

文章编号: 1674-8190(2023)02-073-08

# 多特征注意力的航空发动机剩余寿命预测模型

王欣, 黄佳琪, 孟天宇, 李屹

(中国民用航空飞行学院 计算机学院, 广汉 618307)

**摘要:** 航空发动机性能退化趋势复杂, 适时地对其进行剩余寿命预测和检修维护十分重要。提出一种基于多特征注意力的膨胀卷积网络模型来预测航空发动机的剩余使用寿命, 利用膨胀卷积增强提取序列数据时序信息的能力, 同时建立残差连接以改善传统卷积网络中的梯度消失问题。首先采用定长滑动时间窗沿时间维度截取数据, 对数据进行重构; 再对每个特征对应的时间序列单独应用膨胀卷积提取时序信息; 引入特征注意力机制计算各特征之间的相对重要性; 在公开的航空发动机数据集上进行验证, 并与现有的主流预测方法做对比。结果表明: 该模型在时间序列数据预测方面有着更高的精度。

**关键词:** 航空发动机; 膨胀卷积; 残差连接; 多特征注意力; 剩余寿命预测

中图分类号: V263.6

文献标识码: A

DOI: 10.16615/j.cnki.1674-8190.2023.02.08

## Remaining useful life estimation model for aero-engine using multi-feature attention

WANG Xin, HUANG Jiaqi, MENG Tianyu, LI Yi

(School of Computer Science, Civil Aviation Flight University of China, Guanghan 618307, China)

**Abstract:** The degradation trend of aero-engine performance is complex, so it is very important to predict its remaining life and maintain it in time. In this paper, a dilated convolution network based on multi-feature attention model is presented to predict the remaining useful life (RUL) of aero-engine. In this model, dilated convolution is used to enhance the ability to extract temporal features of sequence data, and residual connections are established to improve the problem of gradient disappearance in traditional convolution networks. Firstly, the raw input data are reconstructed by sliding time window of fixed length to intercept data along the time dimension. Then the dilated convolution networks extract the temporal features of corresponding to each feature respectively. Finally, the feature attention mechanism is used to calculate the relative importance of features. Experimental results demonstrate that the proposed algorithm has better accuracy of RUL estimation than the other comparative models.

**Key words:** aero-engine; dilated convolution; residual connection; multi-feature attention; remaining useful life estimation

收稿日期: 2022-05-05; 修回日期: 2022-06-30

基金项目: 国家自然科学基金民航联合基金重点项目(U2033213); 中央高校基本科研业务费专项资金项目(J2022-048)  
四川省科技厅重点研发项目(2022YFG0027); 四川省大学生创新创业项目(S202110624108)

通信作者: 黄佳琪, huangjq24@163.com

引用格式: 王欣, 黄佳琪, 孟天宇, 等. 多特征注意力的航空发动机剩余寿命预测模型[J]. 航空工程进展, 2023, 14(2): 73-80.

WANG Xin, HUANG Jiaqi, MENG Tianyu, et al. Remaining useful life estimation model for aero-engine using multi-feature attention[J]. Advances in Aeronautical Science and Engineering, 2023, 14(2): 73-80. (in Chinese)

## 0 引言

航空发动机作为飞机的重要部件之一,对飞机的安全运行有着至关重要的意义。发动机的性能与健康状态受到内外综合因素的作用,会呈现衰退的趋势,当衰退达到一定程度时设备会终止工作<sup>[1]</sup>。在发动机从运行到失效的周期内,对发动机的状态监测、故障诊断、寿命预测等是保证发动机安全运行的必要条件<sup>[2]</sup>,因此适时地对发动机进行评估和检修维护十分重要。目前预测性维护(Predictive Maintenance,简称PdM)<sup>[3]</sup>广泛应用于航空发动机维护领域,通过预测发动机的退化趋势,确定设备何时需要维修或退役。这种做法既降低了维护成本,又减少了不必要的维护活动。目前在发动机剩余寿命(Remaining Useful Life,简称RUL)预测领域主要有三种方式,即基于物理模型、经验模型和数据驱动模型的预测方法<sup>[4]</sup>。前两种预测方式都需要足够的先验知识和建立精准的模型来描述发动机的退化方式过程,而基于数据驱动的方法无需系统的先验知识,通过机器学习或深度学习的方法挖掘数据之间的隐含信息进行剩余寿命预测,是一种重要的RUL预测手段。

