

文章编号: 1000-8055(2023)05-1176-09

doi: 10.13224/j.cnki.jasp.20210728

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

陈保家^{1,2}, 郭凯敏¹, 陈法法^{1,2}, 肖文荣¹, 李公法³, 陶 波³

- (1. 三峡大学 水电机械设备设计与维护湖北省重点实验室, 湖北 宜昌 443002;
2. 重庆大学 机械传动国家重点实验室, 重庆 400030;
3. 武汉科技大学 冶金装备及其控制教育部重点实验室, 武汉 430081)

摘 要: 针对长短期记忆(LSTM)网络对于多维数据特征识别和提取上存在不足的问题,在其改进模型嵌套式长短期记忆(NLSTM)网络的基础上,提出了一种基于注意力机制和残差 NLSTM 网络的剩余使用寿命预测方法。该方法将双层 NLSTM 网络代替残差块中的主网络,保留捷径连接中的卷积神经网络结构,既能充分提取时序特征又能保证有用数据在网络层中的跳层传递,并融入注意力机制构建多层残差网络,注意力机制的使用能够选择出对预测结果有重要影响的信息,有效提高预测的准确率。在航空发动机退化实验数据集上进行实验分析,结果表明:所述方法能有效建立监测数据与发动机健康状态之间的关系,剩余使用寿命预测误差较未改进残差结构方法平均降低 10.8%,比未融入注意力机制方法平均降低 18.9%,有效提高了预测精度。

关 键 词: 残差网络; 剩余使用寿命; 注意力机制; 预测模型; 嵌套式长短期记忆神经网络

中图分类号: V240.2

文献标志码: A

Prediction of remaining useful life of aero-engine based on residual NLSTM neural network and attention mechanism

CHEN Baojia^{1,2}, GUO Kaimin¹, CHEN Fafa^{1,2}, XIAO Wenrong¹, LI Gongfa³, TAO Bo³

- (1. Hubei Key Laboratory of Hydroelectric Machinery Design and Maintenance,
China Three Gorges University, Yichang Hubei 443002, China;
2. State Key Laboratory of Mechanical Transmissions,
Chongqing University, Chongqing 400030, China;
3. Key Laboratory of Metallurgical Equipment and Control Units, Ministry of Education,
Wuhan University of Science and Technology, Wuhan 430081, China)

Abstract: The remaining useful life prediction method based on attention mechanism and residual nested long-short-term memory (NLSTM) neural network was employed to address the shortcomings of traditional long-short-term memory (LSTM) neural network in the recognition and extraction of multi-dimensional data features. Two NLSTM neural network layers were used to replace the main structure of

收稿日期: 2021-12-27

基金项目: 国家自然科学基金(51975324, 52075292); 机械传动国家重点实验室开放基金(SKLM-T-MSKFKT-202020);

水电机械设备设计与维护湖北省重点实验室(三峡大学)开放基金(2020KJX02, 2021KJX02, 2021KJX13);

武汉科技大学冶金装备及其控制教育部重点实验室开放基金(MECOMF2021B04)

作者简介: 陈保家(1977—), 男, 教授, 博士, 研究方向为机械装备状态监测、故障诊断及可靠性评估与寿命预测。

通信作者: 陈法法(1983—), 男, 教授, 博士, 研究方向为机电设备检测与智能运维、工业自动化及机器人控制。E-mail: chenfafa2005@126.com

引用格式: 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 Baojia, GUO Kaimin, CHEN Fafa, et al. Prediction of remaining useful life of aero-engine based on residual NLSTM neural network and attention mechanism[J]. Journal of Aerospace Power, 2023, 38(5): 1176-1184.

the residual block, and the shortcut connection of the one-dimensional convolutional network in the residual block was retained, which can fully extract the temporal feature and use the jump layer to transfer useful data in the network layer. The method also added the attention mechanism to construct multilayer network, and the important information influencing the result of prediction can be chosen to improve the prediction accuracy by the attention mechanism. The proposed method was verified by experiments in the aero-engines degradation dataset. The results showed that the method can effectively establish the relationship between the monitoring data and the engines health. The prediction error was reduced by 10.8% compared with the method without residual structure and reduced 18.9% compared with the method without attention mechanism, which improved the prediction accuracy effectively.

