

双通道深度卷积神经网络的航空发动机 剩余使用寿命预测方法

苗青林, 张晓丰, 高杨军, 刘显光, 秦丕胜

(空军工程大学装备管理与无人机工程学院, 西安, 710051)

摘要 提出了一种基于双通道的深度卷积神经网络方法, 用来预测航空发动机剩余使用寿命。该方法在传统卷积神经网络上, 应用最大信息系数进行数据降维、卡尔曼滤波进行数据降噪; 通过数据切片, 将数据片标签设置为最后一个循环的剩余使用寿命, 实现数据重构; 引入分段和线性剩余使用寿命衰减模型, 并给出了寿命衰减起始点判断方法; 将寿命衰减前、寿命衰减中2种特征作为双通道网络模型的输入。在NASA涡轮风扇发动机仿真数据集(C-MAPSS)上测试结果显示, 在测试数据范围较大时, 该方法相关指标明显优于其他方法, 在航空发动机剩余寿命预测上具有显著优势。

关键词 航空发动机; 剩余使用寿命; 深度卷积神经网络; 双通道; 最大相关系数

DOI 10.3969/j.issn.1009-3516.2022.02.003

中图分类号 V23; TP391.4 **文献标志码** A **文章编号** 1009-3516(2022)02-0012-07

A Method of Predicting Aero-Engines Remaining Useful Life Based on Two-Channel Deep Convolutional Neural Network

MIAO Qinglin, ZHANG Xiaofeng, GAO Yangjun, LIU Xianguang, QIN Pisheng
(Equipment Management and Unmanned Aerial Vehicle Engineering School,
Air Force Engineering University, Xi'an 710051, China)

Abstract A two-channel deep convolutional neural network-based method is proposed to predict the remaining useful life of aero-engines. The method is to utilize maximal information coefficient for reducing data dimensionality noise, and Kalman filter for reducing data noise on the traditional convolution neural network. The realization of data reconstruction is subjected by data slicing and setting the data slice label as the remaining useful life of the last cycle. The segmented and linear remaining useful life decay models are introduced and a method to judge the starting point of life decay is given. The two features before and during life decay as the input of the two-channel network model are used. The results of testing on NASA turbofan Engine Simulation Data Set (C-MAPSS) show that the relevant indexes of this method are significantly better than that of other algorithms when the test data range is large. And this method has significant advantages in the remaining useful life prediction of aero-engines.

Key words aero-engines; remaining useful life; deep convolutional neural network; two-channel; maximal information coefficient

收稿日期: 2022-01-01

作者简介: 苗青林(1997—), 男, 山东日照人, 硕士生, 研究方向为装备系统工程与决策。E-mail: 1066508284@qq.com

引用格式: 苗青林, 张晓丰, 高杨军, 等. 双通道深度卷积神经网络的航空发动机剩余使用寿命预测方法[J]. 空军工程大学学报(自然科学版), 2022, 23(2): 12-18. MIAO Qinglin, ZHANG Xiaofeng, GAO Yangjun, et al. A Method of Predicting Aero-Engines Remaining Useful Life Based on Two-Channel Deep Convolutional Neural Network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2022, 23(2): 12-18.

随着传感技术和监测技术的发展,航空发动机剩余使用寿命(remaining useful life, RUL)预测^[1-2]也采用了大量传感器。但各传感器数据间具有强耦合、非线性关联的关系,致使传统预测方法难以准确预测航空发动机 RUL。

近年来,随着机器学习的发展,基于数据驱动的航空发动机 RUL 预测方法受到广泛关注,依靠机器学习算法的航空发动机 RUL 预测方法成为主流发展趋势。人工神经网络(artificial neural network, ANN)^[3]、循环神经网络(recurrent neural network, RNN)^[4-5]、长短期记忆神经网络(long short-term memory, LSTM)^[6-9]、多目标深层信念网络集成方法(multi objective deep belief network integration ensemble, MODBNE)^[10]、相关向量机(relevance vector machine, RVM)融合的时间序列预测方法^[11]、支持向量机(support vector machines, SVM)算法^[12]等在航空发动机 RUL 预测中得到了一定的应用,这些方法克服了传统预测的局限性,预测精度有所提高。