崔利杰等<sup>[5]</sup>提出一种航空发动机多状态寿命的控制策略,在减少发动机大修和合理安排发动机使用上优于传统的发动机寿命控制策略;胡启国等<sup>[6]</sup>使用核主成分分析(KPCA)对发动机的多维退化信息进行降维处理和信息融合,利用BLSTM神经网络模型对带有多维退化信息的航空发动机剩余寿命进行预测;刘伟民等<sup>[7]</sup>提出了CNN-LSTM网络,利用该网络对发动机做出更精确的寿命损耗评估和剩余寿命预测;A. Ayodeji等<sup>[8]</sup>将因果卷积与膨胀卷积结合提取数据的时序特征,而后通过LSTM网络提取不同操作条件的多尺度特征,有效地利用了发动机的时序相关性和特征间的相关性。

以上方法虽然在RUL预测方面取得了不错的效果,却没有充分考虑多传感器特征,只是将输入数据输入到同一个网络结构进行处理。针对这一问题,C. Mikel等<sup>[9]</sup>提出了一种多头卷积神经网络(Convolutional Neural Networks,简称CNN)架构(Multi-head CNN-RNN),通过在多元时间序列的每个特征上面应用一维卷积实现多传感器系统中的异常检测,并将卷积生成的特征向量拼接送入

RNN网络做进一步处理;D. K. Kim等<sup>[10]</sup>在每个特征维度上采用一维卷积分别提取每个变量的时序特征,使用注意力机制反映变量之间的相关性。

考虑到传感器的长时间序列特征,本文在多头CNN结构<sup>[10]</sup>的基础上,提出一种多特征注意力的改进模型,在每个特征上面独立应用膨胀卷积提取更多的发动机性能退化的时序信息,通过特征注意力层得到发动机的RUL预测结果,并与几种主流方法进行对比。

## 1 相关理论方法

### 1.1 时序卷积网络

卷积神经网络(CNN)早在1989年被提出<sup>[11]</sup>,是一种前馈神经网络,具有局部连接、权重共享的特性。卷积运算将输入信号的局部区域与卷积核做卷积运算,且不同层次的网络能学习到不同层次的特征。

时序卷积网络(Temporal Convolutional Network,简称TCN)是在CNN的基础上发展而来,指的是一类具有特殊特征的CNN。TCN主要有以下特点<sup>[12]</sup>:(1)能取任意长度的序列并映射到相同长度的输出序列;(2)下一层的输入只依赖于当前时刻之前的信息,和未来的信息无关;(3)膨胀系数使得网络层的感受野呈指数型增长,有利于减少网络层数和计算内存,增大感受野。

#### 1.1.1 膨胀卷积

因果卷积虽能保证未来的信息不泄露,但是面对长序列记忆的任务时,大量的历史数据需要堆叠更多的网络层,降低了运算效率,膨胀卷积(Dilated Convolutions)通过间隔采样这一思想有效地解决了网络冗余问题。膨胀卷积公式为

$$F(s) = (X * df)(s) = \sum_{i=0}^{k-1} f(i) \cdot X_{(s-d \cdot i)} \quad (1)$$

式中: $f$ 为过滤器; $X * d$ 表示以膨胀系数为 $d$ 的膨胀卷积操作对输入序列 $X$ 进行处理; $k$ 为卷积核尺寸; $X_{(s-d \cdot i)}$ 确保只能对过去的输入做卷积操作。当 $d=1$ 时相当于正常卷积。

#### 1.1.2 残差连接

神经网络的训练中,一般情况下网络越深表达能力越强,性能越好,随着训练的深入,会出现梯度爆炸、梯度消失的问题,因此引入残差学习框架以减轻网络的训练量改善以上问题<sup>[13]</sup>。

残差连接(Residual Connections)中加入了恒等映射函数,使得网络可以实现跨层方式传递信息。残差连接公式为

$$o = \text{Activation}[x + F(x)] \quad (2)$$

式中:Activation为激活函数; $F(x)$ 为转换函数; $o$ 为残差操作的结果。

残差结构中每个残差块由膨胀卷积层、归一化层和激活函数组成,并引入Dropout避免过拟合。考虑TCN中出现的输入输出维度不同的情况,添加一个 $1 \times 1$ 的卷积使输入输出形状相同。

### 1.1.3 TCN模型

本文模型中的TCN部分如图1所示,图中 $k$ 为卷积核尺寸; $b$ 为膨胀系数基数,如 $2, 3, \dots, k$ ( $k$ 为整数)。设置残差块 $n=5, b=2$ 。TCN层之间通过残差结构连接,每个残差结构包括2层膨胀卷积和1层短路连接卷积,每个残差结构的膨胀系数都相同,后一层的膨胀系数是前一层的2倍。膨胀系数的规律增长保证了卷积视野有序扩张,可以综合考虑局部与全局信息。