Keywords: residual network; remaining useful life; attention mechanism; prediction model; nested long-short-term memory neural network

故障预测和健康管理(prognostics and health management, PHM)能够为机械设备的安全高效运行提供关键合理的技术支撑和安全保障。健康预测是 PHM 的主要任务之一,旨在利用设备运行状态信息揭示设备性能退化规律从而预测其有效剩余使用寿命(remaining useful life, RUL)。数据驱动的 PHM 预测方法可根据对象的状态监测数据直接对机械设备的 RUL 进行预测。预测过程先将传感器采集的监测数据转化为表达设备退化趋势的健康指标(health index, HI),然后采用线性回归、机器学习等数学模型结合相应的失效阈值对设备进行 RUL 预测,一般分为数据预处理、特征提取与 HI 构建、数据预测与 RUL 估计四个步骤^[1]。

目前主流的数据驱动 RUL 预测模型分为统计模型、浅层机器学习模型和深度学习模型。基于深度学习模型的 RUL 预测方法能够利用模型对输入的多维监测数据进行深度特征提取从而实现对设备的健康评估。在大量的监测数据条件下,深度学习方法的 RUL 预测效果较好^[2],并且在机械 RUL 预测领域已有广泛应用。Badu 等^[3]使用深度卷积网络(DCNN)做多通道时间序列的数据特征提取,将特征输入回归模型中预测航空发动机的 RUL。Zheng 等^[4]采用长短期记忆(LSTM)网络增强数据特征之间的时间依赖关系,用于航空发动机的 RUL 预测。Wang 等^[5]为充分提取时间序列的深度隐藏特征,采用双向 LSTM 的方法用于航空发动机 RUL 预测。Ellefsen 等^[6]将半监督的预训练方法与 LSTM 相结合,利用遗传算法优化网络参数,实现了在训练数据标签不完全情况下的航空发动机 RUL 预测。Yu 等^[7]使用无监督方式训练双向循环神经网络的自动编码器来构建一维 HI,并使用相似性的曲线匹配方法估计航

空发动机的 RUL。朱霖等^[8]通过增加改进的残差块结构,结合采用遗传算法的集成学习技术实现航空发动机的 RUL 预测。牟含笑等^[9]将连续深度置信网络(CDBN)用于退化 HI 构建,结合双向 LSTM 实现对航空发动机 RUL 做出预测。叶瑞达等^[10]将双层残差网络用于卷积神经网络(convolutional neural networks, CNN)和 LSTM 网络中,构建卷积记忆残差注意力网络(CMRSA)对航空发动机作 RUL 预测。

上述研究中,更偏重于数据的深层特征或 HI 的构建,对于原始输入数据对预测的影响以及时间序列特征提取的充分性未作考虑。Cai 等^[11]在永磁同步电动机的研究中使用了嵌套式长短期记忆(NLSTM)网络作温度预测,有效提高了温度变化之间时间依赖性的特征提取能力。NLSTM 为 LSTM 的嵌套形式,分为内外部两个 LSTM 单元层级,信息传输依靠内外部两层单元结构先后进行权重更新和数据传递,能够更加深入挖掘设备监测数据所包含的时序信息。因此,本文提出了一种使用 NLSTM 网络对残差网络结构改进,并且融合注意力机制进行 RUL 预测的方法。该方法将双层 NLSTM 网络代替残差块中的主网络,保留捷径连接中的 CNN 结构,既能充分提取时序特征又能保证有用数据在网络层中的跳层传递,注意力机制的使用能够选择出对预测结果有重要影响的信息,有效提高预测的准确率。通过选用美国宇航局(NASA)航空涡扇发动机退化数据集完成了 RUL 预测方法的实验验证。

1 方法理论

1.1 NLSTM 网络

NLSTM 网络^[12]为 LSTM 网络的改进形式,其单元结构由两个 LSTM 单元嵌套连接,使得传

入的信息在网络单元内部增加了一次循环。如图 1 所示为 NLSTM 网络的结构图,其中虚线框内为外部层级的 LSTM 记忆单元,虚线框外为内部层级的 LSTM 记忆单元,它用来储存外部层级传入的参数更新和长期信息。




图 1 NLSTM 网络结构

Fig. 1 Structure of NLSTM neural network

LSTM 计算时流程与 NLSTM 的外部层级的单元相同,首先利用上一时刻的输出状态 h_{t-1} 和当前时刻输入 x_t 计算遗忘门 f_t 、输入门 i_t 与输出门 o_t ;然后,结合 f_t 与 i_t 直接更新记忆单元 C_t , 遗忘门用于控制上一时刻的 C_{t-1} 传递至当前时刻 C_t 时需要遗忘的信息,输入门控制上一单元需要保留到 C_t 的信息;最后,输出门 o_t 将当前时刻状态 C_t 传递给输出状态 h_t 。NLSTM 的改进之处为外部层级与内部层级之间增加候选状态 $\tilde{h}_{t-1}$ 和 $\tilde{x}_t$ 。 $\tilde{h}_{t-1}$ 和 $\tilde{x}_t$ 通过外部层级的遗忘门 f_t 和输入门 i_t 更新后作为内部层级的隐藏状态参数和输入进入内部层级计算,其计算流程表达如下:

$$\tilde{f}_t = \sigma(\tilde{W}_f \cdot [\tilde{h}_{t-1}, \tilde{x}_t] + \tilde{b}_f) \quad (1)$$

$$\tilde{i}_t = \sigma(\tilde{W}_i \cdot [\tilde{h}_{t-1}, \tilde{x}_t] + \tilde{b}_i) \quad (2)$$

$$\tilde{o}_t = \sigma(\tilde{W}_o \cdot [\tilde{h}_{t-1}, \tilde{x}_t] + \tilde{b}_o) \quad (3)$$

$$\tilde{x}_t = i_t \otimes \tanh(W_c \cdot [x_t, h_{t-1}] + b_c) \quad (4)$$

$$\tilde{h}_{t-1} = f_t \otimes C_{t-1} \quad (5)$$

$$\tilde{C}_t = \tilde{f}_t \otimes \tilde{C}_{t-1} + \tilde{i}_t \otimes \tilde{c}_t \quad (6)$$

其中 $\tilde{W}_f$ 、 $\tilde{W}_i$ 、 $\tilde{W}_o$ 和 W_c 代表权重矩阵, $\tilde{b}_f$ 、 $\tilde{b}_i$ 、 $\tilde{b}_o$ 和 b_c 代表偏置, σ 为 Sigmoid 激活函数。当内部记忆

单元计算结束后,外部 LSTM 单元中状态更新,为最终结果输出:

$$C_t = \tilde{o}_t \otimes \tanh \tilde{C}_t \quad (7)$$

$$h_t = o_t \otimes \tanh C_t \quad (8)$$

图 2 给出了 LSTM 和 NLSTM 的计算图,可直观看出 NLSTM 网络中前一时刻隐藏状态可以直接影响当前时刻内部记忆单元的内容,而只通过外部记忆单元才能影响当前时刻隐藏状态的内容。因此,输入的数据在 NLSTM 中可以得到充分学习,能够有效获取数据之间时间依赖性。




图 2 LSTM 与 NLSTM 计算图

Fig. 2 Calculation graph of LSTM and NLSTM

1.2 传统残差网络

神经网络层数过多时,容易出现过拟合和梯度弥散问题,残差网络^[13](residual networks, Res-Net)通过引入残差块结构解决了此问题,残差块增加了网络层之间的跳层结构,这种跳层结构为捷径连接,它将单元的输入数据直接向后传递,然后与输出相加后再经过 Relu 激活函数得到最后结果,实现了数据在多层权重层传递后仍能保持特征的有效表达,避免信息丢失,其主要结构如图 3 所示。

残差块中的权重层一般为 CNN,通过设置不同的网络层参数来实现特征提取,输入数据经过




图 3 残差块结构

Fig. 3 Structure of residual block

权重层向后传递与从捷径连接直接传递的数据相加, 该过程表达为

$$H(\mathbf{x}_t) = F(\mathbf{x}_t) + \mathbf{x}_t \quad (9)$$

其中 $\mathbf{x}_t$ 为输入, $H(\mathbf{x}_t)$ 为期望的特征信息的输出, 数据因经过权重层数据减少, 因此 $F(\mathbf{x}_t)$ 为残差。

1.3 注意力机制

普通的注意力机制 (attention mechanism)^[14] 通过对输入数据分配不同的权重, 增强关键信息对结果的贡献, 提高网络模型的计算性能。注意力机制对输入的特征赋予不同权重, 使包含重要信息的特征不会随着步长的增大而消失, 从而突出重要信息的影响, 使模型更容易捕获序列数据的长距离依赖性。如图 4 所示为注意力机制模型。




图 4 注意力机制

Fig. 4 Attention mechanism

注意力机制计算步骤为: 首先通过得分函数计算输入特征的注意力分布, 然后通过指数函数 (softmax) 对得分函数作数值转换, 最后根据权重系数加权求和。设有一组来自上一网络层的 N 维输出向量 $\mathbf{Y} = [y_1, y_2, \dots, y_N]$ 作为 attention 层的输入, 为进一步选择对结果影响大的特征, 引入一组与结果相关的查询向量 $[q_1, q_2, \dots, q_N]$ 与打分函数 g , 通过打分函数计算每个输入向量和查询向量之间的相关性得到对应的分值 $[s_1, s_2, \dots, s_N]$, 用 softmax 函数作归一化处理将分值转化为权重之和为 1 的概率分布, 计算公式如下所示:

$$\alpha_i = p(n=i|\mathbf{Y}, \mathbf{q}) = \frac{\exp[g(y_i, q)]}{\sum_{j=1}^N \exp[g(y_j, q)]} \quad (10)$$

