

基于深度长短期记忆网络的发动机叶片 剩余寿命预测*

马奇友, 刘可薇, 杜 坚, 仇 芝

(西南石油大学 机电工程学院, 四川 成都 610500)

摘要: 为了预测航空发动机转子叶片的剩余寿命, 提出了一种基于多传感器信号融合的深度长短期记忆网络(DLSTM)预测模型。利用深度学习和长短期记忆的组合来构造DLSTM网络, 将多个传感器信号数据进行融合处理, 通过深度学习发现各个传感器时序信号之间隐藏的长期依赖关系。在给定网格搜索策略的情况下, 通过自适应矩估计算法调整DLSTM的网络结构和参数, 在DLSTM模型中引入了一种随机丢失策略, 以缓解过度拟合问题并使预测模型规范化。最后, 利用CMAPSS涡扇发动机进行了实验验证。在一种故障模式和两种故障模式下, DLSTM网络预测模型相对于其它传统方法在评价指标上占优, 表明本文提出的方法具有更高的准确性以及稳定性。

关键词: 航空发动机; 叶片; 寿命预测; 预测模型; 深度学习; 数据融合; 数据处理

中图分类号: V263.6 **文献标识码:** A **文章编号:** 1001-4055 (2021) 08-1888-10

DOI: 10.13675/j.cnki.tjjs.190863

Prediction of Residual Life of Engine Blades Based on Deep Short Term Memory Network

MA Qi-you, LIU Ke-wei, DU Jian, QIU Zhi

(College of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu 610500, China)

Abstract: In order to study the residual life prediction of aeroengine rotor blades, a prediction model of deep long short term memory(DLSTM) based on multi-sensor signal fusion was proposed. First, the DLSTM network was constructed by the combination of DLSTM. Then, the multi-sensor signal data were fused to find the hidden long-term dependence between the sensor timing signals through deep learning. Furthermore, given the grid search strategy, the network structure and parameters of DLSTM were adjusted by the adaptive moment estimation algorithm, and a random loss strategy was introduced into the DLSTM model to alleviate the over fitting problem and standardize the prediction model. Finally, the CMAPSS turbofan engine was used to test and verify. Under one failure mode and two failure modes, the evaluation indexes of DLSTM network prediction model were relatively better than those of other traditional methods. The results show that the method proposed in this paper has higher accuracy and stability.

* 收稿日期: 2019-12-15; 修订日期: 2020-04-13。

基金项目: 国家自然科学基金(61203146); 国家科技重大专项子专题(2008ZX05017-005-05-01HZ); 国家重点研发计划(2016YFC0304008)。

作者简介: 马奇友, 硕士生, 研究领域为机械设计及智能控制。E-mail: woshininis@163.com

通讯作者: 杜 坚, 硕士, 教授, 研究领域为机械设计及智能制造、控制。E-mail: 3190115928@qq.com

引用格式: 马奇友, 刘可薇, 杜 坚, 等. 基于深度长短期记忆网络的发动机叶片剩余寿命预测[J]. 推进技术, 2021, 42(8): 1888-1897. (MA Qi-you, LIU Ke-wei, DU Jian, et al. Prediction of Residual Life of Engine Blades Based on Deep Short Term Memory Network[J]. *Journal of Propulsion Technology*, 2021, 42(8): 1888-1897.)

Key words: Aeroengine; Blade; Life prediction; Forecasting model; Deep learning; Data fusion; Data processing

1 引言

发动机叶片作为发动机压气机的关键部件,任何意外故障都可能导致巨大的经济损失,甚至造成灾难性后果。如果能够提前预测发动机叶片的剩余使用寿命,则可以通过预测性维护来避免故障,保证航空安全。因此,叶片剩余寿命(Remaining useful life, RUL)预测对于提高发动机的可用性和可靠性以及降低其生命周期成本至关重要^[1-2]。

文献[3]提出基于发动机涡轮叶片的状态数据对该叶片的剩余寿命进行评估,文献[4]借助结构近似分析,建立叶片疲劳寿命神经网络近似计算模型,近似计算风力机叶片疲劳寿命性能。文献[5]根据径流式增压器涡轮的结构与工作特点,分析了涡轮叶片的载荷与应力空间分布特征,对增压器涡轮叶片叶根进行了寿命评估。上述研究均取得了不错的效果,但是以上方法均是基于不同叶片的具体分析,主要手段均是疲劳应力分析,方法的通用性不强,且没有充分发挥传感器测量数据的优势,且少有文章利用振动数据分析方法对叶片进行寿命预测。

数据驱动RUL方法易于实现,且能够全面地对数据进行分析,在各个领域均得到了广泛的应用^[6]。虽然这些方法通过映射监视信号和RUL值之间的关系可以实现RUL预测,但是没有考虑反映健康状态微小变化的不同时间序列信号的相关性,因此无法充分发挥测量数据的预测潜力。

递归神经网络(Recurrent neural network, RNN)作为上述问题的一种解决方案,可以跨时间步长从先前处理的数据中提取有用的重要信息,并将其集成到当前的单元状态中以对顺序数据进行建模^[7]。但是训练中梯度消失或爆炸的问题限制了传统RNN的广泛应用。文献[8]创建了一种改进的名为长短期记忆网络(Long short term memory, LSTM)的RNN结构来缓解此问题,通过引入一组记忆神经元,LSTM在学习鲁棒性和敏感数据方面表现出了卓越的能力。但是,该方法仅分析振动信号,而不考虑多传感器数据的融合处理,无法体现数据驱动的全面性,导致预测精度不高,而且,由于网络结构的限制,执行深度学习对预测精度提升的效果不佳。

