LSTM的优点实现了最优的方法组合。

为了进一步分析所提出双分支并联网络的特征融合过程,将融合前和融合后的特征分别映射到三维空间进行可视化展示,如图4所示。点的颜色代表该点的寿命百分比标签,考虑到标签数目较多,将标签分成10类,每类使用相同的颜色。可以看出,融合前Bi-LSTM和Bi-TCN的输出特征表现出混乱发散的状态,融合后Bi-LSTM和Bi-TCN的输出特征表现出有序的状态,且表现出了轴承的退化趋势。以上结果表明双分支网络在特征提取方面具有补作用,同时也表明特征融合注意力机制可以有效提升所提出方法的预测效果。

3 结论

滚动轴承RUL预测是旋转机械健康管理系统中最重要的任务之一,为了解决深度学习无法有效预测轴承RUL的问题,提出了一种基于并行Bi-TCN和Bi-LSTM的方法,并得到以下结论:

1) 设计了一种多传感器数据融合方法,该方法将多传感器数据按照通道进行融合,不仅实现了多传感器数据的高效融合,而且弥补了传统预测方法只使用单传感器数据的不足。

2) 为了解决传统TCN不能利用未来时间特征、LSTM无法有效学习长时间序列特征的问题,提出了一种并行Bi-TCN和Bi-LSTM模型。该模型通过Bi-TCN学习数据中过去和未来方向的长时间特征,通过Bi-LSTM学习数据中时间相关特征,然后通过特征融合注意力机制实现两种特征的融合互补,因此所提出模型可以从多传感器数据学习更全面的特征信息。

3) 使用两种轴承寿命预测数据集验证所提出方法的有效性,实验结果表明所提出方法能够准确地预测多种轴承的RUL,并且与先进的深度学习方法相比,所提出方法具有更低的预测误差。未来,考虑将所提出方法应用于实践中,以实现在实际工业环境下对轴承剩余寿命的预测。

参考文献(References)

- [1] 陈佳鲜, 毛文涛, 刘京, 等. 基于深度时序特征迁移的轴承剩余寿命预测方法[J]. 控制与决策, 2021, 36(7): 1699-1706.
(Chen J X, Mao W T, Liu J, et al. Remaining useful life prediction of bearing based on deep temporal feature transfer[J]. Control and Decision, 2021, 36(7): 1699-1706.)
- [2] 陈佳鲜, 毛文涛, 刘京, 等. 基于时间序列迁移递归预测的未知工况下滚动轴承在线剩余寿命评估[J]. 控制与决策, 2023, 38(1): 112-122.
(Chen J X, Mao W T, Liu J, et al. Online remaining useful life estimation of bearing under unknown working conditions based on time series transfer recursive prediction[J]. Control and Decision, 2023, 38(1): 112-122.)
- [3] 刘小峰, 冯伟, 柏林. 考虑退化轨迹差异性与相似性的轴承RUL预测[J]. 控制与决策, 2021, 36(11): 2833-2840.
(Liu X F, Feng W, Bai L. Prediction of bearing remaining useful life involving difference and similarity of degradation trajectories[J]. Control and Decision, 2021, 36(11): 2833-2840.)
- [4] Ma M, Mao Z. Deep-convolution-based LSTM network for remaining useful life prediction[J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 1658-1667.
- [5] 申彦斌, 张小丽, 夏勇, 等. Bi-LSTM神经网络用于轴承剩余使用寿命预测研究[J]. 振动工程学报, 2021, 34(2): 411-420.
(Shen Y B, Zhang X L, Xia Y, et al. Bi-LSTM neural network for remaining useful life prediction of bearings[J]. Journal of Vibration Engineering, 2021, 34(2): 411-420.)
- [6] Li X, Zhang W, Ma H, et al. Degradation alignment in remaining useful life prediction using deep cycle-consistent learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(10): 5480-5491.
- [7] 黎德才, 张冕, 王科盛, 等. 基于改进的胶囊网络的行星齿轮箱故障诊断方法[J]. 控制与决策, 2023, 38(3): 661-669.
(Li D C, Zhang M, Wang K S, et al. Fault diagnosis method of planetary gearbox based on enhanced capsule network[J]. Control and Decision, 2023, 38(3): 661-669.)
- [8] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J/OL]. 2018, arXiv: 1803.01271.
- [9] 郭振, 王增福, 白向龙, 等. 消息传递方法及其在信息融合中的应用[J]. 控制与决策, 2022, 37(10): 2443-2455.
(Guo Z, Wang Z F, Bai X L, et al. Message passing methods and their applications in information fusion[J]. Control and Decision, 2022, 37(10): 2443-2455.)
- [10] Qiao H H, Wang T Y, Wang P, et al. A time-distributed spatiotemporal feature learning method for machine health monitoring with multi-sensor time series[J]. Sensors, 2018, 18(9): 2932.
- [11] Xie T L, Huang X F, Choi S K. Intelligent mechanical fault diagnosis using multisensor fusion and convolution neural network[J]. IEEE Transactions on Industrial Informatics, 2022, 18(5): 3213-3223.
- [12] 刘建伟, 宋志妍. 循环神经网络研究综述[J]. 控制与决策, 2022, 37(11): 2753-2768.
(Liu J W, Song Z Y. Overview of recurrent neural networks[J]. Control and Decision, 2022, 37(11): 2753-2768.)
- [13] Li X, Zhang W, Ma H, et al. Data alignments in machinery remaining useful life prediction using deep adversarial neural networks[J]. Knowledge-Based Systems, 2020, 197: 105843.
- [14] Cao Y D, Ding Y F, Jia M P, 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.
- [15] Wang Y W, Deng L, Zheng L Y, et al. Temporal convolutional network with soft thresholding and attention mechanism for machinery prognostics[J]. Journal of Manufacturing Systems, 2021, 60: 512-526.
- [16] Zhang Y Z, Zhao X Q. Remaining useful life prediction of bearings based on temporal convolutional networks with residual separable blocks[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2022, 44(11): 1-13.
- [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] Nectoux P, Gouriveau R, Medjaher K, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests[C]. IEEE International Conference on Prognostics and Health Management. Piscataway: IEEE, 2012: 1-8.

作者简介

梁浩鹏(1995—),男,博士生,从事故障诊断、深度学习等研究, E-mail: 928782706@qq.com;

曹洁(1966—),女,教授,博士生导师,从事智能交通、计算机控制技术和智能信息处理等研究, E-mail: haop1115@163.com;

赵小强(1969—),男,教授,博士生导师,从事故障诊断、图像处理、数据挖掘等研究, E-mail: xqzhao@lut.edu.cn.