

DOI:10.13364/j.issn.1672-6510.20230003

## 基于 EMD 和改进 TCN 的滚动轴承剩余寿命预测方法

胡 勇, 李孝忠

(天津科技大学人工智能学院, 天津 300457)

**摘要:** 鉴于当前在滚动轴承的剩余使用寿命预测领域中, 轴承振动数据难以提取有效特征、数据维度小而难以满足需求、预测模型趋于复杂化而造成计算成本高的问题, 本文提出了一种基于经验模态分解(empirical mode decomposition, EMD)的特征提取方法以及基于改进时间卷积网络(temporal convolutional network, TCN)的剩余寿命预测方法, 并在 PHM 2012 轴承数据集上进行了验证。实验结果显示:改进的时间卷积网络在均方误差(mean square error, MSE)指标上比其他时间卷积网络降低 46.43%, 在评分函数(Score)指标上比其他时间卷积网络提升 4.06%。此外, 本文改进的时间卷积网络在 MSE 上比其他 4 种模型方法降低 84.74%; 在 Score 指标上比其他 4 种模型方法提升了 163%, 充分验证了本文改进 TCN 模型的有效性。

**关键词:** 剩余使用寿命预测; 滚动轴承; 时间卷积网络; 经验模态分解

**中图分类号:** TP390 **文献标志码:** A **文章编号:** 1672-6510(2023)06-0062-07

## Prediction Method of Remaining Life of Rolling Bearing Based on EMD and Improved TCN

HU Yong, LI Xiaozhong

(College of Artificial Intelligence, Tianjin University of Science & Technology, Tianjin 300457, China)

**Abstract:** Considering that in the current field of predicting the remaining useful life of rolling bearings, it is difficult to extract effective features from bearing vibration data, the data dimension is small and difficult to meet the demand, and the prediction model tends to become complex, resulting in high computational costs. Therefore, in this article we propose a feature extraction method based on empirical mode decomposition(EMD) and a residual life prediction method based on improved temporal convolutional network(TCN), and also validate it on the PHM 2012 bearing dataset. The experimental results showed that the improved temporal convolution network reduced the mean squared error(MSE) index by 46.43% compared with other temporal convolution networks, and increased the score function index by 4.06% compared with other temporal convolution networks. Moreover, the improved temporal convolutional network in our study reduced the MSE by 84.74% compared to the other four model methods. Compared to its four model methods, the score index increased by 163%. The experimental result fully verifies the effectiveness of improving the TCN model in the article.

**Key words:** remaining useful life prediction; rolling bearing; temporal convolutional network; empirical mode decomposition

随着工业技术的发展, 现代机械设备正朝着大型化、综合化、复杂化的方向发展<sup>[1]</sup>。滚动轴承作为旋转机械中的重要零部件, 广泛应用于工业设备中。工业机械设备在长期运行的过程中可能受过载、冲击等的影响, 出现磨损、疲劳等一系列故障问题是不可避

免的, 更为严重的是这些故障会加速轴承的退化, 对机械设备的安全可靠运行产生严重影响<sup>[2]</sup>。因此, 如何有效地监测机器设备的运行状况和健康状态以及准确预测其重要零部件的剩余使用寿命(remaining useful life, RUL)是当前的研究热点<sup>[3]</sup>。