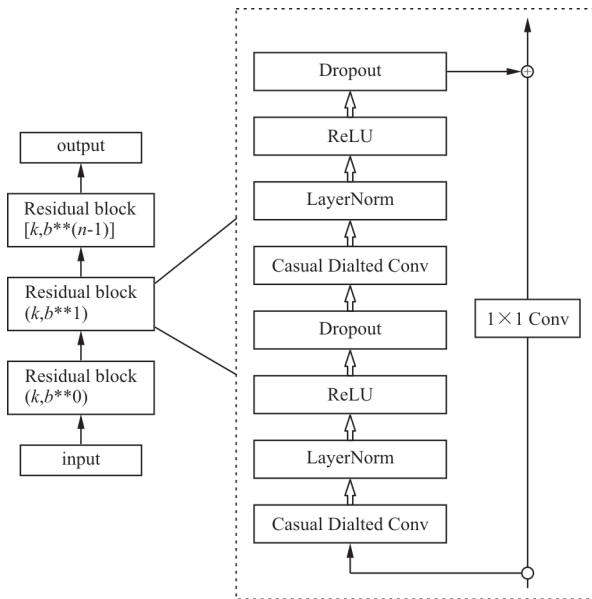


图1 TCN模型  
Fig.1 TCN model

## 1.2 注意力机制

注意力机制(Attention Mechanism)作为神经网络中的一个重要概念,首先被引入机器翻译<sup>[14]</sup>,如今被广泛应用在计算机视觉、文本处理等领域。注意力本质思想类似于人类的视觉注意力机制,对于视觉系统收集到的信息,大脑会选择性聚焦

重点部分,忽略掉其他无用的信息。在注意力模型中,对输入的信息给予不同的权重系数,再与输入向量做加权求和,突出关键特征,使模型得到期望值,在很大程度上提高了模型的性能。

本文在M. T. Luong等<sup>[15]</sup>提出的注意力模型基础上,提出一种特征注意力机制,即在预测过程中计算每一个传感器的权重,更关注重要的传感器参数值,其过程如式(3)~式(5)所示,其中式(3)表示注意力分数,式(4)表示注意力权重,式(5)表示注意力向量。

$$\text{score}(X_t) = X_t W_a \quad (3)$$

$$a_i(N) = \frac{\exp[\text{score}(X_t) \cdot W_b]}{\sum_{i=1}^N \exp[\text{score}(X_t) \cdot W_b]} \quad (4)$$

$$X'_t = X_t \odot a_i(N) \quad (5)$$

式中: $X_t$ 为原始输入序列; $W_a$ 和 $W_b$ 为权重矩阵。

神经网络通过优化算法不断调整参数值从而得到合适的权重矩阵。经过式(3)~式(4)得到每个传感器的注意力权重 $a_i(N)$ ,再与原始输入逐个相乘得到新的特征序列 $X'_t$ 。

## 2 基于多特征注意力的膨胀卷积预测模型

### 2.1 模型预测流程

首先对退化不明显的特征做降维处理,再将数据归一化,利用固定长度的滑动窗口沿时间维度数据进行分割实现数据的重构;其次使用滑窗后的训练数据对模型进行训练,计算每个batch的损失函数,更新模型参数使得模型损失值不断减小,当满足早停条件或达到最大训练轮数时停止训练,建立训练好的预测模型,输入测试集,输出每个发动机的剩余使用寿命预测值。

### 2.2 网络模型设计

剩余使用寿命预测模型如下。

(1) 每台发动机有 $N$ 个特征,设滑窗长度为 $m$ ,从运行到失效的时间周期为 $T$ ,则每次滑窗后生成一个二维矩阵

$$X_t^N = \begin{bmatrix} x_t^1 & x_t^2 & \cdots & x_t^n & \cdots & x_t^N \\ x_{t+1}^1 & x_{t+1}^2 & \cdots & x_{t+1}^n & \cdots & x_{t+1}^N \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{t+m-1}^1 & x_{t+m-1}^2 & \cdots & x_{t+m-1}^n & \cdots & x_{t+m-1}^N \end{bmatrix} \quad (n \in [1, N], t \in [1, T - m + 1]) \quad (6)$$

(2) 针对每一个特征单独应用膨胀卷积,分别提取每个输入特征的时间序列信息,每个 TCN 层的输入是一个一维向量  $X_t^n$ :

$$X_t^n = \begin{bmatrix} x_t^n \\ x_{t+1}^n \\ \vdots \\ x_{t+m-1}^n \end{bmatrix} \quad (7)$$

