

DOI:10.19651/j.cnki.emt.2416954

基于并行 TCN-SE-BiLSTM 模型的 涡扇发动机剩余寿命预测 *

张鑫阳¹ 王可庆^{1,2} 贾新旺³ 郭永信² 蒋 亮²

(1. 南京信息工程大学自动化学院 南京 210044; 2. 无锡学院自动化学院 无锡 214105;

3. 中国船舶集团有限公司第七〇三研究所无锡分部 无锡 214105)

摘 要: 作为现代航空的重要组成部分,维护和预测涡扇发动机的使用寿命对于确保安全和降低运营成本至关重要。为了应对涡扇发动机 RUL 预测中的复杂非线性特征处理难题,本研究提出了一种基于并行 TCN 与 BiLSTM 的新型混合模型。针对传统方法难以同时捕捉局部特征和长时间依赖性的问题,该模型通过 TCN 提取短期局部特征,并利用 BiLSTM 捕捉数据中的双向时序依赖。同时,针对特征重要性识别不足的挑战,引入了改进的 SE 注意力机制模块,以动态调整网络的特征权重,增强对关键信息的关注。在 C-MAPSS 数据集的 FD001 和 FD003 子集上的实验验证中, RMSE 和 Score 分别为 12.15、230.4 和 11.16、209.84。结果表明,该方法与其他方法相比具有更高的精度。

关键词: 涡扇发动机; 时序卷积网络; 双向长短时记忆网络; 注意力机制

中图分类号: TP391.5; TN807 **文献标识码:** A **国家标准学科分类代码:** 520.2

Prediction of remaining useful life for turbofan engines based on parallel TCN-SE-BiLSTM model

Zhang Xinyang¹ Wang Keqing^{1,2} Jia Xinwang³ Guo Yongxin² Jiang Liang²

(1. School of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, China;

2. School of Automation, Wuxi University, Wuxi 214105, China;

3. Wuxi Branch, No. 703 Research Institute of China State Shipbuilding Corporation, Wuxi 214105, China)

Abstract: The maintenance and prediction of turbofan engine lifespan are critical to modern aviation, playing a key role in ensuring safety and minimizing operational costs. This study addresses the challenge of predicting the RUL of turbofan engines by proposing a novel hybrid model that integrates Parallel TCN and Bidirectional BiLSTM. Traditional methods often struggle to capture both local features and long-term dependencies simultaneously; the proposed model overcomes this limitation by using TCN to extract short-term local features and BiLSTM to capture bidirectional temporal dependencies. To further improve feature importance recognition, an enhanced SE attention mechanism is introduced, which dynamically adjusts feature weights to better highlight critical information. Experiments conducted on the FD001 and FD003 subsets of the C-MAPSS dataset demonstrated that the proposed model achieved RMSE values of 12.15 and 11.16, and Scores of 230.4 and 209.84, respectively, outperforming other approaches in terms of accuracy.

Keywords: turbofan engine; temporal convolutional network; bidirectional long short-term memory network; attention mechanism

0 引 言

预测性健康管理(prognostics and health management, PHM)技术通过预测和监控设备状态,可有效预防设备故

障并减少停机维护时间。该技术为维护决策提供了坚实的基础,提高了设备安全性,降低了维护成本^[1]。剩余使用寿命(remaining useful life, RUL)的预测是 PHM 技术中一个重要的组成部分,它指的是设备从当前状态到达性能衰

收稿日期:2024-09-22

* 基金项目:江苏省高等学校自然科学基金(22KJB460039)项目资助

退临界点的预计剩余运行时间。涡扇发动机作为航空领域的核心设备,其可靠性直接关系到飞行安全和经济效益。因此,精确预测涡扇发动机的 RUL 对于航空公司来说至关重要。一般来说,RUL 预测的主要研究方法可分为两类:基于物理模型的方法和数据驱动的方法^[2]。

基于物理模型的方法依赖于对设备具体运作机制的深入了解,通过建立物理和数学模型来模拟设备的磨损和老化过程^[3]。这种方法的优点是能够在理论上提供非常精确的预测,但其局限性在于需要精确的物理参数和复杂的模型校准,这在实际操作中往往难以获取或执行。随着数据处理技术的快速发展,尤其是机器学习技术的进步,数据驱动方法已成为研究的热点^[4]。基于数据驱动的方法通过对设备安装传感器采集大量运行数据,然后利用机器学习、深度学习等方法分析历史运行数据来识别故障模式和预测 RUL,这种方法灵活且易于实施。例如,Wang 等^[5]应用随机森林方法筛选出涡扇发动机的关键退化指标,随后利用多层感知机进行 RUL 的预测,并采用贝叶斯优化技术对预测模型进行参数调优。然而,由于传感器捕捉到的退化数据在时域上通常表现为复杂的非线性特征,传统的机器学习方法往往难以处理高维数据,导致模型性能下降^[6]。