收稿日期: 2023-01-08; 修回日期: 2023-05-02

作者简介: 胡 勇(1995—), 男, 湖北人, 硕士研究生; 通信作者: 李孝忠, 教授, lixz@tust.edu.cn

Lei等<sup>[3]</sup>将RUL预测方法按照其基本技术和方法分为以下4类,即基于物理模型驱动的方法、基于统计模型驱动的方法、基于深度学习的人工智能方法和混合方法。首先,基于物理模型驱动的方法比较依赖于专家知识,只有在充分了解故障机理后才能建立反映机械系统或零部件的退化行为的数学模型。其次,基于统计学模型驱动的方法一般需要较为理想的假设条件,且在非线性转换到线性过程中存在信息丢失的风险<sup>[4]</sup>。基于深度学习的人工智能方法具有很强的特征映射能力,能有效地克服上述问题<sup>[3]</sup>。Wang等<sup>[5]</sup>采用深度可分离卷积网络(deep separable convolution network, DSCN)从轴承的原始振动信号中自动构造深度特征表示,用于轴承的RUL预测。陈保家等<sup>[6]</sup>采用堆栈降噪自编码对经过短时傅里叶变换(short-time Fourier transform, STFT)后原始特征集进行深度特征提取,然后将得到的深度特征输入基于注意力机制的时间卷积网络(temporal convolutional network, TCN)进行轴承的RUL预测。由于上述方法只对单一尺度的特征进行提取,还缺乏对不同时间尺度的局部特征进行提取,所以无法避免某些重要的信息被忽略。莫仁鹏等<sup>[2]</sup>使用注意力模块自适应地给原始多尺度特征集分配权重,然后通过卷积神经网络(convolutional neural network, CNN)模块进行深层特征提取与多尺度特征融合,最后通过前馈神经网络(feedforward neural network, FNN)模块映射得到RUL预测,但该方法不利于非平稳和非线性信号数据的处理。周哲韬等<sup>[7]</sup>采用三角函数变换与累积变换对输入特征进行修正,然后输入Transformer模型进行轴承的RUL预测,但是其结构复杂,并且需要对原始数据进行位置编码才能保持记忆能力,这就有可能对输入特征造成破坏,甚至影响模型对退化敏感特征的提取。张继冬等<sup>[8]</sup>将原始振动信号输入全卷积网络,得到原始的轴承寿命预测曲线,然后利用加权平均方法对预测结果进行降噪处理,得到最终的轴承RUL预测结果,但其难以利用时序数据的内在信息,缺乏数据特征间的关联性。

近年来,伴随着广大科研人员对长短期记忆网络(long short term memory, LSTM)、TCN<sup>[9]</sup>和注意力机制<sup>[10]</sup>模型的不断深入研究,验证了它们在时间序列预测领域的强大功能。这也为轴承的RUL预测提供了可靠的模型方法。LSTM虽然具有较好的记忆能力,但是其参数量大且通常难以进行并行处理。传统TCN的灵感来源于LSTM的记忆特点,具有像CNN

的特征抽取能力,能很好地从多个维度提取原始信号的潜在特征。因此,本文提出一种基于经验模态分解(empirical mode decomposition, EMD)分量统计特征和TCN改进模型的滚动轴承RUL预测方法。它不仅可以从原始信号中提取更多的可识别特征,而且能保证在不同时间尺度上的局部特征被高效利用。首先对轴承原始振动信号进行5层EMD,得到5个固有模态函数(intrinsic mode function, IMF)和1个残差分量;然后计算这6个分量的时域统计特征、三角函数特征以及能量和香农熵作为输入特征集;最后将这些特征作为TCN模型的输入进行寿命预测。在相同网络层数和神经元的情况下,TCN所需参数更少,模型收敛速度更快。

## 1 基本理论

### 1.1 经验模态分解

经验模态分解(EMD)是一种自适应数据处理方法<sup>[11]</sup>。它在处理非平稳和非线性数据方面具有明显的优势<sup>[12]</sup>。EMD的基本思想主要在于能够将复杂的原始信号分解为一组独立的、近周期的固有模态函数(IMF)。其中,IMF必须满足以下条件:IMF的零点和极值点的数目必须相等,或二者之差不超过1;分别由IMF局部极大值和极小值构成的上下包络线,二者在任意时刻的均值为0<sup>[13]</sup>。

对于给定的原始时间序列信号 $x(t)$ ,其EMD过程如下:

(1)找出 $x(t)$ 局部极大值和极小值点,利用三次样条插值法分别对极大值点和极小值点序列进行拟合,得到上包络线和下包络线。对上下包络线取平均值,得到 $m_1(t)$ 。

(2)计算原始时间序列数据 $x(t)$ 与平均包络线 $m_1(t)$ 之差 $p_1(t)$ ,即

$$p_1(t) = x(t) - m_1(t) \quad (1)$$

(3)若 $p_1(t)$ 满足IMF分量的条件,则为第1个IMF分量;否则,将 $p_1(t)$ 作为新的原始时间序列数据重复步骤(1)和步骤(2),直到满足IMF分量的条件为止。