(3) 通过激活函数、批归一化和池化层的处理后,输出  $N$  个一维向量,将这些向量沿特征维度重新拼接,根据公式 (3) 计算出注意力分数  $\text{score}(X_t)$ ,再根据公式 (4) 求出注意力权重值  $a_t(N)$ ,且所有权重值之和为 1,将原始输入与对应的权重系数相乘,输出新的特征序列  $X'_t$ ,最后通过全连接层得到预测值。

基于多特征注意力的膨胀卷积网络结构如图 2 所示。

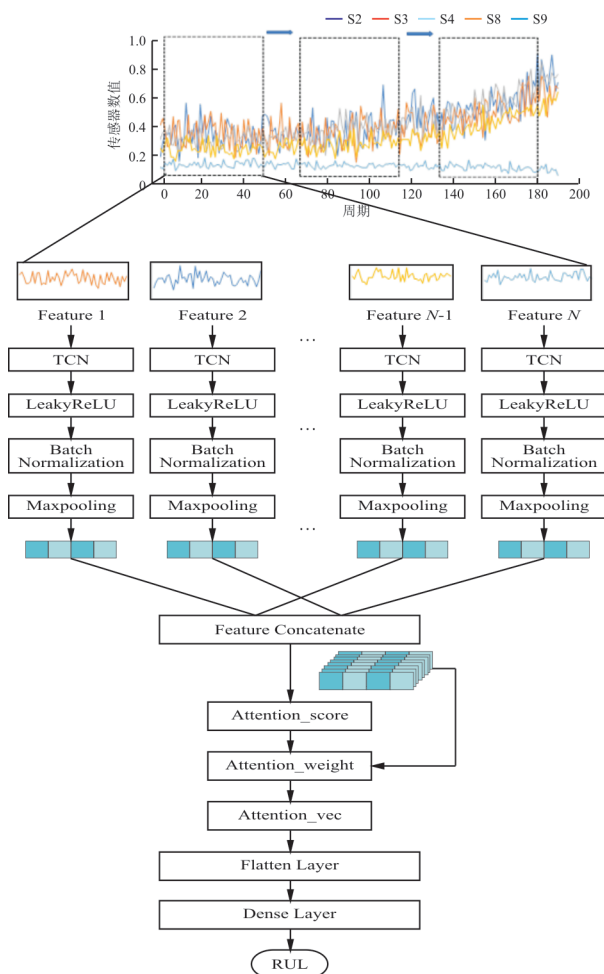


图 2 基于多特征注意力的膨胀卷积网络结构图  
Fig. 2 Structure diagram of dilated convolution networks based on multi feature attention

该模型既实现了在每个特征维度上面提取数据的时序信息,又通过注意力机制提取了特征之间的相对重要的信息,有利于进一步提升预测精度。

## 3 实验

### 3.1 数据集

实验环境配置如下:处理器为 Intel(R) Xeon (R) W-2123(3.60 GHz),内存 16.0 GB;显卡为 NVIDIA Quadro P2000;集成开发环境为 Pycharm Professional Edition 2021,编程语言为 Python 3.8。

本文所采用的数据集来自 NASA 商用模块化航空推进系统模拟模型 (Commercial Modular Aero-Propulsion System Simulation, 简称 C-MAPSS)<sup>[16]</sup>,该数据集在设备剩余使用寿命预测领域已得到普遍应用。该数据集包含 FD001~FD004 四个子集,每个子集包含训练集和测试集,训练集包含发动机从运行到完全失效的数据;测试集为发动机性能衰退数据。C-MAPSS 数据集中的发动机及子样本数如表 1 所示。

表 1 数据集

Table 1 Data set

名称	工作状态	故障模式	训练集	测试集	训练样本	测试样本
FD001	1	1	100	100	20 630	13 095
FD002	6	1	260	259	53 759	33 991
FD003	1	2	100	100	24 720	16 596
FD004	6	2	249	248	61 249	41 214

每个数据集包含 26 维数据,分别是发动机编号、运行周期数、3 个运行参数(飞行高度、马赫数、节流解析器)和 21 个传感器测量参数。在模型训练中,并非所有参数都对预测是有帮助的,如:FD001 中 setting 3 和 sensor[1, 5, 6, 10, 16, 18, 19] 从始至终未发生变化;同样,在 FD003 中 sensors [1, 5, 16, 18, 19] 和 setting 3 也是不变的。为了减少不必要的运算,选择丢弃这些参数,FD002 和 FD004 的所有数据都用来训练。将原训练集按照 7:3 的比例划分为训练集和验证集,当模型在验证集上取得良好效果时,将模型用于测试集。