深度学习方法通过分层结构自动提取多层次特征,可有效处理非线性数据并捕捉复杂的模式和关系。这一过程大大提高了模型的准确性和鲁棒性。聂磊等^[7]通过筛选轴承的退化特征,并运用主成分分析法构建健康指标,最终将其输入至一维卷积神经网络(convolutional neural networks,CNN),以实现轴剩寿命的预测。然而,单独的 CNN 模型通常不足以处理时间序列中的长期依赖性问题。长短期记忆网络(long short-term memory,LSTM)被用于弥补这一缺陷,它通过其独特的门控结构有效地管理信息的长期流动,能够捕捉并保持时间序列数据中的关键信息。李路云等^[8]通过使用一维卷积神经网络来构建涡扇发动机的退化特征,然后将这些特征输入到 LSTM 中进行 RUL 的预测。虽然 LSTM 能够捕捉长期依赖关系,但其在处理长序列数据时易出现梯度消失、对高维多传感器数据的特征提取能力有限、训练效率较低且对数据顺序依赖较强。

同时,涡扇发动机 RUL 预测中,单一网络模型往往难以充分处理多维复杂数据中的时间依赖性问题。时域卷积网络(temporal convolutional network,TCN)因其在处理长期时间依赖性上的优势,成为近年来的一种替代方案。Ji 等^[9]采用 TCN 进行涡扇发动机 RUL 预测,结果要优于 CNN 和 LSTM。对于涡扇发动机这类复杂数据,然而,单一模型往往难以充分捕捉到复杂多维数据中的关键特征,限制了 RUL 预测的准确性。近年来,注意力机制被广泛应用于时间序列预测中,它能够动态加权数据中的关键部分,提升预测的准确性和效率。Li 等^[10]将自注意力机制融入到了 CNN-LSTM 网络中,实现了权值的重新分配,解决了

LSTM 中的信息丢失问题。

尽管深度学习在涡扇发动机 RUL 预测中的应用取得了显著进展,但仍面临一些挑战。涡扇发动机的工作环境复杂严苛,其运行过程中生成的传感器数据具有高维度、非线性和多样性,涵盖多个传感器同时监测的多种参数。这种复杂性给数据处理和特征提取带来了很大的困难。单一网络模型通常难以充分提取多传感器数据中的关键特征,导致 RUL 预测的准确性不足。因此,针对涡扇发动机复杂数据的有效特征提取和精确预测,仍然需要进一步的研究与优化。

针对以上问题,本研究提出了一种基于并行 TCN-BiLSTM 的网络结构,通过结合 TCN 和 BiLSTM 两种优势,TCN 能够有效捕捉时间序列中的长期依赖关系,而 BiLSTM 则通过双向结构同时获取序列中的过去和未来信息,从而提高了对时间序列的全局理解能力。此外,改进的 SE 注意力机制通过结合全局平均池化(global average pooling,GAP)和全局最大池化(global max pooling,GMP),有效增强了对重要特征的关注,克服了传统 SE 模块仅依赖平均池化可能导致关键特征丢失的问题。相比于现有的深度学习方法,所提出的模型在捕捉复杂多维数据中的关键特征和处理长时间序列依赖关系方面具有显著优势,从而提升了 RUL 预测的精度和鲁棒性。

1 理论基础

1.1 TCN

Zheng 等^[11]于 2018 年开发了 TCN,该技术已被广泛应用于处理各种序列数据和预测任务。TCN 网络由一系列残差模块组成,而残差模块的核心部分是因果卷积和膨胀卷积。