卷积神经网络(convolutional neural networks, CNN)是具有卷积计算且有深度结构的前馈神经网络,被广泛应用于图像处理领域。近年来,许多学者将航空发动机传感器数据看成 RGB 通道为 1 的图像,使用 CNN 预测 RUL^[13-14],在 C-MAPSS 数据集上实验,结果表明 CNN 较现有算法在预测准确度上有所提升,但其仍将航空发动机寿命衰减过程看作一个线性过程,没有将航空发动机寿命状态进行分类,即健康状态(未发生寿命衰减)和寿命衰减状态,导致预测仍存在较大的误差。

为进一步提高算法精度,降低预测误差,本文提出了一种基于双通道的深度卷积神经网络(two-channel deep convolutional neural network, TCD-CNN)方法,用来预测航空发动机剩余使用寿命。方法整体框架如图 1 所示。

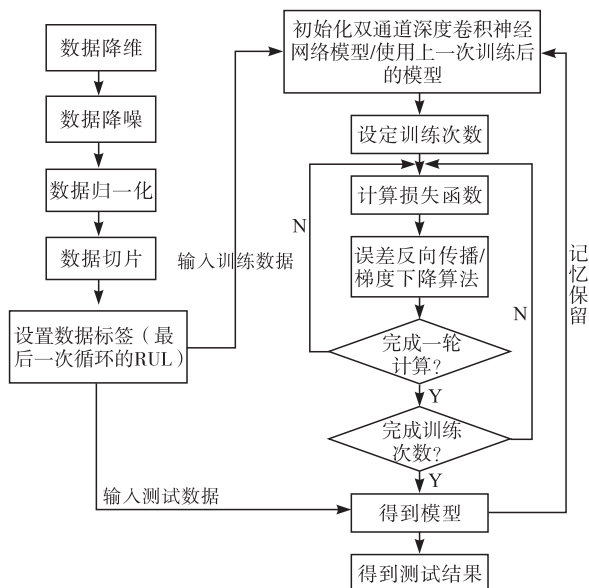


图 1 整体框架

1 数据预处理

本文采用由 NASA 提供的 C-MAPSS 数据集^[1],包括 FD001~FD004 四个子集,每个子集分为训练集和测试集。每个子集的训练集轨迹数量、测试集轨迹数量、工作条件数量和故障模式数量如表 1 所示。

表 1 数据集详情

数据集	FD001	FD002	FD003	FD004
训练集数量	100	260	100	249
测试集数量	100	259	100	248
工作条件数量	1	6	1	6
故障模式数量	1	1	2	2

表 1 中 FD001 和 FD002 中故障模式为高压气机(high pressure compressor, HPC)衰退,FD003 和 FD004 中故障模式为 HPC 衰退和风扇衰退。

每个训练集和测试集中的数据包括航空发动机 id、时间步 c 、3 个航空发动机设置和 21 个航空发动机传感器数据。

训练集中每个航空发动机的总寿命 s_{1id} 为该发动机 c 的最大值,如式(1)所示:

$$s_{1id} = \max_{id} c \quad (1)$$

测试集中每个航空发动机的总寿命 s_{2id} 是该航空发动机 c 的最大值加上测试停止时的 true_RUL_{id} (式中简称为 R_T),如式(2)所示:

$$s_{2id} = R_T + \max_{id} c \quad (2)$$

以 FD001 为例,得到了每个航空发动机总寿命后,用总寿命减 c 得到剩余使用寿命 RUL(式中简称为 R),如式(3)所示:

$$R = \begin{cases} s_{1id} - c & (\text{训练集}) \\ s_{2id} - c & (\text{测试集}) \end{cases} \quad (3)$$