### 3.2 数据预处理

由于数据来自多个传感器,且单位不同,为消

除特征间单位差异的影响,提升模型的收敛速度和精度,需要对数据做归一化处理,将输入数据中的传感器参数和操作设置参数限制在 $[0,1]$ 之间。归一化的公式为

$$x_{i,j}^{\text{norm}} = \frac{x_{i,j} - x_j^{\text{min}}}{x_j^{\text{max}} - x_j^{\text{min}}} \quad (8)$$

式中: $x_{i,j}$ 为 $t$ 时刻第 $i$ 个发动机的第 $j$ 个传感器的数值; $x_j^{\text{min}}$ 、 $x_j^{\text{max}}$ 分别为第 $j$ 个传感器的最小值、最大值; $x_{i,j}^{\text{norm}}$ 为归一化后的值。

剩余使用寿命标签值对预测结果有较大影响。发动机在刚开始运行的阶段,各部件性能都表现良好,此阶段的退化可忽略不计。在运行一段时间后出现线性退化的情况,在线性退化阶段,按照线性函数递减的方式设置RUL阈值为125,当大于等于临界值时,RUL为恒定值;小于阈值时,RUL随周期线性减少,线性退化模型如图3所示。




图3 分段线性退化模型图

Fig. 3 Piecewise linear degradation model

在寿命预测过程中,将剩余使用寿命作为一组数据的目标输出,在训练集中的RUL计算如下:

$$R_{UL, \text{train}} = c_{\text{cycle\_max}} - c_{\text{cycle\_now}} \quad (9)$$

$$R_{UL, \text{test}} = c_{\text{cycle\_max}} + R_{UL} - c_{\text{cycle\_now}} \quad (10)$$

式中: $c_{\text{cycle\_max}}$ 为此发动机的最大运行周期数; $c_{\text{cycle\_now}}$ 为此发动机当前运行的周期; $R_{UL}$ 为真实剩余寿命。

滑动窗口使用固定长度的窗口从起点滑到终点,将长序列数据划分为若干个短序列数据,同时也能保留数据之间的前后依赖性。将固定大小的窗口沿数据集的时间维度向前滑动,把原始长时间序列数据划分为短序列数据。训练集中,取窗口的下一条数据所对应的RUL作为此窗口的剩余使用寿命标签,每个窗口输出一个预测值;测试集中取每个窗口最后一条数据对应的RUL值作为预

测结果<sup>[17]</sup>。滑窗过程如图4所示,在训练过程中取17个特征用于滑窗,图4中只取1号发动机的S2、S3、S4、S8、S9传感器为例。




图4 滑动窗口示意图

Fig. 4 Sliding window diagram

### 3.3 评价指标

为了分析模型性能,采用常用的度量指标均方根误差(Root Mean Squared Error,简称RMSE)、评分函数(Scoring Function,简称Score)作为预测效果的评价指标。

(1) 非对称评分函数Score能对超前和滞后的预测结果产生不同的惩罚,对滞后预测的惩罚高于超前预测,这种风险预防态度与航空业对发动机的预测性维护做法相吻合。 $S_{\text{core}}$ 计算公式为

$$S_{\text{core}} = \begin{cases} \sum_{i=1}^N (e^{-\frac{\hat{y}_i - y_i}{13}}) - 1 & (\hat{y}_i - y_i < 0) \\ \sum_{i=1}^N (e^{\frac{\hat{y}_i - y_i}{10}}) - 1 & (\hat{y}_i - y_i \geq 0) \end{cases} \quad (11)$$

(2)  $R_{\text{MSE}}$ 计算公式为

$$R_{\text{MSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (12)$$

式中: $\hat{y}_i$ 为发动机剩余寿命预测值; $y_i$ 为发动机剩余寿命真实值; $N$ 为发动机数量。当 $S_{\text{core}}$ 和 $R_{\text{MSE}}$ 值越小表示预测值越接近真实值,模型效果越好。

### 3.4 预测结果分析

在时间序列数据任务中,序列长度(或窗口长度)是直接关系到最终精度的最重要参数之一。然而窗口长度的选择没有确切的标准,其结果往往是主观的,本文在集合 $\{30, 40, 50, 60, 70, 80, 90, 100\}$ 中针对不同的窗口长度验证在四个数据集上的效果,结果如表2所示。