(4)在得到第1个IMF分量 $p_1(t)$ 后,将其从原始时间序列 $x(t)$ 中分解出来,得到残差分量 $u_1(t)$ ,即

$$u_1(t) = x(t) - p_1(t) \quad (2)$$

(5)将残差分量 $u_1(t)$ 作为新的数据输入,重新执

行步骤(1)一步骤(5), 获得新的残差分量  $u_2(t)$  以及第 2 个 IMF 分量  $p_2(t)$ 。以此类推, 直到第  $k$  个 IMF 分量  $p_k(t)$  的残差分量  $u_k(t)$  为常数或者单调函数, 不能再分解, 整个 EMD 过程完成。此时, 原始时间序列  $x(t)$  可表示为

$$x(t) = \sum_1^n q_k(t) + u_k(t) \tag{3}$$

式中:  $u_k(t)$  可看作是  $x(t)$  的趋势或者均值;  $q_1(t)$ ,  $q_2(t)$ ,  $\dots$ ,  $q_k(t)$  为  $x(t)$  的 IMF 分量, 代表了原始时间序列数据的高频分量到低频分量。

### 1.2 时间卷积网络

时间卷积网络 (TCN) 是一种具有残差结构、能够处理时间序列的卷积神经网络<sup>[9]</sup>。TCN 与卷积神经网络 (CNN) 的主要区别在于扩展卷积与因果卷积。TCN 中的扩张卷积可以理解为, 对于一维序列输入  $x = \{s_1, s_2, \dots, s_{n-1}\} \in R^n$ , 假设卷积核  $f = \{0, 1, \dots, z-1\} \rightarrow R$ , 则时间序列元素  $s$  的扩展卷积运算  $F$  定义为

$$F(s) = (x * df)(s) = \sum_{i=0}^{z-1} f(i) \cdot x_{s-d \cdot i} \tag{4}$$

其中:  $d$  为膨胀因子,  $k$  为卷积核的大小,  $s-d \cdot i$  表示过去的方向。

TCN 网络由若干个残差块堆叠而成。TCN 基本结构如图 1 所示, 其基本的残差块包含两个相同的内部小单元和一个可选的残差连接, 其中每一个内部小单元从网络底层到顶层依次为扩张因果卷积层、归一化层、激活函数、Dropout 层。

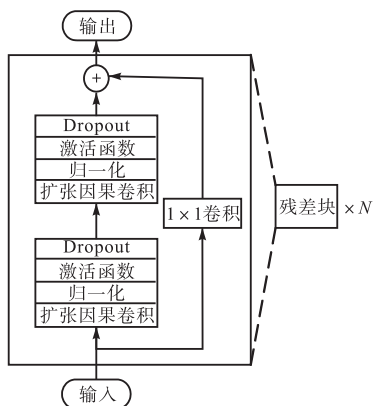


图 1 TCN 基本结构

Fig.1 TCN basic structure

对于归一化层默认选用批归一化 (batch normalization, BN) 或者采用原始的权重归一化 (weights normalization, WN), 但也可以采用层归一化 (layer normalization, LN)、组归一化 (group normalization,

GN) 等。激活函数一般默认采用非线性激活函数, 如修正线性单元 (ReLU)、指数线性单元 (ELU)、带泄露的修正线性单元 (Leaky ReLU) 等。本文对原本的 TCN 残差块进行微小改进, 归一化层采用 GN, 激活函数采用 ELU。

## 2 本文方法

### 2.1 分量统计特征提取

滚动轴承常用的状态监测数据包含振动信号、温度以及声波信号, 其中振动信号因包含了轴承大量有用的特征信息而被广泛研究。本文也采用振动信号进行轴承的 RUL 预测。首先, 采用 EMD 对原始振动信号进行 5 层分解, 得到 5 个 IMF 分量和 1 个残差分量; 然后对这 6 个时间序列的时域统计特征、三角函数特征以及能量和香农熵进行计算, 得到 66 维数据作为轴承 RUL 预测的原始特征集。

### 2.2 滚动轴承 RUL 预测流程

基于 EMD 和 TCN 模型的滚动轴承 RUL 流程如图 2 所示。

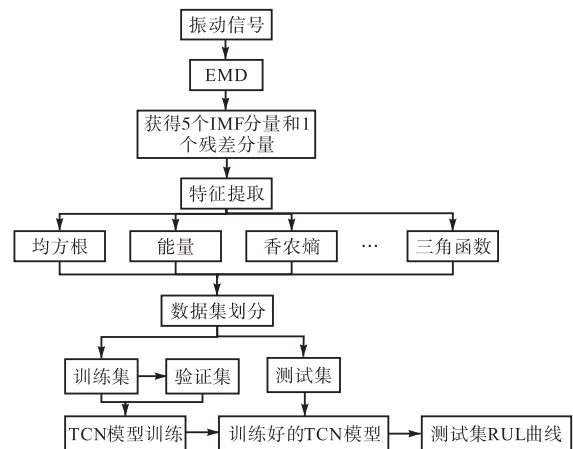


图 2 基于 EMD 和 TCN 模型的滚动轴承 RUL 流程

Fig.2 RUL process of rolling bearing based on EMD and TCN model

滚动轴承 RUL 预测流程的具体步骤为:

(1) EMD: 首先采用 EMD 对原始振动信号进行 5 层分解, 得到 5 个 IMF 分量和 1 个残差分量。

(2) 特征提取: 根据信号处理中常见的无量纲统计特征计算公式, 计算 6 个分量的 11 个统计特征, 得到 66 维原始特征集。

(3) TCN 模型构建: 将训练集的特征进行最大和最小归一化作为 TCN 模型的输入, 将训练集归一化寿命值  $P$  (当前时间周期对应的真实剩余寿命值与全寿命周期对应的全寿命值之间的比值) 作为训练集标

签,以均方误差(mean square error, MSE)作为模型的损失函数,用 Adam 优化算法进行模型训练,同时从训练集样本中随机划分 15% 数据作为验证集,以增加 TCN 模型的泛化能力。

(4) 测试集验证: 将测试集的 66 维特征输入已经训练好的 TCN 模型中,预测测试集特征对应的归一化寿命值  $P$ 。

### 3 实验

#### 3.1 数据集

为了验证本文方法的有效性,采用 PHM 2012 数据挑战赛中提供的 FEMTO-ST 滚动轴承全寿命数据集进行模型验证。PHM 2012 数据集工况信息见表 1。

表 1 PHM 2012 数据集工况信息

Tab. 1 Operating condition of PHM 2012 dataset

数据集	工况	载荷/N	转速/(r·min <sup>-1</sup> )	轴承编号	全寿命/s
训练集	工况 1	4 000	1 800	Bearing1-1	28 030
				Bearing1-2	8 710
				Bearing1-3	23 750
				Bearing1-4	14 280
测试集	工况 1	4 000	1 800	Bearing1-5	24 630
				Bearing1-6	24 480
				Bearing1-7	22 590

该数据集由 PRONOSTIA 实验平台采集获得(图 3),它通过加速度传感器和力矩传感器实现了 3 种不同工况下的滚动轴承加速退化实验<sup>[14]</sup>。利用加速度传感器采集水平方向和垂直方向轴承全寿命周期的振动数据,每 10 s 采集 1 次,采样时长 0.1 s,采样频率为 25.6 kHz,即水平方向和垂直方向每次采集的数据长度为 2 560 个点。工况 1 数据集属于轻载,采集的轴承退化数据较好,被广泛用于 RUL 预测的实验验证。因此,本文采用工况 1 数据作为本文的实验数据集。




图 3 PRONOSTIA 采集平台  
Fig. 3 PRONOSTIA platform

训练集轴承振动数据 EMD 如图 4 所示。本文采用工况 1 数据集的水平振动信号作为 EMD 的原始输入数据,图 4(a)和图 4(b)分别为训练集轴承 Bearing1-1 和 Bearing1-2 的第 1 个时间点采集的数据(Signal)经过 5 层 EMD 后得到的 5 个 IMF 分量和 1 个残差分量(res.)。

#### 3.2 评价指标

为了对模型预测的 RUL 结果进行评估,采用 RUL 预测中常用的评价指标,分别是均方误差(MSE,用符号  $E_{MS}$  表示)和 PHM 2012 评分函数<sup>[5-7, 12]</sup>。MSE 是误差指标越小越好,评分函数是效益型指标越大越好。

$$E_{MS} = \frac{1}{n} \sum_{i=1}^n (P_{ActRUL}^i - P_{PreRUL}^i)^2 \quad (5)$$

式中:  $P_{ActRUL}^i$  为轴承实际的归一化 RUL 值,  $P_{PreRUL}^i$  为轴承预测的归一化 RUL 值。

评分函数(Score,用符号  $S$  表示)定义为

$$E_r^i = \frac{P_{ActRUL}^i - P_{preRUL}^i}{P_{ActRUL}^i} \times 100 \quad (6)$$

$$C^i = \begin{cases} \exp(-\ln(0.5) \cdot (E_r^i / 5)) & \text{if } E_r^i \leq 0 \\ \exp(+\ln(0.5) \cdot (E_r^i / 20)) & \text{if } E_r^i > 0 \end{cases} \quad (7)$$

$$S = \frac{1}{n} \sum_{i=1}^n C^i \quad (8)$$

式中  $E_r^i$  为 RUL 预测结果的绝对误差放大 100 倍后的值,用于后续评分函数的计算。由于本文是全寿命预测全寿命,因此会有真实寿命为 0 的点,而分母不能为 0,故在计算 Score 指标时,会舍弃真实寿命为 0 的点。