1.1 数据降维

由于传感器种类繁多、数据集中、数据维度大,为提高算法效率,需要对数据进行降维,各传感器(sensor)描述如表 2 所示^[14]。

最大信息系数(maximal information coefficient, MIC)是用于检测变量之间的关联程度的度量标准,范围为 0~1,计算各个传感器数据与 RUL 的 MIC 值^[15],得到传感器 s_1 、 s_5 、 s_6 、 s_{10} 、 s_{14} 、 s_{16} 、 s_{18} 和 s_{19} 的 MIC 值为 0,说明上述传感器数据并不影响 RUL 预测,可以删除该传感器数据。

表2 传感器描述

序号	描述
s1	风扇入口总温
s2	低压压气机出口总温
s3	高压压气机出口总温
s4	低压涡轮出口总温
s5	风扇入口压力
s6	外涵道总压
s7	高压压气机出口总压
s8	风扇物理转速
s9	核心机物理转速
s10	发动机压比(p_{50}/p_2)
s11	高压压气机出口静压
s12	燃料流量比
s13	风扇换算转速
s14	核心机换算转速
s15	涵道比
s16	燃烧室油气比
s17	引气焓值
s18	风扇转速设定值
s19	风扇换算转速设定值
s20	高压涡轮冷却气流量
s21	低压涡轮冷却气流量

1.2 数据降噪及归一化

使用存在噪声的数据对网络进行训练,得到网络模型的预测结果误差较大。进行数据降噪时应保证降噪前后的数据量不变,本文采用卡尔曼滤波方法对数据进行降噪。

卡尔曼滤波是采用卡尔曼增益修正状态观测值,以逼近真实值,通常用来去除噪声来还原真实数据,在轨迹预测、制导和导航等领域有较好的应用。

对降噪后的数据进行归一化处理,将数据映射到0~1范围内。

1.3 数据重构并设置标签

卷积神经网络输入的数据通常为矩形数据,本文采用的数据集由多个多元时间序列组成,所以需要数据重构,使其形成矩阵数据。

假设原数据大小为 $x \times y$,采用数据切片大小为 $l \times y$,滑动步长为1,扫描操作之后得到 $(x-l+1)$ 个 $l \times y$ 的数据片,数据片可以看成1张大小为 $l \times y$ 的灰色图像,RGB通道为1。

以FD001中id为1的数据为例,数据的大小为 192×18 ,采用 30×18 的切片进行数据提取,滑动步长为1,过程如图2所示。

图2中灰色矩形为扫描窗口,从数据的最上方开始扫描,然后矩阵向下移一行,依次类推。数据重构之后共获得163个 30×18 大小的数据片。




图2 数据切片过程

对每个数据片设置标签,标签为该数据片的最后一次循环的RUL,一共有163个数据片,对应数据标签为0~162。FD001~FD004的数据切片大小分别为 $30 \times 18, 20 \times 18, 30 \times 18, 20 \times 18$ 。

2 改进模型和机制

现有CNN算法^[13-14]中的寿命衰减过程考虑不够全面,没有判断寿命衰减起始点位置方法,导致预测误差较高。Shi首次将寿命衰减起始点判断方法加入Dual-LSTM算法,利用LSTM进行退化分析和RUL预测^[15],优点是去除对固定变化点的假设,逐单元检测变化点,并在C-MAPSS数据集上验证了该方法的有效性。本文尝试在CNN中加入分段和线性RUL衰减模型和RUL衰减起始点判断方法以取得更准确的预测结果。