为达到叶片预测方法的通用性,并进一步提升预测的精度,结合自适应矩估计算法(Adaptive mo-

ment estimation algorithm, AMEA)、网格搜索策略以及随机丢失策略,提出了一种基于多传感器信号融合的DLSTM网络预测模型。

2 RUL预测模型

2.1 LSTM网络模型

与常见的神经网络不同,RNN具有独特的结构,即隐藏层的输出将作为输入反复迭代,这意味着隐藏层在一段时间内与其自身具有自连接特性。因此,RNN在处理时序相关数据方面具有很强的能力。数学上,在时间 t 处的隐藏层的输出描述为

$$h_t = \varphi(w_{hx} + w_{hh}h_{t-1} + b_h) \quad (1)$$

式中 w_{hx} 和 w_{hh} 分别是隐藏层神经元的输入数据 x_t 和先前输出 h_t 的权重系数, t 和 $t-1$ 代表时间, b_h 表示偏差。然而,由于在模型训练期间反向传播过程中存在梯度消失问题,RNN无法获取数据中的长期依存关系。

因此,在LSTM网络结构中,LSTM神经元通过取代传统的RNN隐藏神经元来构建LSTM层。每个LSTM神经元都有三个精心设计的门函数,即遗忘门,输入门和输出门。这种结构确保LSTM神经元具有发现和记忆长期依赖性的能力。

LSTM神经元中的三个门函数为控制信息的输入和删除提供了良好的非线性控制机制。输入门决定了将进入神经元状态的信息,遗忘门决定了神经元状态中需要丢弃的信息,输出门决定从神经元状态导出什么信息。LSTM神经元的计算过程可以用数学式表示为

$$g_t = \varphi(w_{gx} + w_{gh}h_{t-1} + b_g) \quad (2)$$

$$i_t = \sigma(w_{ix}x_t + w_{ih}h_{t-1} + b_i) \quad (3)$$

$$f_t = \sigma(w_{fx}x_t + w_{fh}h_{t-1} + b_f) \quad (4)$$

$$o_t = \sigma(w_{ox}x_t + w_{oh}h_{t-1} + b_o) \quad (5)$$

$$s_t = g_t \otimes i_t + s_{t-1} \otimes f_t \quad (6)$$

$$h_t = \varphi(s_t) \otimes o_t \quad (7)$$

式中 w_{gx} , w_{fx} , w_{ix} 和 w_{ox} 是输入数据 x_t 的权重, w_{gh} , w_{ih} , w_{fh} 和 w_{oh} 是LSTM神经元先前输出的 h_{t-1} 的权重; b_g , b_f , b_i 和 b_o 表示输入节点、遗忘门、输入门和输出门的偏差; g_t , f_t , i_t 和 o_t 是输入节点、遗忘门、输入门和输出门的输出; σ 和 φ 表示S型和tanh函数; s_t 和 s_{t-1} 是LSTM神经元在时间 t 和 $t-1$ 时的状态; \otimes 表示逐点乘法。

2.2 基于DLSTM网络的URL预测模型

深度学习作为人工神经网络的扩展,可以通过多层网络结构来自适应地捕获数据中的潜在特征^[9]。从结构的角度来看,DLSTM包含多个隐藏层,这是深度学习的一种形式。本文构建了一个DLSTM网络模型,以实现多传感器数据的自动融合和RUL的准确预测。

输入数据的输入由输入神经元控制,因此,输入神经元的数量等于所选传感器信号的数量。传感器时间序列信号数据分为不同部分,分别用于网络模型训练、验证和测试。输入数据被构造成二维矩阵。矩阵中的行数和列数为 k 和 T ,其中 k 表示所选传感器的数量, T 表示采样数据的数量。最终将多传感器数据融合到RUL值。相应的结构图如图1所示。

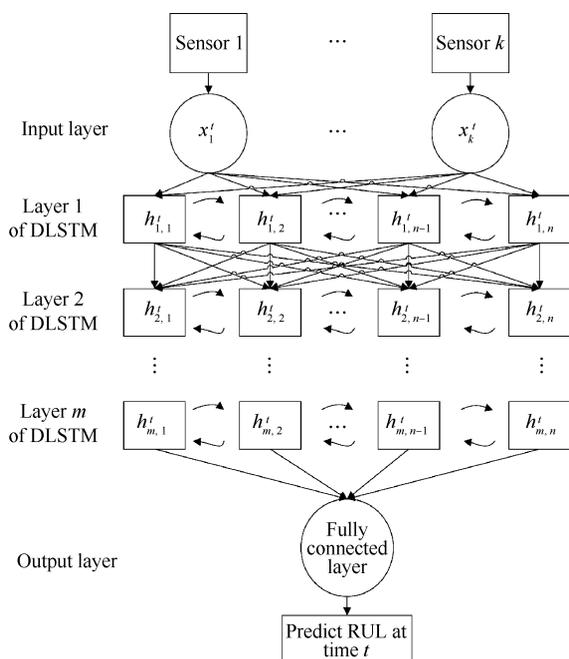


Fig. 1 Network structure of DLSTM

LSTM一般为单路结构,只存在隐藏层与隐藏层之间的数据传递,而多个LSTM层堆叠在构造的DLSTM模型中,实现了多传感器数据的深度挖掘和融合。不同的LSTM层在空间上相连,并且数据从上层输出到下一层的神经元,相同的LSTM层与时间有关,LSTM层的先前输出将作为输入循环到该层。每个LSTM层中都包含许多LSTM神经元,以捕获传感器数据的长期依赖性。在每一层LSTM神经元之间形成信息交换,实现跨时间的自连接。此外,每个神经元的输出不仅在下一刻循环进入自身,而且还与其它神经元共享。