#### 3.3 模型改进验证

本文对传统的 TCN 模型进行了内部结构参数的探究,主要是对归一化层的选用进行了研究对比。本文 TCN 模型第 1 层到最后一层 TCN 残差块的卷积神经元的数目为依次为 64、32、8、1;扩张率依次为 1、2、4、8;卷积核大小均为 3,并采用 ELU 激活函数,批大小为 32。由于 TCN 模型属于时间序列类型的模型,因此需要确定输入数据的时间序列长度,即时间步长的确定。过短的时间步长会导致 TCN 难以学到足够的时间依赖信息,过长的时间步长则极大地增加计算量,降低运算效率。因此,本文时间步长设置为 16,每一个时间步长输入特征数据对应一个归一化寿命值  $P$  作为标签数据。本文改进 TCN 模型和传统 TCN 模型及其他归一化形式的模型对比见表 2,其中 GN8、GN4、GN2 依次表示 GN 分组参数为

8、4、2。

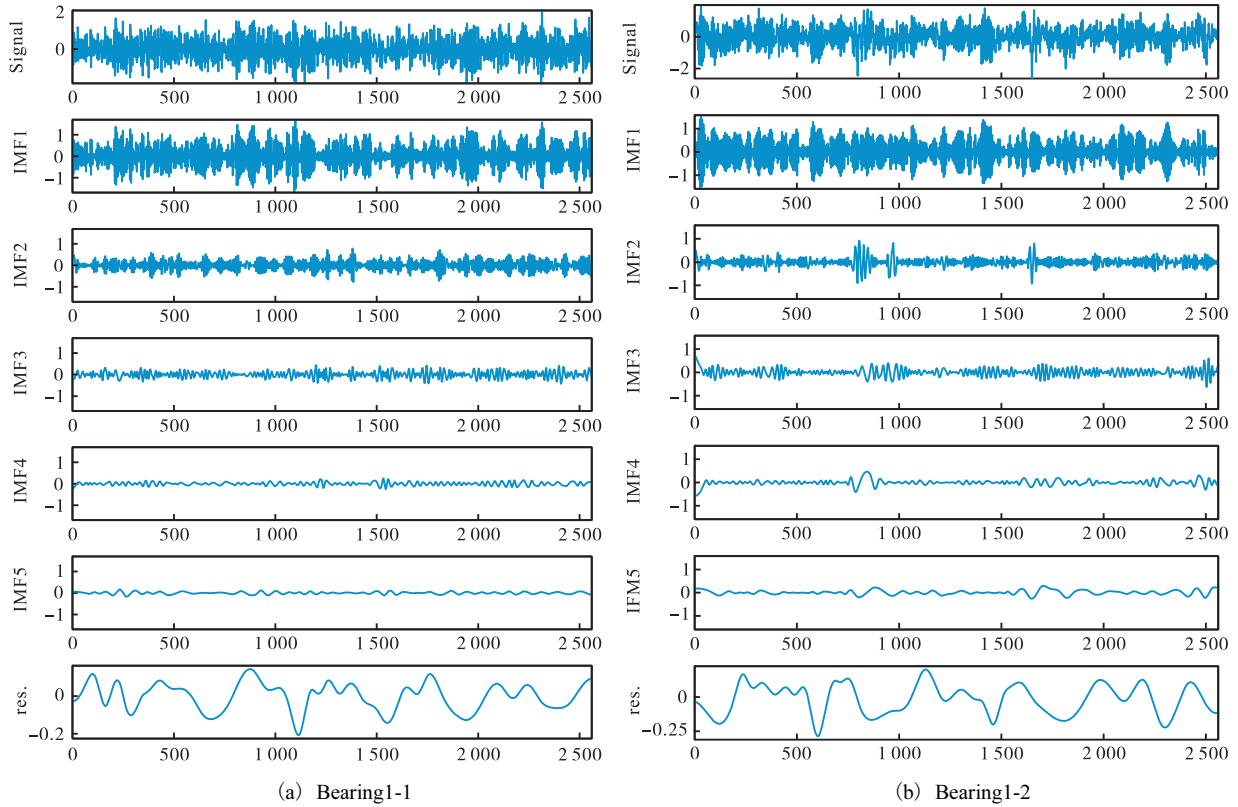


图 4 训练集轴承振动数据 EMD

Fig. 4 EMD of training set bearing vibration data

表 2 TCN 模型不同归一化层的对比

Tab.2 Comparison of different normalization layers of TCN model

方案	模型
1(常用模型)	TCN(BN)
2(原始模型)	TCN(WN)
3	TCN(LN)
4	TCN(GN8)
5	TCN(GN4)
6	TCN(GN2)

