

DOI:10.19651/j.cnki.emt.2313836

# 基于时空特征的航空发动机剩余使用寿命预测<sup>\*</sup>

徐震震 薛林 马凯 杨玉迪

(大连理工大学机械工程学院 大连 116024)

**摘要:** 航空发动机作为一种高精密机械部件,对飞机性能和可靠性有重要影响。准确的剩余寿命预测可以降低维修成本,减少安全事故的发生。现有的预测方法只关注传感器数据之间的时间关系,忽略了传感器之间的空间关系。本文提出了一种时空特征融合的网络模型,利用图卷积神经网络和长短时记忆网络分别提取空间特征和时间特征,运用并行结构将时间特征与空间特征融合。在CMAPSS数据集上进行验证,子数据集FD001的RMSE为12.81,Score为252.04,实验结果表明,该方法相对于其他预测方法,预测精度更高。

**关键词:** 航空发动机;深度学习;剩余寿命预测;空间特征;时间特征

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

## Remaining useful life prediction of based on aero-engine spatio-temporal feature

Xu Zhenzhen Xue Lin Ma Kai Yang Yudi

(School of Mechanical Engineering, Dalian University of Technology, Dalian 116024, China)

**Abstract:** As a high precision mechanical component, aero-engine has important influence on aircraft performance and reliability. Accurate prediction of remaining useful life can reduce maintenance costs and reduce the occurrence of safety accidents. The existing prediction methods only focus on the temporal relationship between sensor data, ignoring the spatial relationship between sensors. This paper proposes a network model that integrates spatial-temporal features, and uses graph convolutional networks and long short-term memory to extract spatial and temporal features, respectively. The parallel structure is used to integrate the temporal and spatial features. The RMSE and Score of subdataset FD001 are 12.81 and 252.04 respectively. The experimental results show that the proposed method has higher prediction accuracy than other prediction methods.

**Keywords:** aero-engine; deep learning; remaining useful life; spatial feature; temporal feature

## 0 引言

航空发动机是一种高度复杂和精密的机械,为飞机飞行提供所需动力<sup>[1]</sup>。它作为飞机的“心脏”,直接影响飞机的性能和可靠性。由于其结构复杂,工作环境恶劣,同时会受到外来物的冲击,因而容易发生故障。

传统的维修方式包括事后维修和定期维修,事后维修是指机械设备发生故障之后进行维修,可以减少设备的停机时间,但对已经造成的损失无法挽回。定期维修是预防性维修,但在机械设备使用过程中,受各种因素的影响,可能在未达到维修日期时出现故障,造成损失,而且定期维修的成本较高、效率低。在这种情况下,故障预测与健康管理(prognostics and health management, PHM)技术被提出。

剩余寿命预测(remaining useful life, RUL)是PHM的重要组成部分。RUL是指机械设备从当前时间到发生故障时的时间间隔<sup>[2]</sup>。高精度的RUL预测可以综合当前的经济、设备等各种因素指导及时制定维修计划,降低发生严重事故的概率,降低维护成本,保障机械设备的安全性和可靠性。

RUL预测的方法可以分为模型的预测方法和基于数据驱动的预测方法<sup>[3]</sup>。基于模型的故障预测方法是指通过建立观测对象的物理特性和失效特性的数学模型,对其健康状态进行评估。基于模型的故障预测方法的优点是预测精度高,但缺点是建模复杂,特别是在复杂工况下建模的难度和成本陡增,模型的泛化能力不强精度也不高。基于数据驱动方法可进一步分为基于统计模型的方法、基于浅层

收稿日期:2023-06-06

\*基金项目:国家自然科学基金(51905074)、辽宁省自然科学基金(2019-KF-04-04)项目资助

机器学习的方法和基于深度学习的方法。其中基于深度学习的方法能拟合任意复杂的函数,不需要手动提取特征,越来越被广泛应用。

深度学习常用 RUL 预测算法包括卷积神经网络(convolution neural network, CNN)、循环神经网络(recurrent neural networks, RNN)、注意力机制(attention mechanism, AM)和 Transformer 等<sup>[4]</sup>。胡立坤等<sup>[5]</sup>提出了一种可自动扩展的长短期记忆(automatically expandable LSTM, AEI LSTM)模型,将前一模块的输出误差作为后一模块的输入,降低了模型的预测误差。马忠等<sup>[6]</sup>使用改进的二维 CNN 在时间维度上进行卷积运算,挖掘数据的趋势和航空发动机剩余寿命之间的关系,提高了预测精度,增强了模型的可解释性。李广福等<sup>[7]</sup>通过皮尔逊相关系数结合核主成分分析法(kernel principal component analysis, KPCA)建立滚动轴承退化状态的多尺度退化指标,结合 Informer 模型,实现滚动轴承 RUL 预测。