输出层采用完全连接的密集层,在该层中将LSTM层的输出信号送入其中,最终将多传感器数据融合到RUL值。采用均方误差函数作为机器学习中常用的损失函数,以使预测的RUL和RUL标签之间的误差最小。在测试阶段,将在线传感器数据依次发送到经过训练的DLSTM中,并将获取预测的RUL。

2.3 DLSTM网络模型优化

2.3.1 基于网格搜索策略的模型结构优化

DLSTM模型结构的大小,包括LSTM层数和每个LSTM层的神经元数,需要很好地确定。这些是DLSTM模型中两个重要的超参数,用于控制网络的体系结构和拓扑。许多文献提出了DLSTM的参数优化方法^[10],尽管这些种优化方法都取得了很好的效果,但优化过程却极其复杂。由于DLSTM网络结构的复杂性和长的训练过程,DLSTM与这些优化方法相结合必然会对计算资源提出更高的要求。

DLSTM将网格搜索用于网络配置探索,原理简单明了,算法容易实现,计算资源要求低^[11]。LSTM层数和各层神经元数的候选构成一个二维网格,并验证网格中各节点参数以选择最佳的网络结构参数。最后,将具有最佳验证预测性能的参数视为最优参数,并用于在线RUL预测中。具体的网格搜索策略过程可参考文献^[11]。

2.3.2 基于AMEA算法的损失函数优化

损失函数的优化将直接影响DLSTM训练的效率和时间,在所提出的DLSTM模型中,通过AMEA算法代替传统的随机梯度下降(Stochastic gradient descent, SGD)优化算法,使DLSTM的损失函数最小。本文中给出的损失函数为均方根误差函数RMSE(Root mean square error),其表达式为

$$\Pi = \sqrt{\frac{1}{m} \sum_{i=1}^m (h(x_i) - y_i)^2} \quad (8)$$

在SGD算法中,保持固定的学习速率来更新所有的权值,这意味着学习速率在训练中保持不变。AMEA算法通过分析梯度的一阶矩估计(First moment estimate, FME)和二阶矩估计(Second moment estimate, SME),针对不同的参数设计独立的自适应学习速率。因此,AMEA算法具有较高的计算效率,但需要较少的配置资源。用AMEA算法更新网络参数的过程表示为

$$g_t = \nabla_{\theta} \sum_i L(\theta_{i-1}) \quad (9)$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (10)$$

$$n_t = \beta_2 n_{t-1} + (1 - \beta_2) g_t^2 \quad (11)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1'} \quad (12)$$

$$\hat{n}_t = \frac{n_t}{1 - \beta_2'} \quad (13)$$

$$\theta_t = \theta_{t-1} - \eta \times \frac{\hat{m}_t}{\sqrt{\hat{n}_t + \varepsilon}} \quad (14)$$

式中 g_t 表示损失函数 $L(\theta)$ 相对于网络参数集 θ 的梯度, m_t 和 n_t 分别代表梯度的 FME 和 SME。 \hat{m}_t 和 \hat{n}_t 分别是 m_t 和 n_t 的偏差校正, β_1 和 β_2 分别代表 FME 和 SME 的衰减率, η 表示步长, ε 表示数值稳定常数, θ_{t-1} 是在 $t-1$ 时刻计算出的 θ_t 更新值。

2.3.3 基于随机丢失策略的 DLSTM 优化

通常,神经网络的训练会随着网络层数的增加变得更加耗时,因此过度拟合将成为一个不可忽视的问题^[11]。严重的过度拟合会导致预测模型在训练数据中表现出色,但在测试数据中表现不佳。为了解决这个问题,在 DLSTM 中引入了随机丢失策略来防止重复捕获相同的特征。

应用于 DLSTM 模型的信号随机丢失策略的示意图如图 2 所示。在这个示意图中,红圈是隐藏层中的神经元,它们在 DLSTM 的训练过程中,根据一定的概率暂时从网络中丢弃。由于丢弃是随机发生的,所以在每个小批量中训练不同的网络,相关的丢失概率设置为 50%,即每一层的神经元个数只能保持 50%。因此,信号丢失可以有效地缓解 DLSTM 的数据过拟合问题。信号丢失只在训练过程中起作用,在测试过程中被禁用,这意味着所有隐藏层的神经元都在测试过程中起作用。在本文中,测试了所有候选遗漏值,最后将最优值应用到 DLSTM 中。

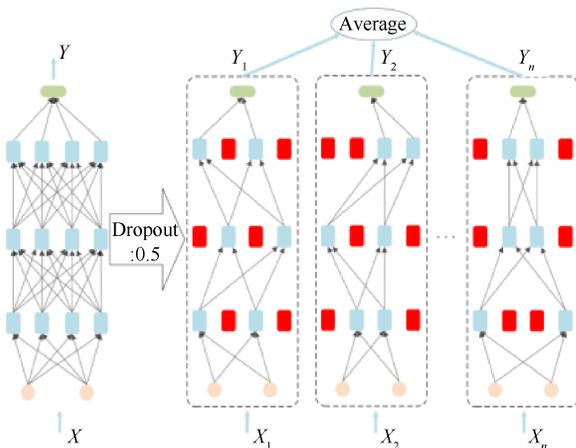


Fig. 2 Diagram of random loss strategy

3 实验与分析

3.1 数据集描述

用于评估所提出方法的数据集是由 CMAPSS 平台生成的 NASA 涡扇发动机数据集,用于模拟涡轮风扇发动机中的不同故障和退化过程。在实验过程中,涡扇发动机开始良好的状态下运行,并出现了一些故障,这些故障会导致性能下降,直到出现事故为止。