式中 $z=i$ 表示第 i 个输入向量, 且 $z \in [1, N]$; α_i 为查询向量在各个输入向量上的注意力分布, 即第 i 个输入向量在下一步被使用的概率; $g(x_i, q)$ 为注意力打分函数, 用来计算两个向量的相似程度, 为加性计算, 公式如下:

$$g(x_i, q) = \mathbf{V}^T \tanh(\mathbf{W}_a x_i + \mathbf{U} q) \quad (11)$$

式中 $\mathbf{W}_a$ 、 $\mathbf{U}$ 、 $\mathbf{V}^T$ 为可学习参数矩阵。最后根据注意力分布 α_i 可以有选择地从输入向量中提取信息, 以加权求和方式得到注意力值 a 并输出, 公式如下:

$$a = \sum_{i=1}^N \alpha_i y_i \quad (12)$$

2 发动机 RUL 预测模型

2.1 改进的 ResNLSTM-attention 残差网络

传统残差结构多采用卷积网络, 将一维 CNN 用于序列类的数据处理, 当输入数据带有明显的时间信息时, 提取数据特征能力在预测模型中效果欠佳。相对地, LSTM 网络能够处理和预测时间序列中间隔和延迟长短不同的重要信息, 通过门控机制进行参数更新, 预测效果较好。

本文所提方法利用双层 NLSTM 网络作为残差块内主体网络, 代替传统残差结构内部的 CNN 进行特征提取和预测, 并保留一维 CNN 结构作为残差块的捷径连接, 向后面网络构建跳层连接, 组成 NLSTM 的残差块结构, 如图 5 中虚线框内所示。再将残差块堆栈组成 NLSTM 的残差结构 (ResNLSTM) 网络, 堆栈方式组成的多层残差网络能够利用 NLSTM 的嵌套结构有效进行深层特征提取, 并且有更多循环单元来获取各时间点特征的依赖关系, 使得网络学习更加充分。此网络改进方法能充分利用卷积神经网络对于特征提取的敏感性和 NLSTM 网络对于时间序列的预测优势。

图 5 所示为 ResNLSTM-attention 网络整体结构图, 其中 ResNLSTM 网络层后加入了 attention 层进行优化, 因为不同时刻的特征对于下一时刻 RUL 预测的贡献程度不同, 通过利用 attention 层的自我调节功能增强下一时刻预测效果, 增大重要时刻特征对 RUL 预测的权重, 组成 ResNLSTM-attention 网络。Attention 层后使用全连接层对预测结果作映射输出, 得到最终的 RUL 结果。

2.2 基于 ResNLSTM-attention 的 RUL 预测

RUL 预测流程包括数据预处理、网络训练和网络测试三个部分, 其中网络训练用的 ResNLSTM-




图 5 ResNLSTM-attention 网络

Fig. 5 ResNLSTM-attention network

attention 网络模型由输入层、特征提取层、NLSTM 残差网络层、注意力层和全连接层构成。图 6 所示为 RUL 的整体预测流程。

首先,在数据预处理阶段,按照输入数据退化信息的表征能力强弱进行特征选择,对所选数据




图 6 ResNLSTM-attention RUL 预测流程图

Fig. 6 Flow chart of ResNLSTM-attention RUL prediction

进行归一化处理,添加分段退化 RUL 标签并对输入数据做时间步划分,构建模型输入样本。特征提取通过改进的 ResNLSTM 网络实现,其中一维 CNN 的跳层结构能保留重要信息向后传递,防止信息损失,增强特征提取的性能,将处理过的训练集划分出验证集在网络训练时进行参数更新。

模型训练阶段中的标签为每组时间序列的下一个时刻所对应的 RUL 值,训练时使用 Keras 中早停机制(early stopping)防止出现过拟合情况,网络通过多次迭代训练,根据验证集损失函数反映训练情况,并更新网络中的权重矩阵,最后得到训练好的网络模型。在测试阶段,将测试集输入到训练好的 ResNLSTM-attention 网络中,得到 RUL 的预测结果。

3 实验验证

航空发动机的健康状态监测评估是保障飞机安全飞行的重要手段。航空发动机具有结构复杂、状态检测变量类型多、数据量大、维度高的特点。本文使用 NASA 提供的航空涡扇发动机退化实验数据集(C-MAPSS)^[15]对所提预测方法进行验证。

3.1 实验数据预处理及评价指标

C-MAPSS 数据集模拟了涡扇发动机在不同操作条件和故障模式下的退化情况,数据集中包含 FD001~FD004 四个子数据集,每个子数据集由一个训练集和测试集组成,如表 1 所示。