目前基于深度学习的航空发动机 RUL 预测只利用传感器数据时间方面的信息,没有考虑不同传感器之间的空间信息。因此,本文提出了一种结合 GCN 和 LSTM 的网络模型,此模型利用 GCN 提取传感器之间的空间特征,使用 LSTM 提取时间特征,将时间特征与空间特征融合输出进行 RUL 预测,充分利用时间和空间特征,提高 RUL 预测精度。

## 1 模型构建

### 1.1 图神经网络

图神经网络(graph neural networks, GNN)是使用神经网络来学习图结构数据,提取和发掘图结构数据中的特征和模式,满足分类、预测等任务需要的算法的总称<sup>[8]</sup>。图结构是由节点和线段构成,可以表示实体之间的关系。图中的节点表示实体,节点之间的线段表示实体之间的关系。图结构可以表示为  $G=(V,E)$ , 其中  $V$  表示节点的集合,  $E$  表示边的集合。

图卷积神经网络(graph convolutional networks, GCN)是一种能够直接作用于图并使用图结构信息的卷积神经网络。GCN 的主要思想是对每个节点,考虑其所有邻居以及自身所包含的特征信息,更新自身信息,如图 1 所示。GCN 的计算公式为:

$$\mathbf{H}^{l+1} = \sigma(\widetilde{\mathbf{D}} - \frac{1}{2}\widetilde{\mathbf{A}}\widetilde{\mathbf{D}} - \frac{1}{2}\mathbf{H}^l\mathbf{W}^l) \quad (1)$$

式中:  $\mathbf{H}^{l+1}$  表示第  $l$  层 GCN 层的输出,  $\mathbf{H}^l$  表示第  $l$  层 GCN 层的输入,  $\mathbf{H}^l \in \mathbb{R}^{n \times d}$ ,  $n$  表示图的节点个数,  $d$  表示每个节点的特征维度,  $\widetilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}_n$ , 其中  $\mathbf{A}$  表示无向图的邻接矩阵,  $\mathbf{I}_n$  表示  $n$  阶单位矩阵,  $\widetilde{\mathbf{D}}$  是无向图的度矩阵,  $\widetilde{\mathbf{D}} = \sum_j \widetilde{\mathbf{A}}_{ij}$ ,  $\mathbf{W}^l \in \mathbb{R}^{d \times h}$  是需要训练的参数,  $h$  是输出维

度,  $\sigma$  是激活函数。

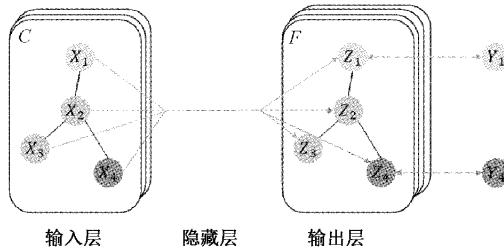


图 1 GCN 传递示意图

GNN 处理的任务可以分为节点级任务和图级任务<sup>[9]</sup>。节点级任务中,图中的每个节点被视为一个样本,模型只需要学习节点的表示,在图级任务中,整个图被认为是一个样本,模型需要首先学习节点表示,然后获得整个图的表示。相较于节点级任务而言,图级任务需要有池化层,来实现分层学习,并减少图中节点的数量,降低复杂度。RUL 预测属于图级任务。

### 1.2 循环神经网络

RNN 在处理长序列数据时,仅可以获得较近的序列的信息,而对于较远的序列的信息不具有记忆功能,导致信息丢失。长短时记忆网络(long short-term memory, LSTM)是 RNN 的一种改进结构,相较于 RNN 而言, LSTM 的单个循环结构内部有 4 种状态,如图 2 所示。LSTM 有效地解决了 RNN 短期依赖问题。