在因果卷积中,输出在时间点 t 只依赖于该时间点及其之前的输入数据,而不会用到该时间点之后的数据。这确保在进行预测时不会发生信息泄露,即模型不会错误地使用未来的信息。因果卷积可以通过对输入数据进行适当的“填充”来实现。然而,通过简单地增加网络层数或扩大卷积核的尺寸来拓宽信息的感受野,会导致网络的计算成本显著提高。为了解决这个问题,引入了在卷积核中插入空白值的策略,这种方法被称为扩张卷积。扩张卷积能够有效地扩大网络层的感受野,使得更高层的节点能够覆盖更广泛的输入信息,从而加入更多的历史数据而无需额外的计算负担。对于时序数据 $x \in R^n$ 和一个卷积核 $f: \{0, 1, \dots, k-1\} \rightarrow R$,其膨胀卷积计算公式如式(1)所示。

$$F(s) = (x \times_d f)(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \quad (1)$$

式中: d 为膨胀因子大小, k 为卷积核大小, $s-d \cdot i$ 表示时间序列过去的方向。

残差块由扩张因果卷积、权重归一化、Relu 激活函数,以及 Dropout 组成。TCN 网络就是由许多残差块堆叠而成,图 1 展示了 n 个残差模块堆叠而成的 TCN 网络,其中

每个残差块中的卷积核大小为 k , 第 n 个残差块中的膨胀因子大小为 2^{n-1} 。




图 1 TCN 结构图

Fig. 1 TCN architecture diagram

1.2 BiLSTM

LSTM 是一种改进的 RNN, 用来解决传统 RNN 在处理长序列数据时遇到的梯度消失或梯度爆炸的问题^[12]。LSTM 通过引入称为“门”(gates)的结构来调控信息的流动, 这些门包括输入门、遗忘门和输出门。图 2 所示为 LSTM 的原理图。 $f(t)$ 、 $i(t)$ 、 $\alpha(t)$ 和 $o(t)$ 分别表示 t 时刻的遗忘门、输入门和输出门的值。计算公式如式(2)~(7)所示。

$$f(t) = \sigma(W_f h_{t-1} + U_f x_t + b_f) \quad (2)$$

$$i(t) = \sigma(W_i h_{t-1} + U_i x_t + b_i) \quad (3)$$

$$\alpha(t) = \tanh(W_a h_{t-1} + U_a x_t + b_a) \quad (4)$$

$$o(t) = \sigma(W_o h_{t-1} + U_o x_t + b_o) \quad (5)$$

$$c(t) = c(t-1) \otimes f(t) + i(t) \otimes \alpha(t) \quad (6)$$

$$h(t) = o(t) \otimes \tanh(c(t)) \quad (7)$$

式中: W_f 、 W_i 、 W_o 和 W_a 分别代表 x_t 在遗忘门、输入门、输出门和特征提取过程中 $t-1$ 时刻隐藏状态值的权重系数。 U_f 、 U_i 、 U_o 、 U_a 分别代表 x_t 在遗忘门、输入门、输出门、特征提取过程中的权重系数, b_f 、 b_i 、 b_o 、 b_a 分别代表 x_t 在遗忘门、输入门、输出门、特征提取过程中的偏置值。 $c(t)$ 代表 t 时刻的细胞状态, $h(t)$ 代表 t 时刻的隐藏状态。 $\tanh$ 代表正切双曲函数, σ 代表 sigmoid 激活函数。

BiLSTM 是通过结合两个独立的 LSTM 网络, 如图 3 所示, 一个处理正向序列, 另一个处理反向序列, 从而能够同时获取过去和未来的上下文信息。

1.3 改进 SE 注意力模块

在深度学习中, 注意力机制通过为输入数据的不同部




图 2 LSTM 原理图

Fig. 2 LSTM schematic diagram




图 3 BiLSTM 原理图

Fig. 3 BiLSTM schematic diagram

分分配不同的权重, 实现了对重要特征的动态关注^[13]。SE 模块首先通过 GAP 将特征图的空间维度信息压缩为一个长度为通道数的向量(squeeze), 然后通过两个全连接层和一个激活函数计算出每个通道的重要性权重(excitation)。这些权重被用于对原始特征图的各通道进行加权(reweight), 从而强化关键特征的表现, 抑制不相关或无用的特征。对于一个输入特征图 X (形状为 $H \times W \times C$, 其中 H 为高度, W 为宽度, C 为通道数), 具体计算过程如下:

1) squeeze 操作。沿着空间维度对特征图进行压缩, 压缩成形状为 $1 \times 1 \times C$ 的特征向量, 计算公式如下:

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{i,j,c} \quad (8)$$

式中: z_c 是通道 c 的全局平均池化输出, $X_{i,j,c}$ 表示特征图在位置 (i, j) 处的第 c 个通道的值。

2) excitation 操作。通过自适应地重新校准每个通道的重要性来增强特征, 通过引入降维比例 r , 先将通道数下降为 c/r , 在升维到 c , 生成每个通道的权重值。计算公式如下:

$$s = \sigma(W_2 \delta(W_1 z_c)) \quad (9)$$

式中: z_c 是 GAP 后的结果, σ 是 sigmoid 激活函数, s 是通过 excitation 后得到的通道权重, W_1 、 W_2 均为权重矩阵。

3) reweight 操作。将 excitation 得到的结果与原始特征图相乘, 得到加权后的特征图, 计算公式如下:

$$\tilde{X} = F_{scale}(s, X) = s \cdot X \quad (10)$$

式中: $\tilde{X}$ 表示经过 reweight 后得到的特征图, X 是原始特征图。

本研究对 SE 注意力模块进行了改进,如图 4 所示,在原来 GAP 的基础上,增加了 GMP。结合 GAP 和 GMP 两

种方式能够更全面地保留特征图中的有效信息。GAP 通过计算平均值捕捉特征图的整体情况,而 GMP 则通过提取最大值突出特征图中的显著特征。将两个池化的结果分别经过激励操作,最后经过融合,将得到的结果与原始特征图相乘,得到加权后的特征图。




图 4 改进的 SE 注意力模块

Fig. 4 Improved SE attention module

1.4 TCN-SE-BiLSTM 预测模型

所提出的 TCN-SE-BiLSTM 模型结构如图 5 所示。首先,使用滑动窗口对原始传感器数据进行分段处理,生成适合输入模型的时间序列片段。接下来,模型分为两条并行路径进行特征提取。第 1 条路径通过 TCN 网络提取

时间序列中的长期依赖特征,TCN 采用因果卷积结构,确保模型在不引入未来信息的前提下高效捕捉序列的长时依赖性。随后,经过改进的 SE 注意力模块,该模块通过结合 GAP 和 GMP,自适应地调整各通道的权重,从而增强了对重要特征的关注。




图 5 TCN-SE-BiLSTM 模型

Fig. 5 TCN-SE-BiLSTM model

第 2 条路径通过 BiLSTM 网络对时间序列数据进行双向依赖的捕捉,BiLSTM 通过其双向结构,能够同时处理序列中的前向和后向信息,确保对序列全局动态变化的有效建模。两条路径的特征在输出后通过 concat 操作进行融合,融合后的特征被传递到全连接层,通过进一步的非线性变换和特征压缩,最终输出对涡扇发动机 RUL 的预测值。

2 实验设计

实验中,使用 Pycharm 进行模型的训练和测试操作,实验环境为 Pytorch 2.0.1。所有程序都在具有以下配置的计算机上运行:Windows 11、AMD Ryzen 7 6800H、NVIDIA RTX 3060、16GB RAM。

2.1 数据集来源

本研究采用广泛认可的商业模块化航空推进系统仿真 (commercial modular aero-propulsion system simulation,

C-MAPSS) 数据集对新提出的 RUL 预测模型进行评估。该数据集由 4 个子数据集组成,即 FD001、FD002、FD003 和 FD004 数据集,具体如文献[14]。本研究选取 FD001 和 FD003 数据集用于实验验证,两个子数据集的信息如表 1 所示,其中训练集包括了航空发动机从正常状态到故障状态的完整循环,记录了多个状态参数在整个过程中的时间序列数据。测试集则包含了故障发生前的状态参数的数据记录,以及对应的剩余寿命值。在 C-MAPSS 数据集中,并非所有传感器的数据都对寿命预测有意义。因此,剔除编号为 1、5、6、10、16、18、19 的传感器数据,将剩余的 14 个传感器数据和 3 种操作条件作为实验的输入特征。

2.2 数据预处理

1) 数据归一化

为了使不同通道的数据具有可比性,必须对所有数据进行归一化。本研究采用最大-最小归一化,将每个通道的传感器数据缩放到范围[0,1],归一化公式如式(11)所示。

表 1 数据集介绍

Table 1 Description of the dataset

数据集	FD001	FD003
训练集发动机个数	100	100
测试集发动机个数	100	100
训练样本	20 631	24 720
测试样本	13 096	16 596
故障模式	1	2
工况模式	1	1
最小循环周期	31	38

$$\tilde{x}_{st} = \frac{x_t^s - \min\{x_s\}}{\max\{x_s\} - \min\{x_s\} + eps} \quad (11)$$