CMAPSS 平台提供四个数据集:FD001~FD004。在每个数据集中,都包括训练集和测试集。训练集会保存整个寿命周期的信号,而测试集仅包含多个传感器数据,这些数据在发动机故障和 RUL 需要预测之前的某个时间终止。训练集和测试集都由一系列循环组成,每个循环包含 26 列,分别指示发动机序号、循环索引、三个操作设置和 21 个传感器测量值。

由于发动机具有明显的健康退化过程,四个数据集中,FD001 与 FD002 均代表一种故障模式,FD003 与 FD004 代表两种故障,由于多种工况条件下不确定较大,且振动信号的变化剧烈,因此本文采用了 FD001 和 FD003 两组单一工况条件的数据集进行说明。FD001 和 FD003 都包含 100 个训练引擎和 100 个测试引擎。

本文中所有方法都是在 Anaconda 和 Python3.6 上执行的。计算设备是一台具有 Intel Core i5-4460 (3.20 GHz) CPU, 16 GB RAM 的计算机。

3.2 性能评价指标

本文提出的方法采用 S, R, RUL 误差范围三个指标来评估 RUL 预测性能。

数据创建者提供的指标 S 表示为

$$S = \begin{cases} \sum_{i=1}^n \exp\left(-\frac{\hat{R}_i - R_i}{13}\right) - 1, & \text{if } \hat{R}_i - R_i < 0 \\ \sum_{i=1}^n \exp\left(\frac{\hat{R}_i - R_i}{10}\right) - 1, & \text{if } \hat{R}_i - R_i \geq 0 \end{cases} \quad (15)$$

该指标表示总体指数的误差大小,其中 \hat{R}_i 表示预测的 RUL, R_i 表示实际 RUL。 n 表示测试发动机的总数。指标 R 定义为

$$R = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{R}_i - R_i)^2} \quad (16)$$

R 表示均方根误差, S 和 R 都用来评估预测 RUL 和实际 RUL 之间的差异,一个小的 S 或 R 值代表一个好的预测效果。然而,这两个指标之间存在微妙的

差异。如图3所示,比起早期的预测,S对晚期预测的惩罚更大。

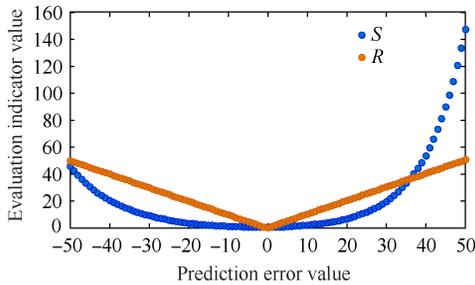


Fig. 3 Error variation of S and R

指标RUL误差范围代表所有RUL预测值的误差范围。RUL误差范围越小,预测方法的有效性和稳定性越高。

3.3 多传感器数据预处理

涡扇发动机获得的多传感器数据存在较大的随机波动和噪声干扰,可能影响RUL预测的性能。采用指数平滑算法去除噪声,减弱传感器数据的随机波动,其表达式为

$$\begin{cases} x'_t = \alpha x_t + (1 - \alpha)x'_{t-1}, & \text{if } t \geq 2 \\ x'_t = x_t, & \text{if } t = 1 \end{cases} \quad (17)$$

式中 x_t 是 t 时刻传感器的实际测量值, x'_t 表示 t 时刻的平滑值, x'_{t-1} 表示 $t-1$ 时刻的平滑值, α 表示平滑系数。

α 值的大小直接决定了发动机传感器数据的平滑效果,从而间接影响RUL预测的精度。图4显示出了与FD001中的原始传感器数据相比具有不同 α 值的传感器2的预处理传感器数据。传感器数据平滑使用三个不同的 α 值,分别为0.25,0.50和0.75。如图4所示,与原始传感器数据相比,平滑的传感器数据的波动减小,并且平滑的传感器数据能够很好地反映原始传感器数据的趋势。此外,通过一系列对比实验发现, α 值为0.25的预处理传感器数据波动较小,这意味着数据平滑效果更好。因此,在本实验中, α 设置为0.25。

综上所述,从21个传感器获取的信号包含在CMAPSS数据集中。传感器类型均为振动传感器,分为轴向振动传感器与周向传感器,然而并不是所有的传感器都能很好地表示退化过程。为了得到准确的RUL预测,需要选择传感器。合理的传感器信号与健康退化过程具有良好的相关性,表现出单调递增或递减的趋势^[12]。因此,通过分析信号数据的单调性 M 和相关性 C 来实现传感器的选择。

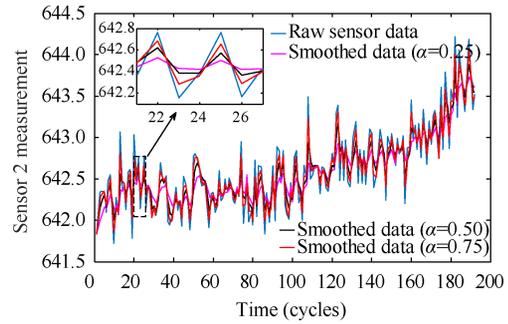


Fig. 4 Raw data and smooth data

为了测量发动机数据的趋势,首先提取发动机数据的平均趋势特征,表示为

$$f(t) = \frac{f_u(t) + f_l(t)}{2} \quad (18)$$

式中 $f(t)$ 是时间 t 处传感器信号的趋势值。 $f_u(t)$ 和 $f_l(t)$ 表示传感器信号的上下包络。对传感器信号的 M 和 C 进行分析,定义为

$$\begin{cases} M = \frac{\left| \sum_t \text{sign} \left[f(t+1) - f(t) - \sum_t \text{sign} (f(t) - f(t+1)) \right] \right|}{T-1} \\ C = \frac{\left| \left(T \sum_t f(t) - T \sum_t f(t) \sum_k t \right) \right|}{\sqrt{\left[T \sum_t f(t)^2 - \left(\sum_t f(t) \right)^2 \right] \left[T \sum_t t^2 - \left(\sum_t t \right)^2 \right]}} \end{cases} \quad (19)$$