表 1 C-MAPSS 数据集描述

Table 1 Description of C-MAPSS dataset

数据集	训练集 (发动机数量)	测试集 (发动机数量)	操作 条件	故障 模式
FD001	100	100	1	1
FD002	260	259	6	1
FD003	100	100	1	2
FD004	248	249	6	2

训练集中包含多个发动机从正常到失效的全寿命数据,测试集包括大量在故障前结束的不完整数据,用于 RUL 测试。训练集或测试集中的每个发动机数据由 26 个多变量时间序列组成,其中第 1 个变量表示发动机序号,第 2 个变量表示以循环周期(t)为单位的工作时间,第 3 至第 5 个变量表示对发动机性能有显著影响的 3 个工作参数(高度、马赫数和海平面温度),其余 21 个变量代表 21 个不同传感器的监测数据。

1) 特征选择

使用全部发动机数据集进行验证,选择表征

发动机明显退化趋势的传感器数据作为样本输入, 为了降低计算复杂度, 本文采用文献 [16] 中评价指标, 利用单调性和相关性强的数据特征体现退化信息。数据和 RUL 预测的相关程度与两个指标呈正相关, 通过计算两者的线性组合来选择合理的传感器数据, 计算方法如下:

$$M_i = \left| \frac{dz^{(i)} > 0}{T-1} - \frac{dz^{(i)} < 0}{T-1} \right| \quad (13)$$

$$C_i = \frac{\left| \sum_{t=1}^T [(z_t^{(i)} - \bar{z}_t^{(i)}) (t - \bar{t})] \right|}{\sqrt{\sum_{t=1}^T (z_t^{(i)} - \bar{z}_t^{(i)})^2 \sum_{t=1}^T (t - \bar{t})^2}} \quad (14)$$

$$L_i = \beta C_i + (1 - \beta) M_i \quad (15)$$

式中 T 为全寿命周期的时间序列长度; $z^{(i)}$ 为第 i 列的时间序列, i 属于 $\{1, 2, \dots, 21\}$; t 为时间步长; $\bar{t}$ 为平均值, $dz^{(i)}$ 表示 $z^{(i)}$ 的微分; β 为权重系数, 属于 $[0, 1]$ 。通过对整个子集计算平均值得到 L_i 并选择大于 0 的数据作为模型输入。

2) RUL 分段设置标签

发动机各性能监测变量在退化初期均变化较小, 因此提取的 HI 在退化初期变化缓慢。为了提高模型预测的准确性, 假定发动机在运行初期无退化, 其寿命始终为一常数值; 当大于此常数值时, 才开始退化, 发动机寿命变为实际值。此方法划分 RUL 标签为分段线性^[17]退化, 其中常数值设为发动机的平均寿命 125 个循环周期。

3) 评价指标

为了衡量所提预测模型的优劣, 本文选取常用的两个性能度量指标: 评分函数(score function, S_f)和方均根误差(root mean square error, σ_{rms})对 RUL 预测效果进行评价。 S_f 的计算公式为

$$S_f = \begin{cases} \sum_{i=1}^N \left[\exp\left(-\frac{r_i}{13}\right) - 1 \right] & r_i < 0 \\ \sum_{i=1}^N \left[\exp\left(-\frac{r_i}{10}\right) - 1 \right] & r_i \geq 0 \end{cases} \quad (16)$$

$$r_i = l' - l_i \quad (17)$$

其中 l' 为 RUL 预测值, l_i 为 RUL 真实值, r_i 为预测得差值。 σ_{rms} 可以衡量全测试循环数据序列的预测结果, 其计算公式为

$$\sigma_{\text{rms}} = \sqrt{\frac{1}{N} \sum_{i=1}^N r_i^2} \quad (18)$$

评分函数和方均根误差的数值越小代表预测效果越好。

3.2 实验过程

对发动机数据集原始输入数据进行预处理和特征选择。对于 FD001 与 FD003 数据集, 共 14 个传感器数据能够明显表征发动机退化趋势; 对于 FD002 与 FD004 数据集, 共有 21 个传感器对发动机剩余使用寿命预测的贡献度较高, 因此在构建输入样本时, 选择对应的传感器数据作为输入。

将数据集的训练集与测试集设置滑动时间窗口长度为 36, 对数据序列最小最大归一化后再将数据集中寿命标签与训练集和测试集进行匹配, 并按照退化阶段进行线性划分, 寿命周期的最大值设为 125。