2.1 改进寿命衰减模型

本文使用的寿命衰减模型如图3所示。




图3 改进后的寿命衰减模型

图3中改进的寿命衰减模型中有2种不同的衰减模型,包括线性衰减模型和分段衰减模型。通过RUL衰减起始点来判断该航空发动机RUL衰减模型。

2.2 RUL衰减起始点判断

在测试集中,若RUL大于或等于训练集中的最大寿命时,则说明测试开始的一段时间内航空发动机寿命未衰减,此时,寿命衰减起始点为RUL等于 s_{1id} 的点,对应分段RUL衰减模型。当RUL大于 s_{1id} 时,RUL置为最高寿命,如式(4)所示:

$$R = \begin{cases} s_{1id} & (R \geq s_{1id}) \\ s_{2id} - c & (R < s_{1id}) \end{cases} \quad (4)$$

若 RUL 一直小于训练集中的最大寿命,此时,寿命衰减起始点即为测试起始点,对应线性 RUL 衰减模型。

2.3 卷积神经网络记忆保留机制

本文将每次训练的寿命衰减模型保留并作为下一次训练的初始模型进行训练,继承训练结果。图 4 为训练过程流程图。

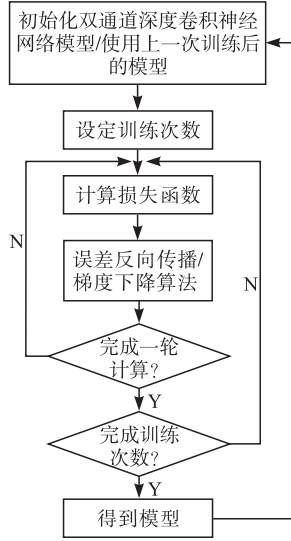


图 4 训练过程流程图

3 卷积神经网络

3.1 卷积

本文采用卷积神经网络对时间序列数据进行预测,以 FD001 为例,重构后的数据片为:

$$x = \begin{bmatrix} a_{1,1}, a_{1,2}, \dots, a_{1,18} \\ a_{2,1}, a_{2,2}, \dots, a_{2,18} \\ \vdots \\ a_{30,1}, a_{30,2}, \dots, a_{30,18} \end{bmatrix} \quad (5)$$

卷积运算是利用卷积核对数据进行特征提取,采用共享网络权值的方法降低了网络复杂度,提升训练速度。若采用卷积核 u , 大小为 $k \times 1$ 。

$$u = (u_1, u_2, \dots, u_k) \quad (6)$$

若该卷积核提取的数据为 p , 大小为 $1 \times k$ 。

$$p = (a_{i,j}, a_{i+1,j}, \dots, a_{i+k-1,j})^T \quad (7)$$

卷积结果为:

$$C_i = \varphi(Up - b) \quad (8)$$

式中: φ 为激活函数,一般采用非线性函数; b 为偏置; p 为感受野,长度为 k ,经过多层卷积,将结果输入到全连接层,得到结果与真实值差值,采用梯度下降算法更新网络权值。

3.2 网络参数设置

本文使用卷积神经网络分为 7 层(包括 5 个卷积层,2 个全连接层),深度卷积神经网络结构如图 5 所示。本文选择 2 种卷积核,大小分别为(10,1)和(3,1),池化层选择最大池化,大小为(2,2),每层添

加 dropout() 操作,防止产生过拟合。激活函数统一采用 Relu() 函数。

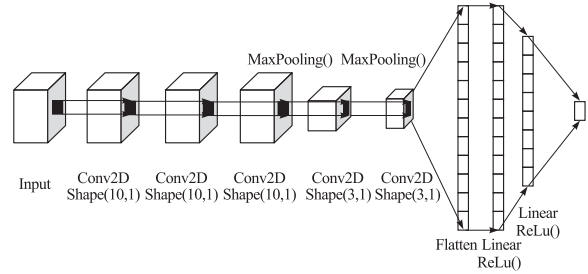


图 5 深度卷积神经网络结构

3.3 双通道网络结构

本文采用双通道网络结构对不同的特征进行训练,采用寿命衰减起始点判断方法对 2 种寿命衰减过程进行区分,将寿命衰减前、寿命衰减中 2 种特征作为双通道网络模型的输入。相较于单通道网络模型,能保留更多数据,提高预测精度。双通道网络模型结构如图 6 所示。