式中: $\tilde{x}_t^s$ 表示第 s 个传感器在第 t 个时间步标准化的数据, $\max\{x_s\}$ 和 $\min\{x_s\}$ 分别表示第 s 个传感器中的最大值和最小值。 $eps = 10^{-12}$, 主要目的是为了防止分母为零的情况, 避免出现计算错误。

2) 滑动窗口处理

数据的滑动窗口示例如图 6 所示。对于发动机从运行到失效整个周期, 假设发动机的总运行周期数为 T , 窗口大小为 W , 滑动步长为 S 。每个样本的大小为 $W \times N$, 其中 N 为特征数量。对于第 $i+1$ 个样本, 其对应的 RUL 计算公式如下:

$$RUL = T - W - i \times S \quad (12)$$

在设置滑动窗口参数时需要注意的是, 窗口大小不能大于训练集和测试集中的最小循环次数, 否则可能导致数据缺失, 两个数据集的测试集最小循环周期如表 1 所示。本研究选取的步长大小 $S = 1$, 窗口大小 $W = 30$, 这样可以保证每个样本覆盖足够的时间跨度, 同时最大化样本数量, 避免数据冗余。此外, 这些参数选择也是通过多次实验确定的, 步长较小时可以更精细地捕捉到时间序列中的细微变化, 而窗口大小确保了模型可以学习到时间序列的长期依赖关系。




图 6 滑动窗口示例

Fig. 6 Sliding window example

3) RUL 标签处理

为了有效预测涡扇发动机的 RUL, 本研究对标签进行

了分段线性处理。发动机在运行初期通常没有明显的退化迹象, 因此当 RUL 大于某个阈值时, 将 RUL 值设定为常数。与先前的研究相同^[15-17], 本研究中的 RUL 断点设定为 125, 即如果当前循环的 RUL 大于 125 时, 默认 RUL 值为 125。这种标签处理方法可以减少极端值对模型训练的干扰, 同时避免过拟合到健康阶段的数据。

4) 评价指标

本研究使用两种评价指标来评估模型的性能。第 1 种是均方根误差 (root mean square error, RMSE), RMSE 能够直观地反映出预测误差的平均水平。第 2 种是得分函数 (Score)。两种评价指标的公式如式 (13)~(14)。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (13)$$

$$Score = \begin{cases} \sum_{i=1}^N (e^{\frac{\Delta y_i}{10}} - 1), & \Delta y_i \geq 0 \\ \sum_{i=1}^N (e^{-\frac{\Delta y_i}{13}} - 1), & \Delta y_i < 0 \end{cases} \quad (14)$$

式中: $\Delta y_i = \hat{y}_i - y_i$, y_i 和 $\hat{y}_i$ 分别表示第 i 个样本的 RUL 实际值和 RUL 预测值。

2.3 实验流程

涡扇发动机 RUL 预测的流程图如图 7 所示。首先, 从 C-MPASS 数据集中选择合适的传感器数据, 并通过滑动窗口技术进行数据处理。在模型训练阶段, 将每台发动机的最后一个时间窗口作为测试集, 训练集数据用于训练混合模型, 并通过计算损失和反向传播优化模型, 训练一轮, 用测试集测试一次, 直至达到最大迭代次数。最后, 选取最佳模型在测试数据上进行 RUL 预测, 并对模型的预测结果进行评估以验证其性能。




图 7 涡扇发动机 RUL 预测流程图

Fig. 7 Flowchart of turbfan engine RUL prediction

2.4 模型参数设置

模型中各模块的具体参数和超参数设置如表 2 所示，涵盖了各层的神经元数量、卷积核大小、正则化策略等。本研究采用了 Adam 优化器，初始学习率设置为 0.001，这是一个常用的初始学习率，经过多次实验验证，能够在模型训练早期提供足够的学习步长以快速收敛。这些超参数的选择是基于多次实验结果的调整，最终使模型在 C-MAPSS 数据集上表现出最佳的 RUL 预测能力。