式中 T 表示信号样本的数量。通过 M 和 C 的组合找到一个复合选择标准,其表示为

$$\begin{aligned} \max_{\omega} H &= \omega_1 M + \omega_2 C \\ \text{s.t. } \sum_{i=1}^2 \omega_i &= 1, \quad \omega_i > 0 \end{aligned} \quad (20)$$

其中 Ω 表示所有候选传感器信号, ω_i 表示加权系数。由公式可以看出, H 与 M 和 C 呈线性正相关,即 H 指数越高,传感器越能反映变化趋势。为了选择更好的特征,阈值 Φ 设置为0.75。

图5说明了FD001和FD003中传感器的分类 H 值,从图7(a)可以看出,FD001中的21个传感器(S1~S21)的 H 被排序。S2,S3,S4,S7,S8,S11,S12,S13,S15,S17,S20和S21的 H 大于阈值。因此,它们被选中。在图7(b)中,选择传感器S4,S7,S11,S12,S15,S20和S21的数据来构建FD003中的训练数据集。

RUL标签值对预测性能有显著影响,RUL标签被假定在初始阶段是恒定的,然后线性下降,根据文献[13],早期的采样点设置一个恒定的RUL

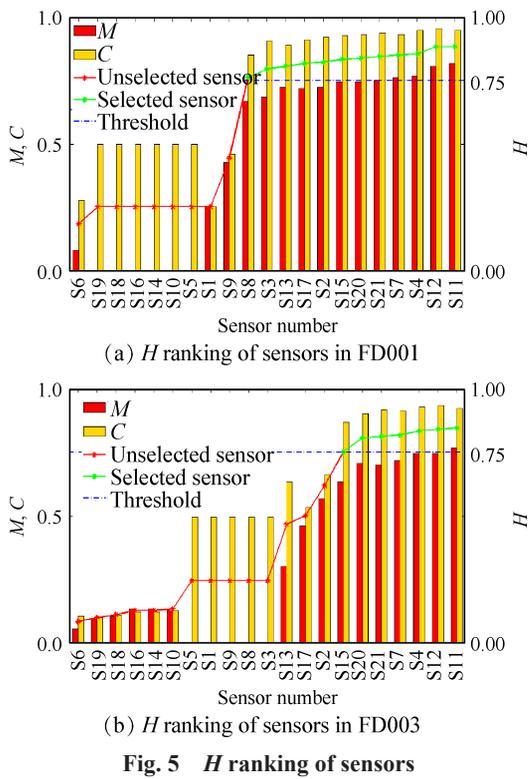


Fig. 5 *H* ranking of sensors

值 125。

多传感器融合方式为所有选中的传感器的加权归一化,其中,权值为单个传感器的 *H* 与所有选中传感器 *H* 之和的比值。

3.4 结果分析

3.4.1 单一故障模式

对数据集 FD001 进行分析,以验证所提出的方法。首先,在多传感器数据预处理完成后,利用 100 台发动机的传感器数据建立训练数据集,其中随机选取 90 台发动机进行 DLSTM 模型训练,其余 10 台发动机验证模型的有效性。

其次,考虑数据集中监测信号的特性,建立了用于 RUL 预测的 DLSTM 模型,并对其参数进行了优化确定。利用网格搜索方法对模型进行训练,以探索最优的 DLSTM 结构。由 LSTM 层数和各层形式的神经元数构成二维网格,并将网格中的每个节点参数

验证为候选参数。考虑到时间限制和计算复杂性,将 LSTM 层数设置为 1~6,并且每个 LSTM 层中的神经元数设置为从 50~300。在这个网格中,每两个参数组合用于构造一个新的 DLSTM。采用 10 台发动机对每个模型结构进行验证,并利用 RMSE 对模型训练结果进行比较。图 6 显示了不同层数和神经元数的 DLSTM 的训练结果。从图 6 可以看出,每个模型结构具有不同的性能,最重要的是,DLSTM 模型具有 5 个 LSTM 层,每个 LSTM 层有 100 个神经元,达到了最优的性能。因此,在这种情况下,DLSTM 模型由 5 个 LSTM 层和 100 个神经元构成。表 1 记录了部分参数组合情况下 DLSTM 的训练结果,选择了 6 个参数组合,取得了较好的训练效果。通过对参数和训练时间的比较,发现 DLSTM 的训练时间随着 LSTM 层数和 DLSTM 层数的增加而逐渐延长。

为了减少 DLSTM 模型的数据过度拟合,采用了丢失法。本文尝试用不同的丢失值来确定构造的 DLSTM 的最佳值。图 7 显示了具有不同丢失值的构造的 DLSTM 的训练结果,从图 7 可以看出,当丢失率为 0.7 时,DLSTM 模型具有最小的 RMSE 并获得最佳的训练性能。因此,在这种情况下,为了获得良好的 DLSTM 训练效果,将丢失值设置为 0.7。