表 2 不同滑窗长度的影响  
Table 2 Influence of different sliding window lengths

滑窗长度	$R_{MSE}$				$S_{core}$			
	FD001	FD002	FD003	FD004	FD001	FD002	FD003	FD004
30	13.71	21.05	16.85	23.25	297.99	3 969.45	907.03	4 905.78
40	12.86	21.53	14.46	23.07	278.33	6 951.00	384.11	8 819.43
50	13.53	22.91	12.34	19.51	322.95	4 182.36	257.70	2 930.71
60	15.64	20.09	10.07	16.06	444.72	3 032.97	217.07	1 365.05
70	12.09	21.57	12.99	18.82	244.39	4 498.42	361.41	2 462.63
80	11.97	15.44	13.87	15.88	236.59	1 631.29	1 046.41	1 380.47
90	11.71	12.75	12.22	15.87	226.17	795.24	316.54	1 321.97
100	11.13	14.22	13.46	15.86	198.56	1 124.42	883.38	1 433.41

针对不同的卷积核尺寸、卷积核数量、膨胀系数等关键参数,使用贝叶斯调参的方法寻找最优参数,分别在不同的数据集上进行训练,最后获得最优参数组合如表 3 所示,可以看出:对于 FD001~FD004 数据集,最优的卷积核尺寸和滑窗长度分别为 [12,6,10,12],[100,90,60,100]。

表 3 模型参数  
Table 3 Parameters of model

参数	数值
卷积核数量	64
卷积核尺寸	[12,6,10,12]
膨胀系数	{1,2,4,8,16,32}
批训练量	64
迭代次数	100
早停率	3
优化器	Adam
初始学习率	0.005
滑窗长度	[100,90,60,100]

将本文模型结果与几种主流方法进行对比,如表 4 所示,可以看出:本文模型在多工况的 FD002 和 FD004 数据集上的预测效果整体不如单工况的 FD001 和 FD003 数据集,原因是多工况复杂多变的工作环境会影响提取到的传感器特征,难以挖掘传感器从运行到失效的退化规律,影响预测效果。相比之前的最优模型,本文模型在四个数据集上的  $R_{MSE}$  值分别降低了 2.7%、26.1%、1.4%、18.3%;在数据集 FD002、FD003 和 FD004 上,  $S_{core}$  值也均优于其他模型。 $R_{MSE}$  是对称指标,  $S_{core}$  是非对称指标,  $S_{core}$  加大了对剩余寿命高估行为的惩罚,综合考虑两种指标,  $R_{MSE}$  值更能从整体上体现对发动机剩余寿命的预测精度,在  $R_{MSE}$  值相近的情况下,  $S_{core}$  值更能反映对发动机剩余寿命高估和低估情况。综上,本文提出的多特征注意

力膨胀卷积模型在多工况的 FD002 和 FD004 数据集上表现效果较好,且对物理背景知识和专家经验依赖更低,具有潜在应用价值。

表 4 与目前流行方法对比  
Table 4 Comparison of with current popular methods

模型	数据集	$R_{MSE}$	$S_{core}$
CNNLSTM <sup>[7]</sup>	FD001	17.28	656.51
	FD002	28.49	6 970.07
	FD003	18.59	1 024.80
	FD004	27.09	6 548.54
LSTM <sup>[18]</sup>	FD001	15.51	593
	FD002	20.19	6 820
	FD003	12.59	280
	FD004	23.94	19 424
MS-DCNN <sup>[19]</sup>	FD001	11.44	196.22
	FD002	19.35	3 747
	FD003	11.67	241.89
	FD004	22.22	4 844
DCNN <sup>[20]</sup>	FD001	12.61	273.7
	FD002	22.36	10 412
	FD003	12.64	284.1
	FD004	23.31	12 466
CNN+ATT <sup>[21]</sup>	FD001	11.48	198
	FD002	17.25	1 144
	FD003	12.31	251
	FD004	20.58	2 072
CNN-XGB <sup>[22]</sup>	FD001	12.61	224.73
	FD002	19.61	2 525.99
	FD003	13.01	279.36
	FD004	19.41	2 930.65
本文方法	FD001	11.13	198.56
	FD002	12.75	795.24
	FD003	10.07	217.07
	FD004	15.86	1 433.41

在测试集四个数据集中分别选取第24、14、100、102号发动机验证模型效果,得到的分布曲线如图5所示,可以看出:在发动机的正常运行和退化阶段,模型对发动机剩余寿命的预测值与真实值基本吻合,表明了本文提出的模型具有较好的预测精度。