为了减小偶然误差,上述模型分别运行 3 次后取评价指标的均值,最终的评价指标对比见表 3。

所有方案在 Bearing1\_3 和 Bearing1\_4 上的预测效果相当;方案 5 和方案 4 在 Bearing1-7 上的预测效果最佳;而方案 6 的 TCN(GN2)模型在 Bearing1-5, Bearing1-6 上的提升效果最为明显,在衡量预测误差的指标 MSE 上,比方案 1(常用模型)平均降低了 70.03%;比方案 2(原始模型)平均降低了 78.54%;比方案 3 平均降低了 75.40%;比方案 5 平均降低了 75.37%;比方案 4 平均降低了 83.01%。

表 3 测试集轴承 RUL 预测结果对比

Tab.3 Comparison of test set bearing RUL prediction results

模型	Bearing1-3		Bearing1-4		Bearing1-5		Bearing1-6		Bearing1-7		测试集整体	
	MSE	Score	MSE	Score	MSE	Score	MSE	Score	MSE	Score	MSE	Score
TCN(BN)	0.004	0.986	0.009	<b>0.988</b>	0.039	0.899	0.037	0.882	0.055	0.938	0.030	0.934
TCN(WN)	0.003	0.987	0.015	0.978	0.053	0.873	0.055	0.866	0.067	0.915	0.041	0.918
TCN(LN)	0.002	0.018	0.021	0.976	0.042	0.885	0.063	0.860	0.070	0.920	0.041	0.921
TCN(GN8)	0.019	<b>0.991</b>	0.024	0.960	0.073	0.850	0.058	0.866	<b>0.022</b>	0.915	0.041	0.912
TCN(GN4)	0.004	0.989	0.014	0.985	0.047	0.890	0.046	0.873	0.030	0.929	0.029	0.928
TCN(GN2)	<b>0.001</b>	0.984	<b>0.011</b>	0.983	<b>0.016</b>	<b>0.944</b>	<b>0.007</b>	<b>0.955</b>	0.057	<b>0.945</b>	<b>0.019</b>	<b>0.960</b>

注:表中加粗数字表示该列评价指标中的最优值。

方案 6 的 TCN(GN2)模型的在测试集轴承 RUL 预测的整体评估效果上表现最佳。在 MSE 指标上,

方案 6 比方案 1(常用模型)降低 36.67%,比方案 2(原始模型)降低了 53.66%,比方案 3 降低了

53.66%, 比方案 5 降低了 34.48%, 比方案 4 降低了 53.66%, 比这 5 个方案平均降低了 46.43%。在 Score 指标上, 方案 6 分别比方案 1(常用模型)、方案 2(原始模型)、方案 3、方案 5 和方案 4 提升了 2.78%、

4.58%、4.23%、3.45% 和 5.26%, 平均提升了 4.06%。图 5 为本文 4 种归一化层和 6 种方案在测试集 Bearing1-3 到 Bearing1-7 的 RUL 预测可视化结果。