图 6 多通道网络模型

4 实验验证

按照前面的模型结构在 Intel I7-10750H, 2.6 GHz CPU, 16 GiB RAM, NVIDIA GEFORCE RTX 2070 GPU, Pytorch 1.81 的环境下搭建 CNN 结构。

4.1 数据降噪

使用卡尔曼滤波对传感器数据进行降噪,以 train_FD004 为例,降噪前的传感器参数值如图 7(a)所示,降噪后的传感器参数值如图 7(b)所示。


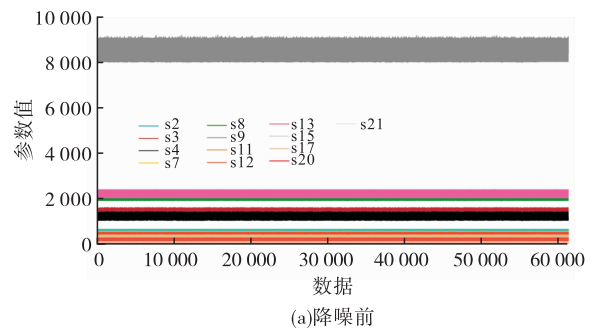


图 7 降噪前后 train_FD004 中传感器参数值

对降噪后的数据进行重构,将重构后的 train_FD001~FD004 作为训练集训练网络权值,将重构后的 test_FD001~FD004 作为测试集得到预测结果。

4.2 评价标准

进行误差分析时通常采用回归评价标准均方根误差(root mean square error, RMSE,公式中简写为 E_{RMS}),如式(9)所示:

$$E_{\text{RMS}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_{i \text{ true}} - y_{i \text{ predict}})^2} \quad (9)$$

相对预测误差 E_{rr} ,如式(10)所示:

$$E_{\text{rr}} = \frac{1}{m} \sum_{i=1}^m \frac{|y_{i \text{ true}} - y_{i \text{ predict}}|}{t} \quad (10)$$

该评价标准很好地反映了观测值同真实值之间的偏差,值越小就说明偏差越小。

此外,得分可以反映该模型超前或者滞后预测的程度,因此,在进行评价时,要将得分函数 s_i 也作为评价标准之一。在 RMSE 相同时,得分函数越小,说明 RUL 预测结果偏向于预测值小于真实值,符合航空发动机 RUL 预测问题特性^[14],单个预测结果的得分 s 的计算如式(11)所示,得分函数 s_i 计算如式(12)所示:

$$s_i = \begin{cases} e^{\frac{y_{i \text{ predict}} - y_{i \text{ true}}}{10}} - 1, & y_{i \text{ predict}} > y_{i \text{ true}} \\ e^{\frac{y_{i \text{ true}} - y_{i \text{ predict}}}{13}} - 1, & y_{i \text{ predict}} < y_{i \text{ true}} \end{cases} \quad (11)$$