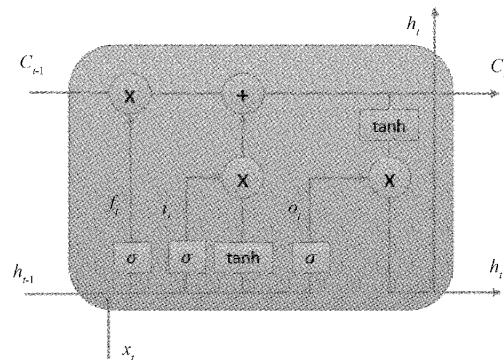


图 2 LSTM 细胞结构图<sup>[10]</sup>

LSTM 细胞主要由输入门、遗忘门和输出门组成,其中遗忘门  $f_t$  控制上一时刻  $c_{t-1}$  需要遗忘的信息,输入门  $i_t$  控制当前时刻的候选状态  $\tilde{c}_t$  有多少信息需要保存,输出门  $o_t$  控制当前时刻的内部状态  $c_t$  需要输出给外部状态  $h_t$  的信息。遗忘门  $f_t$ 、输入门  $i_t$  和输出门  $o_t$  的计算公式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

式中:  $f_t$  是遗忘门的输出值,  $h_{t-1}$  是  $t-1$  时刻的输出值,  $x_t$  是  $t$  时刻的输入值,  $W_f$  是遗忘门的网络层权重,  $b_f$  是遗忘门的网络层偏置,  $\sigma$  是激活函数。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

式中:  $i_t$  是输入门的输出值,  $W_i$  是输入门的网络层权重,  $b_i$

是输入门的网络层偏置。

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

式中: $o_t$ 是输出门的输出值, $\mathbf{W}_o$ 是输出门的网络层权重, $b_o$ 是输出门的网络层偏置。

### 1.3 预测模型

本文提出了一种基于时间特征和空间特征的 RUL 预测模型,模型整体使用并行结构,相对于串行结构,并行结

构可以更好地保留特征,一条分支利用 LSTM 网络层提取传感器数据之间的时间依赖关系,一条分支将各个传感器看作图结构上的节点,利用 GCN 网络层提取传感器数据的空间特征,提取的空间特征经 MaxPool 层处理,聚合全局信息,增强层次表示,转换为图级任务。将时间特征与空间特征融合经全连接层输出,得到预测结果。在全连接层之间添加 Dropout 层,防止过拟合的发生。如图 3 所示。

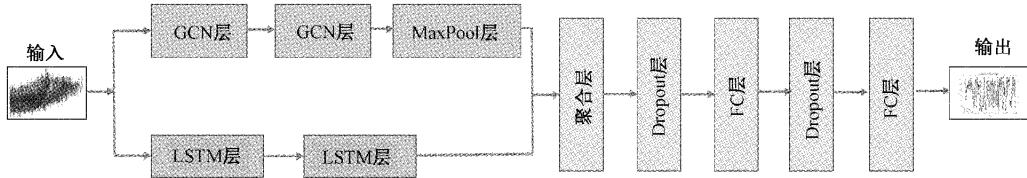


图 3 模型结构图

## 2 实验分析

### 2.1 数据集介绍

本文使用 CMAPSS 数据集,该数据集是由美国国家航空航天局所提供,被广泛应用在航空发动机 RUL 预测。

CMAPSS 数据集由 4 个子数据集组成,本文选取 FD001 数据集进行实验验证。该数据集模拟的故障模式是高压压气机故障<sup>[11]</sup>,运行工况是由 3 个操作条件飞行高度、马赫数和油门解算器组合而成,训练集的数据包含 100 台涡扇发动机从开始到完全失效的全部数据,测试集数据包含 100 台涡扇发动机从开始到某一时刻的数据。

### 2.2 数据预处理

#### 1) 数据降维

该数据集包含 21 个传感器数据和 3 个操作条件数据,绘制各传感器数据随运行周期变化曲线,传感器 2 变化曲线图如图 4 所示。其中传感器 1、5、6、10、16、18、19 数据随运行周期波动较小,所以将这些传感器数据去除以降低样本输入的维度。