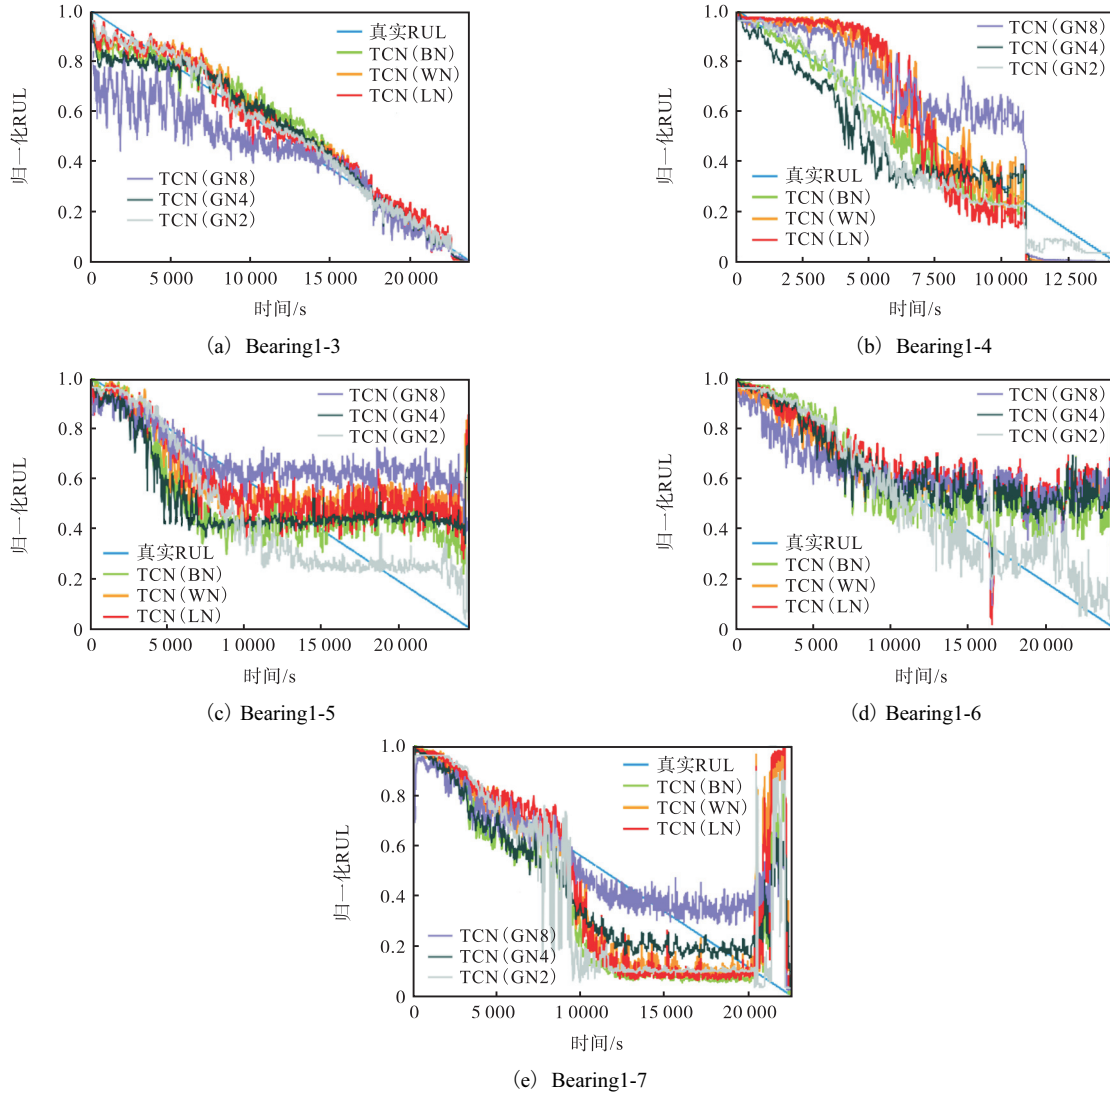


图 5 不同模型方案在测试集上的 RUL 预测可视化结果

Fig. 5 Visualization results of RUL predictions of different model schemes on the test set

### 3.4 与其他模型的对比

为了进一步验证本文方法的有效性, 本文与其他

深度学习模型算法: CNN、LSTM 以及文献[12]方法中的 TCN 和 EMD-TCN 进行了对比, 结果见表 4。

表 4 本文改进 TCN 与其他模型方法的对比

Tab. 4 Comparison between improved TCN in this article and other model methods

模型	Bearing1-3		Bearing1-4		Bearing1-5		Bearing1-6		Bearing1-7		测试集整体	
	MSE	Score	MSE	Score	MSE	Score	MSE	Score	MSE	Score	MSE	Score
CNN	0.12	0.40	0.24	0.23	0.16	0.34	0.13	0.35	0.17	0.32	0.15	0.34
LSTM	0.16	0.35	0.15	0.30	0.20	0.30	0.22	0.22	0.23	0.21	0.19	0.27
TCN	0.03	0.61	0.15	0.36	0.10	0.44	0.10	0.44	0.12	0.46	0.11	0.44
EMD-TCN	0.06	0.60	0.08	0.57	0.10	0.50	0.10	0.44	0.11	0.46	0.09	0.49
TCN(GN2)	<b>0.001</b>	<b>0.984</b>	<b>0.011</b>	<b>0.983</b>	<b>0.016</b>	<b>0.944</b>	<b>0.007</b>	<b>0.955</b>	<b>0.057</b>	<b>0.945</b>	<b>0.019</b>	<b>0.960</b>