$$s_f = \frac{\sum_{i=1}^m s_i}{m} \quad (12)$$

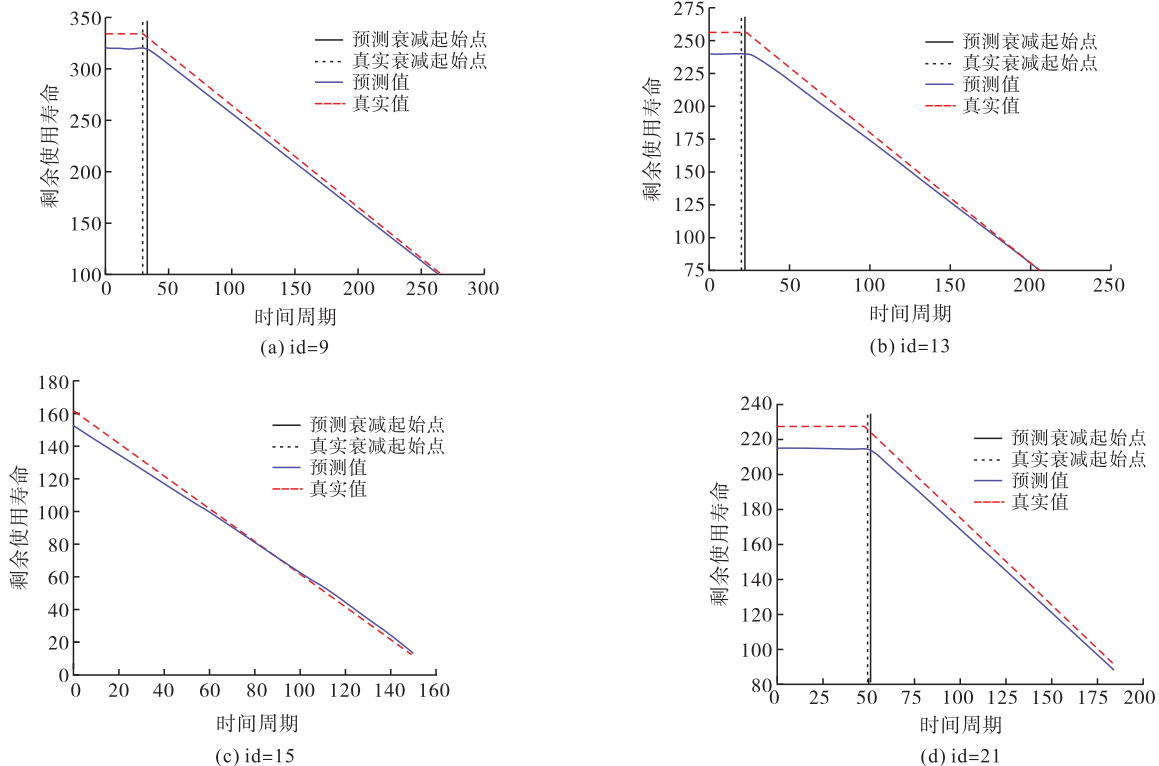


图9 降噪前 FD004 中样本航空发动机的预测结果

式中: m 为数据量; $y_{i \text{ true}}$ 为真实值; $y_{i \text{ predict}}$ 为预测值; t 为该航空发动机总寿命。

4.3 预测结果及分析

将数据输入到卷积神经网络中训练,迭代 20 次,并使用训练后的数据进行预测,以数据集 FD004 为例,预测误差分布直方图(预测值-真实值)如图 8 所示。

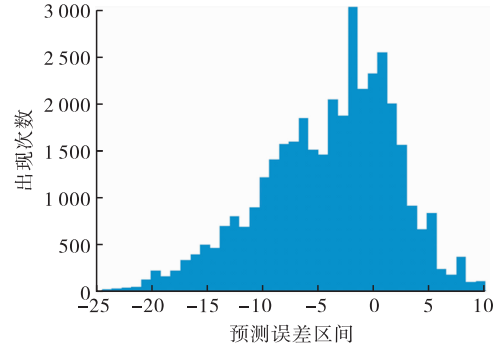


图8 预测误差直方图

从预测误差分布直方图可以看出在数据集 FD004 中 41 214 条数据的预测误差范围在 $-20 \sim 10$ 之间,其中大部分误差小于 0,表示本方法预测结果偏向于预测值小于真实值。在航空发动机寿命预测角度上,预测值小于真实值带来的安全隐患较小,符合航空发动机寿命预测问题特性。