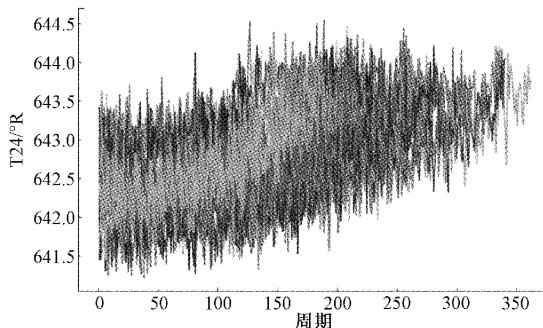


图 4 传感器 2 变化曲线图

#### 2) 数据标准化

对传感器数据进行标准化处理,可以消除由于量纲不同引起的误差,提高模型的精度和收敛速度。本文使用 z-score 标准化方法,其计算公式为:

$$x^* = \frac{x - \mu}{\sigma} \quad (5)$$

式中: $x$  是标准化前传感器数据, $x^*$  是标准化后传感器数据, $\mu$  是传感器数据的平均值, $\sigma$  是传感器数据的标准差。

#### 3) 标签设置

航空发动机性能退化过程可认为是线性退化<sup>[12]</sup>。在运行初期航空发动机处于健康状态,航空发动机发生退化的概率小,所以此阶段航空发动机 RUL 为定值,本文设置此定值为 125。在故障发生之后,发动机保持线性退化状态,此时航空发动机 RUL 线性递减至 0。

#### 4) 图结构构造

利用 Pearson 相关系数计算各个传感器之间的相关性,Pearson 相关系数计算公式如式(6)所示<sup>[13]</sup>。利用此公式计算各个传感器之间的相关性,各传感器之间的计算结果如图 5 所示。Pearson 相关系数的取值范围为  $[-1, 1]$ ,绝对值越接近 1 表示两者相关性越强。

$$\rho_{x,y} = \frac{\text{cov}(X,Y)}{\sigma_x \sigma_y} \quad (6)$$

式中: $\text{cov}(X,Y)$  是传感器 X 和传感器 Y 的协方差, $\sigma_x$  是传感器 X 的标准差, $\sigma_y$  是传感器 Y 的标准差。(原始行间距有误)

设定 Pearson 相关系数的阈值为 0.75,若两个传感器的 Pearson 相关系数的绝对值大于阈值,则判定这两个传感器之间存在关联,否则认为这两个传感器之间不存在关联。通过各个传感器之间的 Pearson 相关系数和阈值,判断各个传感器之间的相关性,构建传感器的图结构。

#### 5) 样本的构造

本文采用滑动窗口的方法构造样本。滑动窗口就是通过固定长度来划分时间序列,每滑动一个单位可得到一个样本,如图 6 所示。为了确保发动机数据的完整性,滑动窗口的尺寸应该不大于发动机的运行周期数,考虑到 FD001 数据集中发动机的运行周期数最小为 31,所以本文将滑动窗口的尺寸设置为 30。

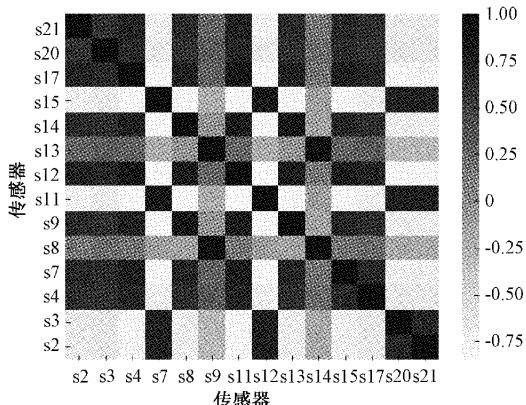


图 5 传感器相关系数图

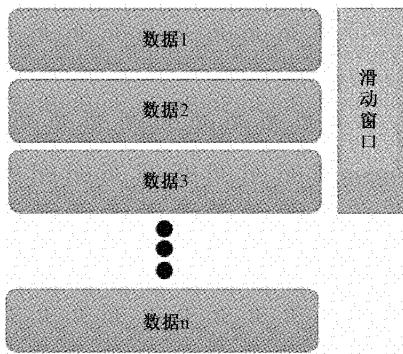


图 6 滑动窗口示意图

### 2.3 评价指标

本文选用 CMAPSS 数据集给出的得分函数(Score)和均方根误差(root mean square error, RMSE)作为评价指标。计算公式(原始行间距有误)为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{t}_i - t_i)^2} \quad (7)$$

$$Score = \begin{cases} \sum_{i=1}^n (e^{-\frac{\hat{t}_i - t_i}{13}} - 1)^2 & \hat{t}_i < t_i \\ \sum_{i=1}^n (e^{-\frac{\hat{t}_i - t_i}{10}} - 1)^2 & \hat{t}_i \geq t_i \end{cases} \quad (8)$$