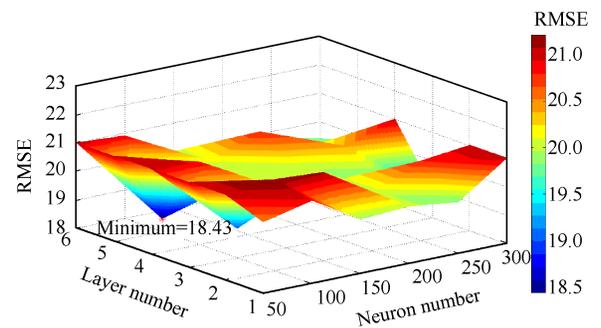


Fig. 6 DLSTM training with different layers and neurons

为了使损失函数最小化,本文将不同的优化算法与 AMEA 算法进行了比较,包括批量梯度下降法 (SGD),均方根 (RMSprop),自适应梯度 (Adagrad) 和

Table 1 Training results of DLSTM with combination of parameters

No.	Layer No.	Number of neurons in each layer	RMSE	Training time/s
1	2	150	20.40	34804.87
2	3	200	20.35	69720.27
3	3	250	18.56	98679.69
4	4	250	20.52	153776.33
5	5	100	18.43	56994.93
6	5	300	18.70	260307.16

Adadelata算法。图8显示了使用不同优化算法训练DLSTM。从图8可以看出,这四个优化器都可以帮助DLSTM在经过1000个阶段后实现网络优化。尽管如此,与其它算法相比,DLSTM中的AMEA算法具有更高的效率和更好的收敛性。因此,AMEA在构造的DLSTM中用作损失函数优化器。

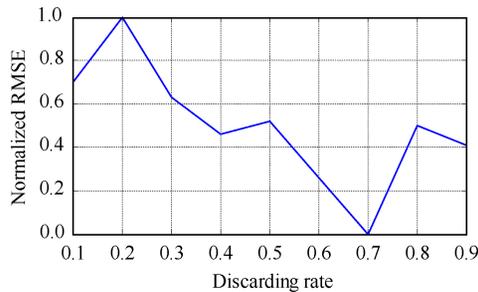


Fig. 7 Training DLSTM with different loss values

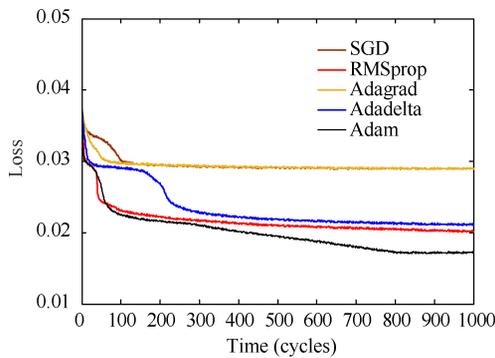


Fig. 8 Different optimizers for training DLSTM

最后,建立了一个包含5层LSTM和100个神经元的DLSTM模型,用于发动机RUL的预测。将丢失

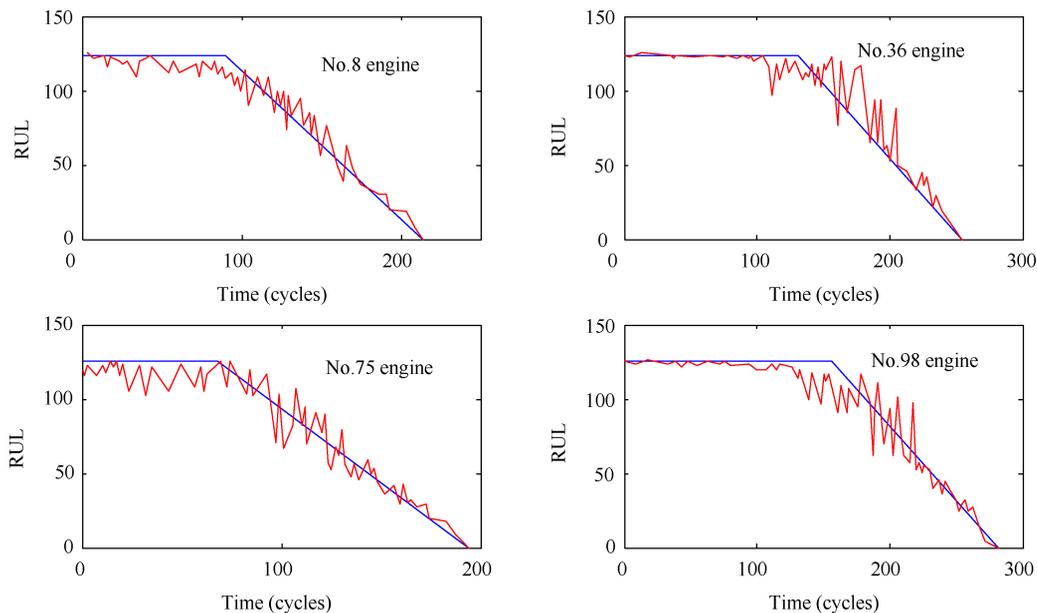


Fig. 9 Prediction results of 4 engines

值设为0.7,损失函数优化算法采用AMEA。表2报告了构建的DLSTM模型的其它参数。

Table 2 Parameters of DLSTM model

Parameter	Value
Initial learning	0.001
Training period	1000
Batch size	10
Loss function	Mean square error

模型训练完成后,利用10台发动机对训练后的DLSTM进行性能验证。图9比较了10台发动机的预测RUL和真实RUL,其中红色曲线代表预测结果,蓝色曲线代表真实剩余寿命。早期的采样点用一个恒定的RUL值进行标记,根据文献[6]可知将其设置为125,当预测的剩余寿命为0时终止。从图9可以看出,这些预测能够很好地反映10台发动机真实RUL的变化。

在线过程中,将测试发动机的监测信号依次输入DLSTM模型,得到预测的RUL。图10显示了FD001中100台发动机的实际RUL与预测RUL。结果表明,预测的RUL与实际RUL非常吻合。