表 2 模型参数设置
Table 2 Model parameter settings

模块名称	参数	数值
TCN 模块	卷积核大小	3
	扩张率	1/2/4
	卷积核个数	25/30/50
BiLSTM 模块	隐藏层大小	25
SE 模块	降维比例	4
全连接层	全连接层 1	1 500/20
	全连接层 2	1 500/20
	全连接层 3	20/1
	批次大小	128
	迭代次数	50
超参数	学习率	0.001
	Dropout	0.2
	损失函数	MSE
	优化器	Adam

3 实验结果

图 8 和图 9 分别展示了 FD001 和 FD003 数据集中 100 台发动机的 RUL 预测结果。图 10 和图 11 分别展示了 FD001 测试集中 24 号发动机和 FD003 测试集中 99 号发动机的 RUL 预测结果。从图中可以看出，在运行的初始阶段，发动机的 RUL 表现出稳定性，这表明发动机处于良好的健康状态。然而，在退化阶段初期，预测的 RUL 与真实 RUL 之间存在较大的差异，这主要是由于退化的早期特征不够明显所致。随着发动机进入退化的后期，模型的预测准确率提高，这是因为在此阶段发动机的退化特征变得更加显著。

为了验证所提出 TCN-SE-BiLSTM 模型的有效性，本研究将其与 BiLSTM-ED^[18]、LSTM^[19]、MSDCNN-LSTM^[20]、ResNLSTM^[21]、DBN-SO-BiGRU^[22] 网络进行了对比实验。为消除实验过程中的随机性，每一实验均进行了十次重复，并记录了平均指标。表 3 提供了 TCN-SE-BiLSTM 模型与其他模型在 FD001 和 FD003 数据集上的 RMSE 和 Score 对比结果。

结果表明，所提出的混合模型在不同数据集的 RMSE




图 8 FD001 预测结果
Fig. 8 Prediction results of FD001




图 9 FD003 预测结果
Fig. 9 Prediction results of FD003




图 10 FD001 中 24 号发动机预测结果
Fig. 10 Prediction results of engine 24 in FD001




图 11 FD003 中 99 号发动机预测结果
Fig. 11 Prediction results of engine 99 in FD003

表 3 本方法与其他方法的对比结果

Table 3 Comparison of the results between the proposed method and other methods

方法	年份	FD001		FD003	
		RMSE	Score	RMSE	Score
BiLSTM-ED ^[18]	2019	14.74	273.00	17.48	574.00
LSTM ^[19]	2020	14.91	333.80	13.37	316.55
MSDCNN-LSTM ^[20]	2023	12.96	256.59	11.78	211.99
ResNLSTM ^[21]	2023	12.53	265.00	12.15	284.00
DBN-SO-BiGRU ^[22]	2024	12.23	242.80	11.93	235.37
TCN-SE-BiLSTM(本文方法)	2024	12.15	230.40	11.16	209.84

和 Score 表现出色,超过了大多数现有方法。总体而言,所提出的 TCN-SE-BiLSTM 模型性能最佳, RMSE 和 Score 最低。对于 FD001 和 FD003 数据集,在 RMSE 和 Score 上,本文所提出的方法比文献[18]的方法分别降低了 17.57%、15.61%、36.16%和 63.45%;比文献[19]的方法分别降低了 18.51%、30.97%、16.54%和 33.71%;比文献[20]的方法分别降低了 6.25%、10.21%、5.26%和 1.01%;比文献[21]的方法分别降低了 3.03%、13.06%、8.15%和 26.11%;比文献[22]的方法分别降低了 0.65%、5.10%、6.45%和 10.84%。综上所述,这些对比结果进一步证明了 TCN-SE-BiLSTM 模型的优越性和可靠性。通过结合 TCN 的时间序列建模能力、BiLSTM 对双向依赖的捕捉以及改进的 SE 模块对关键特征的自适应加权,该模型在 RUL 预测任务中显著提升了预测精度,表现出更强的鲁棒性和泛化能力。

为评估 TCN-SE-BiLSTM 模型中各模块对整体性能的贡献,本研究进行了消融实验,涵盖了 TCN、BiLSTM、TCN+BiLSTM 和 TCN+SE+BiLSTM 四种模型组合。消融实验结果如表 4 所示。实验结果表明,与 TCN+BiLSTM 相比,加入改进的 SE 模块后,模型的 RMSE 和 Score 分别降低了 4.03%和 4.46%。改进的 SE 模块通过结合 GAP 和 GMP,能够为模型提供对各通道特征的自适应加权。这种自适应加权机制允许模型动态调整不同通道特征的重要性,从而增强了对关键特征的捕捉能力。此外,并联的 TCN 和 BiLSTM 结构相较于单一模型更具优势,能够同时捕捉长短期时间依赖关系,从而进一步提高了预测的准确性和鲁棒性。整体来看,TCN 负责长时间序