式中: $n$  表示样本个数,  $\hat{t}_i$  表示第  $i$  个样本的预测值,  $t_i$  表示第  $i$  个样本的真实值。

### 2.4 超参数的设置

超参数是手动设置用来估计模型的参数, 超参数的设置对模型的训练速度和预测精度影响较大。如表 1 所示, 记录了模型中各个超参数的设置, 其中 LSTM 层的激活函数为 ReLu 函数, 选择均方误差(mean square error, MSE)作为模型损失函数。

### 2.5 实验结果分析

为了验证所提模型的优越性, 本文设计 3 组对比实验, 分别是只使用 GCN 层提取空间特征的模型, 使用 GCN

表 1 超参数设置

超参数	设置
优化器	RMSprop
学习率	0.001
批处理大小	512
迭代次数	30
GCN 层 1	层数 1, 节点数 64
GCN 层 2	层数 1, 节点数 32
MaxPool 层	层数 1
LSTM 层 1	层数 1, 节点数 64
LSTM 层 2	层数 1, 节点数 32
FC 层 1	节点数 512
FC 层 2	节点数 1
Dropout 层	0.1

层提取空间特征和 LSTM 层提取特征的串行结构模型, 以及使用 GCN 层提取空间特征和 LSTM 层提取时间特征的并行结构模型, 实验结果如表 2 所示。

表 2 对比实验结果

模型	RMSE	Score
GCN	23.78	1 488.86
GCN+LSTM 串行	14.49	412.76
GCN+LSTM 并行	12.81	252.04

从表 2 中可以看出融合时间特征和空间特征的并行模型可以更好地利用时间特征和空间特征, 表现在 RMSE 和 Score 均有较大提升, 相较于串行结构 RMSE 提升 11.6%, Score 提升 38.9%。如图 7 所示, 将 FD001 测试集通过此模型得到的各发动机预测 RUL 和真实 RUL 做对比。

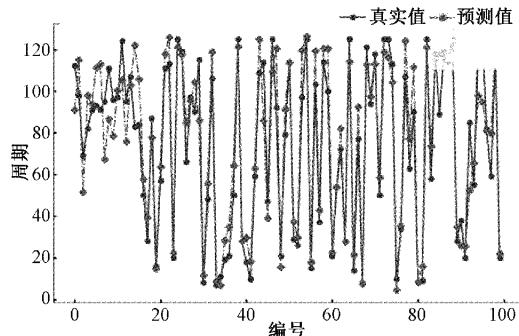


图 7 预测值与真实值对比图

将本文所提模型与其他模型进行对比, 对比结果如表 3 所示。可以看出, 本文所提出的模型相较于其他模型, 在 RMSE 和 Score 两方面均有较大提升。相对于 LSTM 模型 RMSE 下降 20.6%, Score 下降 25.4%; 与 BiLSTM 和 ED 融合模型对比, RMSE 下降 11.5%, Score

下降7.7%;对比RBPF模型,RMSE下降19.6%,Score下降34.3%;相较于CNN模型,Score下降7.9%;与KGHM模型对比RMSE下降28.1%。

表3 各方法结果对比

方法	RMSE	Score
LSTM <sup>[14]</sup>	16.14	338.00
CNN <sup>[15]</sup>	12.61	273.70
BiLSTM+ED <sup>[16]</sup>	14.47	273.00
RBPF <sup>[17]</sup>	15.94	383.39
KGHM <sup>[18]</sup>	13.18	250.99
本文	12.81	252.04