注: 表中加粗数字表示该列评价指标中的最优值。

从表 4 中可以看出,本文的 TCN(GN2)模型在 Bearing1-3 到 Bearing1-7 这 5 个测试集轴承上的误差指标 MSE 和效益指标 Score 上均为最佳,5 个测试集轴承 RUL 预测的整体评估效果也是最佳。

在测试集整体的 MSE 指标上,本文改进 TCN 模型比 CNN 模型降低了 87.33%,比 LSTM 模型降低了 90%,比文献[12]的 TCN 模型降低了 82.73%,比文献[12]的 EMD-TCN 模型降低了 78.89%,比这 4 种方法平均降低了 84.74%。

在测试集整体的 Score 指标上,本文改进 TCN 模型比 CNN 模型的提升了 182.35%,比 LSTM 模型提升了 255.56%,比文献[12]的 TCN 模型提升 118.18%,比文献[12]的 EMD-TCN 模型提升了 95.92%,比这 4 种方法平均提升了 163%。

## 4 结 论

本文提出了一种改进的 TCN 模型方法,并对 TCN 残差块的内部结构进行了探究。经过实验验证,本文方法对经验模态分解的每个 IMF 分量和残差分量都进行了特征提取,扩充了模型输入的数据维度,使深度学习模型能够更好地训练学习特征信息。通过与 CNN、LSTM 以及相关文献方法进行对比分析,证明了本文提出的分组数为 2 的组归一化改进 TCN 模型在众多模型中表现最佳。此外,本文模型具有轻量、易训练以及参数量少等优势,在 PHM 2012 工况 1 数据集上证明了 TCN(GN2)的有效性和优越性。

本文提出的采用组归一化改进的 TCN 模型能够很好地捕捉轴承的退化特征信息,有效预测轴承的 RUL。在后续的研究中,可以将回归拟合预测扩展到具有实际工程意义的截断寿命预测。

### 参考文献:

- [1] CHEN J, CHEN D, LIU G. Using temporal convolution network for remaining useful lifetime prediction[J]. *Engineering reports*, 2021, 3(3): e12305.
- [2] 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.
- [3] 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.
- [4] 李京峰, 陈云翔, 项华春, 等. 基于 LSTM-DBN 的航空发动机剩余寿命预测[J]. *系统工程与电子技术*, 2020, 42(7): 1637-1644.
- [5] WANG B, LEI Y, LI N, et al. Deep separable convolutional network for remaining useful life prediction of machinery[J]. *Mechanical systems and signal processing*, 2019, 134: 106330.
- [6] 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.
- [7] 周哲韬, 刘路, 宋晓, 等. 基于 Transformer 模型的滚动轴承剩余使用寿命预测方法[J]. *北京航空航天大学学报*, 2023, 49(2): 430-443.
- [8] 张继冬, 邹益胜, 邓佳林, 等. 基于全卷积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.
- [9] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. [2022-12-20]. <https://doi.org/10.48550/arXiv.1803.01271>.
- [10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[EB/OL]. [2022-12-20]. [http://www.aiotlab.org/teaching/dl\\_app/slides/6\\_3\\_attention\\_n\\_bert.pdf](http://www.aiotlab.org/teaching/dl_app/slides/6_3_attention_n_bert.pdf).
- [11] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proceedings mathematical physical & engineering sciences*, 1998, 454(1971): 903-995.
- [12] YANG W, YAO Q, YE K, et al. Empirical mode decomposition and temporal convolutional networks for remaining useful life estimation[J]. *International journal of parallel programming*, 2020, 48(1): 61-79.
- [13] 庞红旗, 高飞翔, 程国开, 等. 基于经验模态分解和极限学习机的日输电量分时建模预测[J]. *智慧电力*, 2021, 49(9): 63-69.
- [14] NECTOUX P, GOURIVEAU R, MEDJAHER K, et al. PRONOSTIA: an experimental platform for bearings accelerated degradation tests[C]//IEEE. *IEEE International Conference on Prognostics and Health Management, PHM'12*. New York: IEEE, 2012: hal-00719503.

责任编辑: 郎婧