列的依赖建模,而 BiLSTM 通过双向结构捕捉序列中的前后依赖,两者结合再加上 SE 模块的增强作用,使得 TCN-SE-BiLSTM 模型在复杂时间序列预测中表现出更优的性能和更高的鲁棒性。

4 结 论

本研究提出了一种基于并行 TCN-SE-BiLSTM 的 RUL 预测模型。通过结合 TCN 和 BiLSTM 的优点,模型能够有效提取复杂的时间序列特征,同时通过改进的 SE 注意力机制,进一步增强对关键特征的关注,从而提升了 RUL 预测的准确性。实验结果表明,所提出的模型在处理涡扇发动机多传感器复杂数据时表现出了良好的鲁棒性和预测能力,优于传统单一网络模型。在实际应用中,该模型为涡扇发动机的预测性维护提供了有力支持,有助于延长设备的使用寿命并降低维护成本。未来的研究将进一步优化网络结构,并探索更多用于复杂工业设备的 PHM 解决方案。

参考文献

[1] ZIO E. Prognostics and health management(PHM): Where are we and where do we(need to) go in theory and practice[J]. Reliability Engineering & System Safety, 2022, 218: 108119.

[2] 徐震震, 薛林, 马凯, 等. 基于时空特征的航空发动机剩余使用寿命预测[J]. 电子测量技术, 2023, 46(23): 63-67.

XU ZH ZH, XUE L, MA K, et al. Remaining useful life prediction of aero-engine based on spatio-temporal features[J]. Electronic Measurement Technology, 2023, 46(23): 63-67.

[3] ELLIS B, HEYNS P S, SCHMIDT S. A hybrid framework for remaining useful life estimation of turbomachine rotor blades[J]. Mechanical Systems and Signal Processing, 2022, 170: 108805.

[4] CHEN J, HUANG R, CHEN Z, et al. Transfer

表 4 消融实验结果

Table 4 Ablation study results

方法	FD001		FD003	
	RMSE	Score	RMSE	Score
TCN	13.10	247.19	12.43	271.50
BiLSTM	12.95	251.94	11.63	231.12
TCN+BiLSTM	12.66	241.16	11.39	224.47
TCN+SE+BiLSTM	12.15	230.40	11.16	209.84