### 3 结 论

本文针对航空发动机RUL预测,提出了一种结合传感器数据时间特征和空间特征的网络模型。利用GCN层提取空间特征,并将每个传感器视为节点,按照图级任务处理,利用LSTM层提取时间特征,将空间特征和时间特征利用并行结构进行融合输出。经实验证明所提出的模型,有效地融合时间特征和空间特征,在单工况的FD001数据集上表现良好,具体体现在评价指标RMSE和Score均有较大的提升。在未来的研究中,应重点关注多工况航空发动机的RUL预测和模型迁移。

### 参考文献

- [1] 蔡景,康婷玮,左洪福,等.多源信息融合的航空发动机异常检测方法研究[J].电子测量技术,2022,45(22):135-141. DOI:10.19651/j.cnki.emt.2211502.
- [2] 张加劲.基于注意力机制和CNN-BiLSTM模型的航空发动机剩余寿命预测[J].电子测量与仪器学报,2022,36(8):231-237. DOI:10.13382/j.jemi.B2205473.
- [3] 任越.基于深度学习的发动机故障预测技术研究[D].绵阳:西南科技大学,2022. DOI:10.27415/d.cnki.gxngc.2022.000004.
- [4] 袁烨,张永,丁汉.工业人工智能的关键技术及其在预测性维护中的应用现状[J].自动化学报,2020,46(10):2013-2030. DOI:10.16383/j.aas.c200333.
- [5] 胡立坤,何旭杰,殷林飞.基于可自动扩展的LSTM模型的航空发动机剩余寿命预测方法[J/OL].计算机应用研究,2023,40(8):2311-2322. DOI:10.19734/j.issn.1001-3695.2023.01.0010.
- [6] 马忠,郭建胜,顾涛勇,等.基于改进卷积神经网络的航空发动机剩余寿命预测[J].空军工程大学学报(自然科学版),2020,21(6):19-25.
- [7] 李广福,马萍,张宏立,等.一种Informer模型的滚动轴承剩余寿命预测方法[J/OL].机械科学与技术,1-8[2023-06-06]. DOI:10.13433/j.cnki.1003-8728.20230117.
- [8] 吴博,梁循,张树森,等.图神经网络前沿进展与应用[J].计算机学报,2022,45(1):35-68.
- [9] LI T, ZHOU Z, LI S, et al. The emerging graph neural networks for intelligent fault diagnostics and prognostics: A guideline and a benchmark study[J]. Mechanical Systems and Signal Processing, 2022, 168: 108653.
- [10] LINDEMANN B, MASCHLER B, SAHLAB N, et al. A survey on anomaly detection for technical systems using LSTM networks[J]. Computers in Industry, 2021, 131: 103498.
- [11] RAMASSO E, SAXENA A. Performance benchmarking and analysis of prognostic methods for CMAPSS datasets [J]. International Journal of Prognostics and Health Management, 2014, 5(2): 1-15.
- [12] WU Y, YUAN M, DONG S, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks[J]. Neurocomputing, 2018, 275: 167-179.
- [13] 李雅.基于数据驱动的航空发动机剩余寿命预测研究[D].郑州:河南大学,2022. DOI:10.27114/d.cnki.ghnau.学2022.000726.
- [14] ZHENG S, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation[C]. 2017 IEEE international conference on prognostics and health management (ICPHM). IEEE, 2017: 88-95.
- [15] LI X, DING Q, SUN J Q. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. Reliability Engineering & System Safety, 2018, 172: 1-11.
- [16] YU W, KIMI 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.
- [17] CAI H, FENG J, LI W, et al. Similarity-based particle filter for remaining useful life prediction with enhanced performance[J]. Applied Soft Computing, 2020, 94: 106474.
- [18] LI Y, CHEN Y, HU Z, et al. Remaining useful life prediction of aero-engine enabled by fusing knowledge and deep learning models[J]. Reliability Engineering & System Safety, 2023, 229: 108869.

### 作者简介

徐震震,硕士研究生,主要研究方向为深度学习、剩余寿命预测。

E-mail:1527783974@qq.com

薛林,博士,副教授,主要研究方向为无损检测、高精度工业CT及智能检测装备。

E-mail:linxue@dlut.edu.cn

马凯,硕士研究生,主要研究方向为工业CT图像处理、图像分割。

E-mail:2423959211@qq.com

杨玉迪,硕士研究生,主要研究方向为结构设计、无损检测。

E-mail:gaven\_yangyd@163.com