预处理过的数据输入到 ResNLSTM-attention 模型中进行预测, 划分验证集进行参数更新, 在训练过程中使用均方误差(mean squared error, σ_{ms})作为损失函数(loss)评价网络中预测值的偏离程度, 如式(19)所示。

$$\sigma_{\text{ms}} = \frac{1}{N} \sum_{i=1}^N r_i^2 \quad (19)$$

利用早停机制防止过拟合, 在取得网络训练参数最优时提前停止训练。网络训练中用 RMS-Prop 算法进行优化, 初始学习率为 0.01, 并使用 Keras 中的 Reduce LR on Plateau 回调函数对训练过程的学习率进行梯度更新。网络模型具体参数与数据输出尺寸如表 2 所示。

表 2 ResNLSTM-attention 网络参数

Table 2 ResNLSTM-attention network parameters

网络层	层参数	输出尺寸
输入层	时间步: 36	(36, 14)
NLSTM 层	单元数: 14	(36, 14)
Conv1D 层	单元数: 14, 核尺寸: 1	(36, 14)
NLSTM 层	单元数: 7	(36, 7)
Conv1D 层	单元数: 7, 核尺寸: 1	(36, 7)
Attention 层	单元数: 32	(36, 7)
Attention 输出层	单元数: 32	(None, 32)
Dense 层	单元数: 1	(None, 1)

训练过程中, 数据每批次输入大小为 128, 由于采用早停机制在最优结果时停止训练, 迭代次数设置上限为 600, 一般训练过程在 100 次迭代以内均能达到最佳效果。

3.3 实验结果分析

通过对 FD001、FD002、FD003 和 FD004 子数据集的发动机 RUL 进行预测, 每个子集进行三次有效实验, 得出每次预测的评分函数值和方均根误差, 并计算平均值, 具体结果如表 3 与表 4 所示。

表 3 方均根误差结果

Table 3 Result of root mean square error

子数据集	σ_{rms}			平均值
	第 1 次	第 2 次	第 3 次	
FD001	12.52	12.50	12.56	12.53
FD002	19.37	20.34	21.82	20.51
FD003	11.94	12.03	12.48	12.15
FD004	22.29	20.99	23.80	22.36

表 4 评分函数结果

Table 4 Result of score function

子数据集	S_f			平均值
	第 1 次	第 2 次	第 3 次	
FD001	279	259	257	265
FD002	761	496	2 328	1 195
FD003	249	258	345	284
FD004	3 444	1 724	2 907	2 692

为了验证 ResNLSTM-attention 模型的性能, 将其与未改进残差网络的 NLSTM-attention 模型和未融入 attention 机制的 ResNLSTM 进行验证对比, 实验预测结果如表 5 所示。通过比较计算可得, 在四个数据集子集的 RUL 预测效果上, 本文所提 ResNLSTM-attention 方法的最优结果比未改进为残差结构的 NLSTM-attention 准确率分别提高 7.3%、17.4%、5.1% 和 13.2%; 比没有融入 attention 的 ResNLSTM 方法准确率分别提高 18.4%、13.4%、28.4% 和 15.4%。预测误差较未改进残差结构方法平均降低 10.8%, 比未融入注意力机制方法平均降低 18.9%。因此, 通过将 NLSTM 网络改为残差结构和融入 attention 能够有效提高 RUL 预测准确率。

表 5 C-MAPSS 数据集消融实验结果对比

Table 5 Comparison of the results of ablation experiments in the C-MAPSS dataset

方法	FD001	FD002	FD003	FD004
NLSTM-attention	13.49	24.61	12.58	24.18
ResNLSTM	15.32	23.50	16.68	24.80
本文方法预测平均值	12.53	20.51	12.15	22.36
本文方法预测最优值	12.50	20.34	11.94	20.99

为验证所提方法在航空发动机 RUL 预测的有效性, 将其与文献 [3]、文献 [4]、文献 [6]、文献 [7]、文献 [9] 和文献 [18-20] 所提方法的预测效果进行对比, 方均根误差结果对比如表 6 所示, 评分函数结果对比如表 7 所示。

表 6 C-MPASS 数据集下不同方法的方均根误差结果对比

Table 6 Comparison of root mean square error results of different methods in the C-MPASS dataset

方法	σ_{rms}			
	FD001	FD002	FD003	FD004
CNN ^[3] , 2016	18.45	30.29	19.82	29.16
LSTM-FNN ^[4] , 2017	16.14	24.49	16.18	28.17
RBM-LSTM-FNN ^[6] , 2019	12.56	22.73	12.10	22.66
Auto-Encoder ^[7] , 2019	14.74	22.07	17.48	23.49
CMRSA ^[9] , 2021	15.00	23.22	17.23	23.74
CNN-FNN ^[19] , 2018	12.61	22.36	12.64	22.43
Auto-Encoder ^[20] , 2020	13.58	19.59	19.16	22.15
DCNN-FNN ^[21] , 2020	12.61	28.51	12.62	30.73
本文方法预测平均值	12.53	20.51	12.15	22.36
本文方法预测最优值	12.50	20.34	11.94	20.99