- learning algorithms for bearing remaining useful life prediction: A comprehensive review from an industrial application perspective[J]. *Mechanical Systems and Signal Processing*, 2023, 193: 110239.
- [5] WANG H R, LI D W, LI D J, et al. Remaining useful life prediction of aircraft turbofan engine based on random forest feature selection and multi-layer perceptron[J]. *Applied Sciences*, 2023, 13(12): 7186.
- [6] 袁玉昕, 程跃兵, 熊敏艳, 等. 基于 Transformer-Bi-LSTM 模型的武器装备剩余寿命预测方法[J]. *计算机测量与控制*, 2024, 32(7): 203-210.
- YUAN Y X, CHENG Y B, XIONG M Y, et al. Remaining life prediction method of weapon equipment based on transformer-Bi-LSTM model[J]. *Computer Measurement & Control*, 2024, 32(7): 203-210.
- [7] 聂磊, 张吕凡, 徐诗奕, 等. 基于相似度特征融合和 CNN 的滚动轴承剩余寿命预测[J]. *噪声与振动控制*, 2023, 43(5): 115-121.
- NIE L, ZHANG L F, XU SH Y, et al. Remaining life prediction of rolling bearings based on similarity feature fusion and CNN [J]. *Noise and Vibration Control*, 2023, 43(5): 115-121.
- [8] 李路云, 王海瑞, 朱贵富. 改进 1D-CNN 和 LSTM 的涡扇发动机剩余寿命预测[J]. *热能动力工程*, 2023, 38(7): 194-202.
- LI L Y, WANG H R, ZHU G F. Remaining life prediction of turbofan engine based on improved 1D-CNN and LSTM[J]. *Thermal Power Engineering*, 2023, 38(7): 194-202.
- [9] JI W Q, JIAN CH, YI CH. Remaining useful life prediction for mechanical equipment based on Temporal convolutional network[C]. 2019 14th IEEE International Conference on Electronic Measurement & Instruments(ICEMI), 2019: 1192-1199.
- [10] LI J, JIA Y, NIU M, et al. Remaining useful life prediction of turbofan engines using CNN-LSTM-SAM approach[J]. *IEEE Sensors Journal*, 2023, 23(9): 10241-10251.
- [11] ZHENG J F, ZHANG B W, MA J, et al. A new model for remaining useful life prediction based on NICE and TCN-BiLSTM under missing data [J]. *Machines*, 2022, 10(11): 974.
- [12] 郭敏, 张浩. 基于改进 Bi-LSTM 网络下的多时变状态锂电池剩余寿命预测方法[J]. *国外电子测量技术*, 2023, 42(10): 59-68.
- GUO M, ZHANG H. Remaining life prediction method for lithium batteries with multiple time-varying states based on improved Bi-LSTM network [J]. *Foreign Electronic Measurement Technology*, 2023, 42(10): 59-68.
- [13] 兰杰, 李志宁, 李宁, 等. 基于注意力机制和残差深度分离卷积的 RUL 预测方法[J]. *电子测量技术*, 2023, 46(15): 149-157.
- LAN J, LI ZH N, LI N, et al. RUL prediction method based on attention mechanism and residual depthwise separable convolution [J]. *Electronic Measurement Technology*, 2023, 46(15): 149-157.
- [14] SAXENA A, GOEBEL K, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation [C]. 2008 International Conference on Prognostics and Health Management, 2008: 1-9.
- [15] 吴嘉俊, 苏春, 张玉茹. 基于双重自注意力机制和长短时记忆网络的剩余寿命预测[J]. *系统工程与电子技术*, 2024, 46(6): 1986-1994.
- WU J J, SU CH, ZHANG Y R. Remaining life prediction based on dual self-attention mechanism and long short-term memory network [J]. *Systems Engineering and Electronics*, 2024, 46(6): 1986-1994.
- [16] 修瑞, 丁建完, 刘笑炎, 等. 基于 ALSTM-MHA 的航空发动机寿命预测[J]. *机床与液压*, 2024, 52(12): 187-192.
- XIU R, DING J W, LIU X Y, et al. Life prediction of aero-engine based on ALSTM-MHA [J]. *Machine Tool & Hydraulics*, 2024, 52(12): 187-192.
- [17] 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. Remaining life prediction method for aero-engine based on improved generative adversarial network and ConvLSTM [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(3): 211-221.
- [18] YU W, KIM I Y, MECHEFSKE C. Remaining

- useful life estimation using a bidirectional recurrent neural network based autoencoder scheme [J]. Mechanical Systems and Signal Processing, 2019, 129: 764-780.
- [19] XIA T, SONG Y, ZHENG Y, et al. An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation [J]. Computers in Industry, 2020, 115: 103182.
- [20] CHEN W, LIU C, CHEN Q, et al. Multi-scale memory-enhanced method for predicting the remaining useful life of aircraft engines[J]. Neural Computing and Applications, 2023, 35(3): 2225-2241.
- [21] 陈保家, 郭凯敏, 陈法法, 等. 基于残差 NLSTM 网络和注意力机制的航空发动机剩余使用寿命预测[J]. 航空动力学报, 2023, 38(5): 1176-1184.
- CHEN B J, GUO K M, CHEN F F, et al. Remaining useful life prediction of aero-engine based on residual NLSTM network and attention mechanism [J]. Journal of Aerospace Power, 2023, 38 (5): 1176-1184.
- [22] 吴兴华, 包俊, 王洪亮, 等. 基于 DBN-SO-BiGRU 融合模型的航空发动机 RUL 预测[J/OL]. 控制工程, 1-10[2024-11-22]. <https://doi.org/10.14107/j.cnki.kzgc.20240328>.
- WU X H, BAO J, WANG H L, et al. RUL prediction of aero-engine based on DBN-SO-BiGRU fusion model[J/OL]. Control Engineering, 1-10[2024-11-22]. <https://doi.org/10.14107/j.cnki.kzgc.20240328>.

作者简介

张鑫阳, 硕士研究生, 主要研究方向为设备剩余使用寿命预测。

E-mail: 202312570030@nuist.edu.cn

蒋亮(通信作者), 副教授, 高级工程师, 主要研究方向为工业装备预测性维护。

E-mail: jiangliang@cw Xu.edu.cn