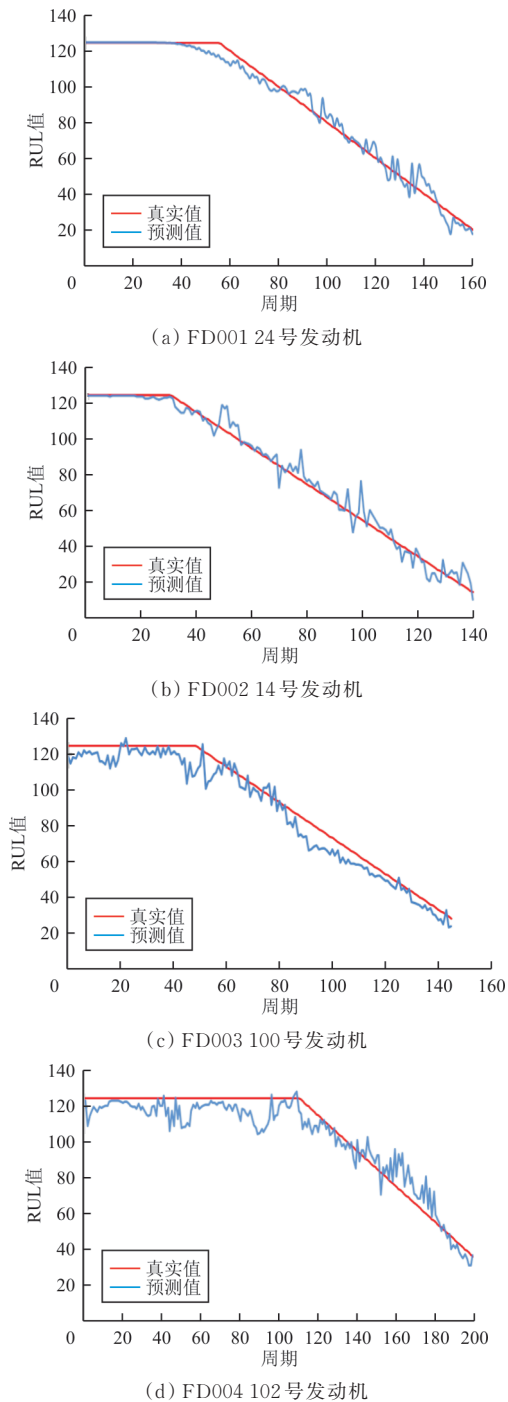


图5 测试集RUL预测值与实际值比较  
Fig. 5 The comparison between predicted RUL and actual RUL for testing engines

## 4 结论

(1) 针对航空发动机在多工况和不同故障模式下的运行状况,提出多特征注意力的膨胀卷积网络模型分别对单个特征进行信息提取,将单独提取后的特征拼接,充分考虑了单个传感器的信息。使用滑动窗口捕获更多的时序特征,有效地学习了历史数据间的依赖关系。但是TCN层数的增加也增加了模型的训练负荷,因此需要考虑如何减小多头网络结构的复杂度。

(2) 特征注意力机制通过计算出不同传感器(如风机、低压压气机、高压压气机、高压涡轮、低压涡轮等)的权重,分析不同传感器对预测结果的重要性,通过与几种主流模型的对比,证明了本文所提出的模型在发动机寿命预测方面有着良好的精度。

### 参考文献

- [1] 裴洪, 胡昌华, 司小胜, 等. 基于机器学习的设备剩余寿命预测方法综述[J]. 机械工程学报, 2019, 55(8): 1-13.  
PEI Hong, HU Changhua, SI Xiaosheng, et al. Review of machine learning based remaining useful life prediction methods for equipment [J]. Journal of Mechanical Engineering, 2019, 55(8): 1-13. (in Chinese)
- [2] 林京, 张博瑶, 张大义, 等. 航空燃气涡轮发动机故障诊断研究现状与展望[J]. 航空学报, 2022, 43(8): 1-14.  
LIN Jing, ZHANG Boyao, ZHANG Dayi, et al. Research status and prospect of fault diagnosis for gas turbine aeroengine [J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(8): 1-14. (in Chinese)
- [3] LIU Qinming, DONG Ming, LYU Wenyuan, et al. Manufacturing system maintenance based on dynamic programming model with prognostics information [J]. Journal of Intelligent Manufacturing, 2019, 30(3): 1155-1173.
- [4] LIAO Linxia, KOTTIG F. review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction [J]. IEEE Transactions on Reliability, 2014, 63(1): 191-207.
- [5] 崔利杰, 李皓祥, 李薛, 等. 航空发动机多状态寿命控制策略及仿真研究[J]. 航空工程进展, 2022, 13(5): 141-147.  
CUI Lijie, LI Haoxiang, LI Xue, et al. Research on multi-state life control strategy and simulation for aero-engine [J]. Advances in Aeronautical Science and Engineering, 2022, 13(5): 141-147. (in Chinese)
- [6] 胡启国, 白熊, 杜春超. 基于KPCA-BLSTM的航空发动机多信息融合剩余寿命预测[J]. 航空工程进展, 2022, 13(3): 157-163, 170.  
HU Qiguo, BAI Xiong, DU Chunchao. Remaining useful