本文使用了一些最新的研究成果与DLSTM进行了比较,包括多层感知器(Multi layer perceptron, MLP)^[14]、支持向量回归(Support vector regression, SVR)^[15]、相关向量回归(Related vector regression, RVR)^[6]、深卷积神经网络(Deep convolution neural network, DCNN)^[9]、带模糊聚类的ELM(ELM-FC)^[16]、支持向量机(Support vector machine, SVM)^[17],具有KF的回波状态网络(ESN-KF)^[18]和基于相似性算法

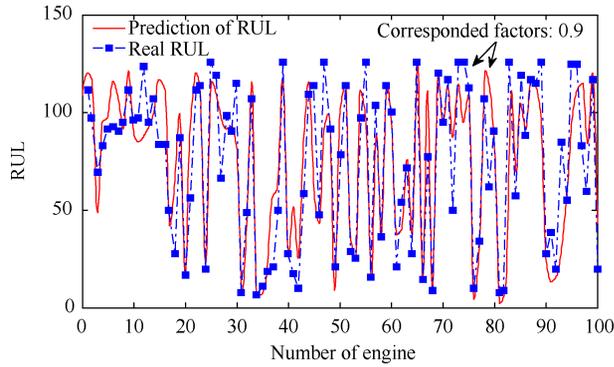


Fig. 10 Actual and predicted RUL of 100 engines

(Based on similarity algorithm, SBA)^[19]。表 3 显示了性能比较,其中 N/A 表示信息不可用,表中比较了 DLSTM 和在数据集 FD001 中的测试发动机上实现的最新技术的性能,可以看出,在这种 RUL 预测问题中,许多方法都显示了各自的优势,包括 DCNN, ELM, SBA 等。与其它方法相比,DLSTM 具有最小的得分 S, R 和 RUL 误差范围。对比其它方法中最优得分,DLSTM 减少了 17.19%,而 R 值相对其它方法的最优值仍旧下降了 0.65%,RUL 误差范围也是所有方法中最小的。这意味着所提出的 DLSTM 具有最好的预测性能,这说明所提出的 DLSTM 对该发动机预测问题的有效性。

3.4.2 两种故障模式

由于包含了更多的故障模式,使用数据集 FD003 进行准确的 RUL 预测比数据集 FD001 困难得多。本文利用 FD003 数据集比较了 DLSTM 和其它 RNN 方法的 RUL 预测性能,包括深度递归神经网络(DRNN)、深门控递归单元(DGRU)、双向 GRU

Table 3 Performance comparison

Method	S	R	RUL error range
MLP	17992	37.56	N/A
SVR	1381	20.96	N/A
RVR	1502	23.80	N/A
DCNN	1287	18.45	N/A
ELM-FC	1046	N/A	[-80, 120]
SVM	N/A	29.82	[-64, 69]
ESN-KF	N/A	63.46	[-185, 120]
SBA	791	N/A	N/A
DLSTM	655	18.33	[-47, 56]

(BDGRU)和双向 LSTM(BDLSTM)。所有的方法都采用了网格搜索和丢失的方法来获得最优模型。表 4 记录了所有方法的关键参数。

图 11 显示出了五个模型的 RUL 误差的箱形图。五个模型的 100 台发动机的 RUL 误差集中在 0 附近,与其它模型相比,DLSTM 的 RUL 预测误差更为集中,说明 DLSTM 预测稳定性更好。

表 5 根据三个评估指标和时间消耗比较了五个模型的预测结果,可以看出,所提出的 DLSTM 在 S, R 和 RUL 误差范围方面始终优于其它比较的 RNN 模型。其中,DLSTM 的 S 相对于其它方法中最优值下降了 14.37%,而 R 值相对于其它方法中的最小值仅上升了 1.54%,误差范围是所有方法中最小的。而 BDLSTM 和 BDGRU 由于其独特的双向网络结构,能够更好地处理时间序列数据。因此,BDLSTM 和 BDGRU 的评估指标略差于最优结果。由于 DRNN 结构最简单,与其它进化的 RNN 结构相比,DRNN 的预

Table 4 Key parameters of all methods

Model	Layer number of LSTM	Number of neurons in each layer	Discarding rate
DRNN	4	100	0.5
DGRU	4	150	0.5
BDLSTM	3	150	0.6
BDGRU	3	300	0.6
DLSTM	2	250	0.7

Table 5 Performance comparison of five models on FD003

Method	S	R	RUL error range	Training time/s	Online average cumulative time/s
DRNN	1358	26.12	[-73, 44]	81503.25	0.11
DGRU	1105	20.86	[-48, 45]	296997.23	0.15
BDLSTM	980	19.48	[-54, 67]	234484.16	0.28
BDGRU	967	19.94	[-52, 67]	449436.09	0.36
DLSTM	828	19.78	[-44, 38]	346454.71	0.18

测结果相对较差。从表5可知,虽然DLSTM与其他模型相比在线平均计算时间相对于最优值增加了63.63%,这是因为DLSTM具有相对复杂的网络结构。但是所有模型的在线平均计算时间均较短,符合工业应用的要求,因此证明了DLSTM可以应用于工业系统的实际设备中。

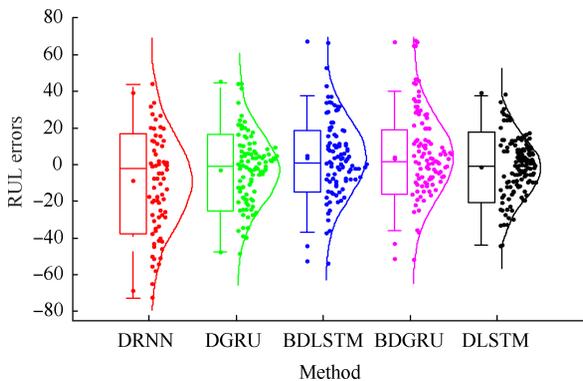


Fig. 11 Box diagram of RUL error of five models

4 结 论

本文通过建立的DLSTM网络模型,提出了一种多传感器数据融合驱动的发动机叶片RUL预测方法。并通过实验数据进行了验证,得出如下结论:

(1)多传感器数据融合驱动与建立的DLSTM相结合,使得在两个预测分析中的 S 相对于其它方法中的最优值下降了17.19%和14.37%,而 R 值相对于其它方法中的最小值变化幅度十分微小,RUL误差范围则是所有方法中最小的。因此可知该方法可以有效地提升剩余寿命的预测精度,并且具备良好的效率和收敛性。

(2)DLSTM与其它模型相比在线平均计算时间相对于最优值增加了63.63%,但是其本身计算时间量级较小,因此计算时间依旧处于一个较小的数量级,增加的计算时间对于系统的应用影响不大,能够符合工业应用要求,证明了DLSTM可以应用于工业系统的实际设备中。

(3)该方法具有多传感器数据融合能力,方法本身具备一般性,可广泛应用于其它领域的不同类型设备。

但是本文的实验对象为单一工况条件下的数据集,由于振动信号变化大,对于多工况复杂条件下的多故障发动机叶片寿命预测需要进一步研究。

致 谢:感谢国家自然科学基金、国家科技重大专项子专题、国家重点研发计划的资助。

参考文献

- [1] 黄智,李超,宋瑞,等.航空发动机叶片型面加工误差可视化方法研究[J].推进技术,2019,40(1):184-191.(HUANG Zhi, LI Chao, SONG Rui, et al. Research on Visualization Method of Aero-Engine Blade Surface Machining Error[J]. *Journal of Propulsion and Technology*, 2019, 40(1): 184-191.)
- [2] 张春宜,刘令君,孙旭东,等.基于双重响应面法的航空发动机叶片振动概率分析[J].推进技术,2017,38(4):918-924.(ZHANG Chun-yi, LIU Ling-jun, SUN Xu-dong, et al. Probability Analysis of Aero-engine Blade Vibration Based on Double Response Surface Method [J]. *Journal of Propulsion and Technology*, 2017, 38(4): 918-924.)
- [3] 孙见忠,左洪福,梁坤.基于民航发动机状态数据的涡轮叶片剩余寿命评估[J].机械工程学报,2015,51(23):53-59.
- [4] 王雷,陆金桂,李乐为.叶片疲劳寿命神经网络近似计算模型数值实验[J].上海大学学报(自然科学版),2019,25(6):870-878.
- [5] 王正,马同玲.增压器涡轮叶片疲劳蠕变寿命预测方法[J].中国机械工程,2019,30(21):2521-2526.
- [6] Liu H, Zhou J, Zheng Y, et al. Fault Diagnosis of Rolling Bearings with Recurrent Neural Network-Based Auto-Encoders[J]. *ISA Transaction*, 2018, 77: 167-178.
- [7] 喻昕,胡悦,马崇,等.递归神经网络方法解决非光滑伪凸优化问题[J].计算机应用与软件,2019,36(11):145-151.
- [8] 曲星宇,曾鹏,李俊鹏.基于RNN-LSTM的磨矿系统故障诊断技术[J].信息与控制,2019,48(2):179-186.
- [9] 葛绍林,叶剑,何明祥.基于深度森林的用户购买行为预测模型[J].计算机科学,2019,46(9):190-194.
- [10] 李永刚,王朝晖,万晓依,等.基于深度残差双向DLSTM的时空一致视频事件识别[J].计算机学报,2018,41(12):2852-2866.
- [11] Cheng Y W, Zhu H P, Wu J, et al. Machine Health Monitoring Using Adaptive Kernel Spectral Clustering and Deep Long Short-Term Memory Recurrent Neural Networks[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(2): 987-997.
- [12] Wang W, Hong G, Wong Y, et al. Sensor Fusion for Online Tool Condition Monitoring in Milling[J]. *International Journal of Production Research*, 2017, 45(21): 5095-5116.
- [13] Wang J L, Zhang J, Wang X X. Bilateral LSTM: A

- Two-Dimensional Long Short-Term Memory Model with Multiply Memory Units for Short-Term Cycle Time Forecasting in Re-Entrant Manufacturing Systems[J]. *IEEE Transactions on Industry Applications*, 2018, 14(2): 748-758.
- [14] Ba G S, Zhao P, Li X L. Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life [C]. *Dallas: International Conference on Database Systems for Advanced Applications*, 2016.
- [15] 李 康, 王 魏, 林少涵. 基于GA-SVR的海水养殖过程软测量建模[J]. *控制工程*, 2019, 26(11): 2047-2051.
- [16] 杨本臣, 于坤鹏, 张 军. 基于ELM优化模型的用户短期负荷研究[J]. *计算机应用与软件*, 2019, 36(11): 91-95.
- [17] 戴邵武, 陈强强, 戴洪德, 等. 基于平滑先验分析和模糊熵的滚动轴承故障诊断[J]. *航空动力学报*, 2019, 34(10): 2218-2226.
- [18] Schmidhuber J. Deep Learning in Neural Networks: An Overview[J]. *Neural Networks*, 2015, 61: 85-117.
- [19] 陆圣宇, 欧 锋, 黄清元, 等. 基于资源分配与偏好连接的局部路径链路预测算法[J]. *计算机工程*, 2019, 45(9): 316-320.

(编辑:史亚红)