表 7 C-MPASS 数据集下不同方法的评分函数结果对比

Table 7 Comparison of score function results of different methods in the C-MPASS data set

方法	S_f			
	FD001	FD002	FD003	FD004
CNN ^[3] , 2016	1 290	13 570	1 596	7 886
LSTM-FNN ^[4] , 2017	338	4 450	852	5 550
RBM-LSTM-FNN ^[6] , 2019	231	3 370	251	2 840
Auto-Encoder ^[7] , 2019	273	3 099	574	3 202
CMRSA ^[9] , 2021	381	21 766	994	13 564
DBN ^[18] , 2017	640	10 851	683	7 210
CNN-FNN ^[19] , 2018	274	10 412	284	12 466
Auto-Encoder ^[20] , 2020	220	2 650	1 727	2 901
本文方法预测平均值	265	1 195	284	2 692
本文方法预测最优值	257	496	249	1 724

由表 6 可得本文所提方法在所有子集上预测的 σ_{rms} 最优值比文献 [3] 方法的结果分别提高 32.3%、32.8%、39.8% 和 28.0%; 比文献 [4] 中的结果分别提高 22.6%、16.9%、26.2% 和 25.5%; 比文献 [5] 中的结果分别提高了 0.5%、10.5%、1.3% 和 7.4%; 比文献 [7] 中结果分别提高 15.2%、7.8%、31.7% 和 10.7%; 相比于文献 [9] 中结果分别提高了 16.7%、12.4%、30.7% 和 11.6%; 比文献 [19] 中的结果分别提高 0.9%、9.0%、5.5% 和 6.4%。在文献 [20] 所用预测方法中, 对于 FD002 数据集预

测结果的 σ_{rms} 值要优于本文所提方法, 但 FD003 数据集本文方法结果比其提高 37.7%, 其余数据集结果分别提高 8.0% 和 5.2%; 相比于文献 [21] 结果分别提高 0.9%、28.7%、5.4% 和 31.7%。比较表 7 中结果得出, 本文所提方法在 S_f 的最优结果上, 尤其是在 FD002 数据集的预测上比所有文献均提高 80% 以上, 在 FD004 数据集上均提高在 39.3%~78.1% 之间, 效果明显; 在 FD001 数据集的表现中略高于文献 [6] 与文献 [20], 比文献 [3]、文献 [4]、文献 [7]、文献 [9]、文献 [18]、文献 [19] 分别提高 80.0%、24.0%、5.9%、32.5%、59.8% 和

6.2%; 在 FD003 数据集的表现上, 比其他文献分别提高 84.4%、70.8%、0.8%、56.6%、74.9%、63.5%、12.3% 和 85.6%。通过以上结果充分证明本文所提方法的有效性, 而且相较于传统 CNN、LSTM 和自编码器的方法, 使用多网络组合且引入注意力机制的方法效果更好。

为进一步观察本文所提方法预测效果, 图 7 展示了两个子数据集所有发动机 RUL 预测值和实际值的对比结果, 可以看出两者误差极小, 满足对退化的预测精度要求。图 8 给出了部分测试发动机的全测试循环 RUL 预测结果, 这里选取测




图 7 不同数据集的所有发动机 RUL

Fig. 7 All engines RUL in different dataset




图 8 发动机 RUL 预测过程

Fig. 8 Engine RUL prediction process

试循环比较多的四台发动机单元,分别为第24号、34号、76号和第100号发动机,给出其一次全测试循环的全寿命退化预测结果,能够清楚看出本文所用方法在单个发动机的RUL预测中也具有一定优势,退化趋势拟合较好。

4 结 论

本文针对传统LSTM在航空发动机RUL预测中特征识别和提取不充分的问题,构建了基于NLSTM的残差网络模型并融入了attention机制,网络训练过程中使用早停机制和学习率优化算法对预测模型改进,提升了RUL预测性能,得到如下结论:

1) 采用NLSTM改进残差块结构和CNN捷径连接的方式,既保留了LSTM的记忆特性,利用网络单元的嵌套结构充分学习退化特征,也保留了有效特征的向后传递,解决特征学习不充分的问题。

2) 采用attention机制对网络中输入的特征按照不同权重进行筛选,充分利用重要的数据信息,提高RUL预测精度。

3) 通过实验证明了本文所提ResNLSTM-attention方法在预测航空发动机RUL中能够降低预测误差,对比其他文献方法具有一定优势。

参考文献:

- [1] 彭宇, 刘大同. 数据驱动故障预测和健康管理综述[J]. 仪器仪表学报, 2014, 35(3): 481-495.
PENG Yu, LIU Datong. Data-driven prognostics and health management: a review of recent advances[J]. Chinese Journal of Scientific Instrument, 2014, 35(3): 481-495. (in Chinese)
- [2] LEI Yaguo, LI Naipeng, GUO Liang, et al. Machinery health prognostics: a systematic review from data acquisition to RUL prediction[J]. Mechanical Systems and Signal Processing, 2018, 104(5): 799-834.
- [3] BABU G S, ZHAO Peilin, LI Xiaoli. Deep convolutional neural network based regression approach for estimation of remaining useful life[C]// International Conference on Database Systems for Advanced Applications. Cham, Switzerland: Springer, 2016: 214-228.
- [4] ZHENG Shuai, RISTOVSKI K, FARAHAT A, et al. Long short-term memory network for remaining useful life estimation[C]// IEEE International Conference on Prognostics and Health Management (ICPHM). Dallas, US: IEEE, 2017: 88-95.
- [5] WANG Jiujian, WEN Guilin, YANG Shaopu, et al. Remaining useful life estimation in prognostics using deep bidirectional lstm neural network[C]// Prognostics and System Health Management Conference (PHM-Chongqing). Chongqing, China: IEEE, 2018: 1037-1042.
- [6] ELLEFSEN A L, BJORLYKHAUG E, AESOY V, et al. Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture[J]. Reliability Engineering and System Safety, 2019, 183(3): 240-251.
- [7] YU W, KIM I 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(8): 764-780.
- [8] 朱霖, 宁芊, 雷印杰, 等. 基于遗传算法选优的集成手段与时序卷积网络的涡扇发动机剩余寿命预测[J]. 计算机应用, 2020, 40(12): 3534-3540.
ZHU Lin, NING Qian, LEI Yinjie, et al. Remaining useful life prediction for turbofan engines by genetic algorithm-based selective ensembling and temporal convolutional network[J]. Journal of Computer Applications, 2020, 40(12): 3534-3540. (in Chinese)
- [9] 牟含笑, 郑建飞, 胡昌华, 等. 基于CDBN与BiLSTM的多元退化设备剩余寿命预测[J/OL]. [2022-06-27]. <http://kns.cnki.net/kcms/detail/11.1929.v.20210510.1354.004.html>.
- [10] 叶瑞达, 王卫杰, 何亮, 等. 基于残差自注意力机制的航空发动机RUL预测[J]. 光学精密工程, 2021, 29(6): 1482-1490.
YE Ruida, WANG Weijie, HE Liang, et al. RUL prediction of aero-engine based on residual self-attention mechanism[J]. Optics and Precision Engineering, 2021, 29(6): 1482-1490. (in Chinese)
- [11] CAI Yongping, CEN Yuefeng, CEN Gang, et al. Temperature prediction of PMSMs using pseudo-siamese Nested LSTM[J]. World Electric Vehicle Journal, 2021, 12(2): 57-71.
- [12] MONIZ J R A, KRUEGER D. Nested LSTMs[C]// Asian Conference on Machine Learning. Seoul, Korea: The Journal of Machine Learning Research, 2017: 530-544.
- [13] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C]// European Conference on Computer Vision. Cham, Switzerland: Springer, 2016: 630-645.
- [14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach, US: Curran Associates Inc, 2017: 5998-6008.
- [15] 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. Denver, US: IEEE, 2008: 1-9.
- [16] WU Yuting, YUAN Mei, DONG Shaopeng, et al. Remaining useful life estimation of engineered systems using vanilla LSTM neural networks[J]. Neurocomputing, 2018, 275(1): 167-179.
- [17] HEIMES F O. Recurrent neural networks for remaining useful life estimation[C]// 2008 International Conference on Prognostics and Health Management. Denver, US: IEEE, 2008: 6-12.
- [18] CHONG Z, LIM P, QIN A K, et al. Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics[J]. Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2306-2318.
- [19] LI Xiang, DING Qian, SUN Jianqiao. Remaining useful life estimation in prognostics using deep convolution neural networks[J]. Reliability Engineering and System Safety, 2018, 172(4): 1-11.
- [20] YU W, KIM I Y, MECHEFSKE C. An improved similarity-based prognostic algorithm for RUL estimation using an RNN autoencoder scheme[J]. Reliability Engineering and System Safety, 2020, 199(7): 1-12.
- [21] XU Xin, WU Qianhui, LI Xiu, et al. Dilated convolution neural network for remaining useful life prediction[J]. Journal of Computing and Information Science in Engineering, 2019, 20(2): 1-14.

(编辑: 陈 越)