- life prediction of aero-engine multi-information fusion based on KPCA-BLSTM[J]. *Advances in Aeronautical Science and Engineering*, 2022, 13(3): 157-163,170. (in Chinese)
- [7] 刘伟民, 胡忠志. 一种基于神经网络的航空发动机剩余寿命预估方法[J]. *航空发动机*, 2021, 47(3): 8-15.  
LIU Weimin, HU Zhongzhi. An aeroengine remaining useful life prediction method based on neural network[J]. *Aeroengine*, 2021, 47(3): 8-15. (in Chinese)
- [8] AYODEJI A, WANG Zhiyu, WANG Wenhai, et al. Causal augmented ConvNet: a temporal memory dilated convolution model for long-sequence time series prediction[J]. *ISA Transactions*, 2021, 153: 23-27.
- [9] MIKEL C, ISAAC T, ANGEL C, et al. Multi-head CNN-RNN for multi-time series anomaly detection: an industrial case study[J]. *Neurocomputing*, 2019, 363: 1-10.
- [10] KIM D K, SHYN S K, KIM D, et al. A daily tourism demand prediction framework based on multi-head attention CNN: the case of the foreign entrant in south korea[C]// 2021 IEEE Symposium Series on Computational Intelligence (SSCI). USA: IEEE, 2021: 1-10.
- [11] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. *Neural Computation*, 1989, 1(4): 541-551.
- [12] BAI Shaojie, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. [2022-05-05]. <https://arxiv.org/abs/1803.01271v1>.
- [13] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 1063-1069.
- [14] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[J]. *Computer Science*, 2014, 13: 5-15.
- [15] LUONG M T, PHAM H, MANNING C D. Effective approaches to attention-based neural machine translation[J]. *Computer Science*, 2015, 12: 121-131.
- [16] SAXENA A, KAI G, SIMON D, et al. Damage propagation modeling for aircraft engine run-to-failure simulation[C]// 2008 International Conference on Prognostics and Health Management. USA: IEEE, 2008: 1-12.
- [17] 王欣, 孟天宇, 周俊曦. 基于注意力与LSTM的航空发动机剩余寿命预测[J]. *科学技术与工程*, 2022, 22(7): 2784-2792.  
WANG Xin, MENG Tianyu, ZHOU Junxi. Remaining useful life prediction for aircraft engine using attention based LSTM[J]. *Science Technology and Engineering*, 2022, 22(7): 2784-2792. (in Chinese)
- [18] MIRANDA A, BARBOSA T, CONCEICAO A, et al. Recurrent neural network based on statistical recurrent unit for remaining useful life estimation[C]// 2019 The 8th Brazilian Conference on Intelligent Systems (BRACIS). Salvador, Brazil: [s. n.], 2019: 1-15.
- [19] LI Han, ZHAO Wei, ZHANG Yuxi, et al. Remaining useful life prediction using multi-scale deep convolutional neural network[J]. *Applied Soft Computing*, 2020, 89: 106113.
- [20] LI Xiang, DING Qian, SUN Jianqiao. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. *Reliability Engineering & System Safety*, 2018, 172: 1-11.
- [21] WEI M T, TEO T H. Remaining useful life prediction using temporal convolution with attention[J]. *Artificial Intelligence*, 2021, 2(1): 48-70.
- [22] ZHANG Xiaoyong, XIAO Pengcheng, YANG Yingze, et al. Remaining useful life estimation using CNN-XGB with extended time window[J]. *IEEE Access*, 2019, 99: 1-17.

#### 作者简介:

王欣(1973—),男,博士,教授。主要研究方向:机器学习,计算机仿真。

黄佳琪(1996—),男,硕士研究生。主要研究方向:机器学习。

孟天宇(1996—),男,硕士研究生。主要研究方向:自然语言处理。

李屹(1999—),男,硕士研究生。主要研究方向:机器学习。

(编辑:马文静)