从 test_FD004 中随机选取 4 个航空发动机作为测试样本,降噪前预测值和真实值对比如图 9 所示。降噪后预测值和真实值对比如图 10 所示。

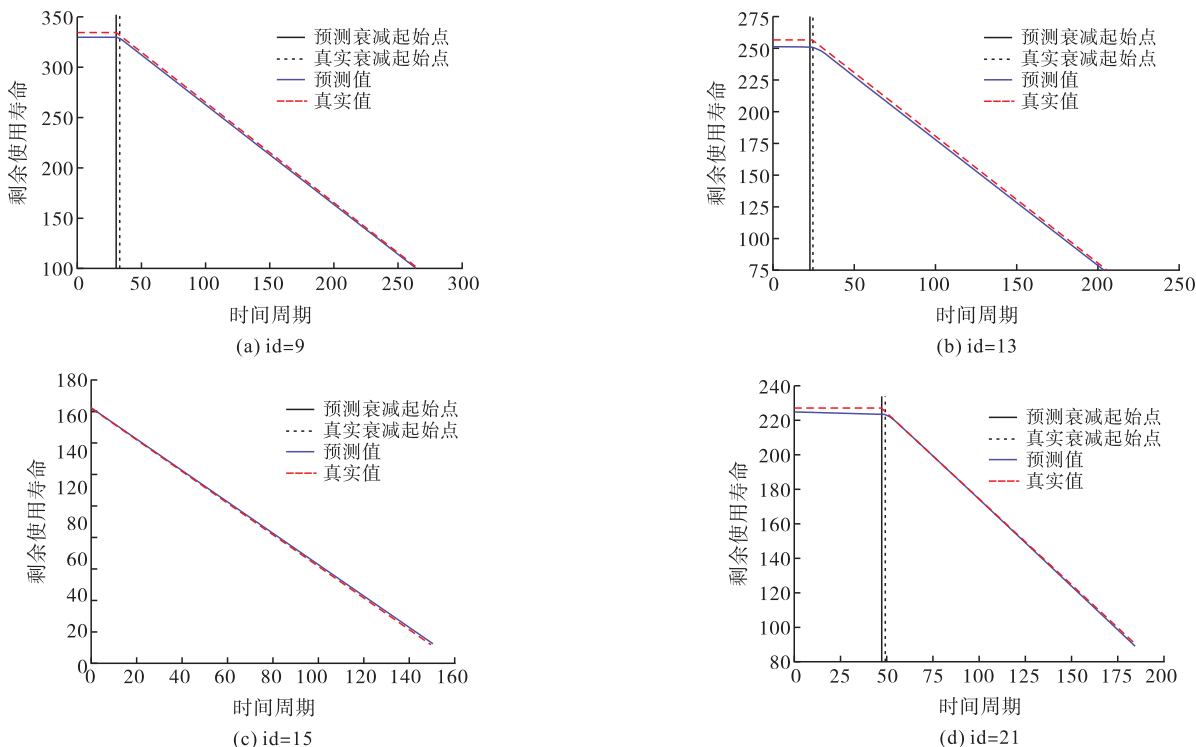


图 10 降噪后 FD004 中样本航空发动机的预测结果

图 9 和图 10 中对比了降噪前后预测结果的差异,说明了降噪之后可以有效减少数据噪声带来的影响。预测开始时,误差相对较大,是由于模型带来的误差,经过迭代,预测的误差相对较小。

同理,对 FD001 和 FD003 数据进行预测,取 5 次实验结果的平均值,数据集 FD003 的 s_f 和 E_{RMS} 指标和其他方法^[15]的对比如表 3 所示。

数据集 FD001 和 FD003 的相关指标和其他算法^[15]的对比如表 4 所示。

从表 3 中可以看出,数据量的大小不会引起两项指标的大幅变化,分布比较均匀。

表 4 中 p_n 表示预测相对误差小于或等于 n 的样本百分比,在样本大小相同时, p_5 越大,预测表现越好。 p_5 相等时, p_{10} 越大,预测表现越好,以此类推。

本方法在数据量较多时,预测结果明显优于其他方法,当剩余周期次数大于 20 时, s_f 和 E_{RMS} 两项指标均优于其他方法,原因在于本方法预测结果偏向于预测值小于真实值,计算 s_f 时较有优势。符合航空发动机寿命预测问题特性,验证了该方法在航空发动机 RUL 预测上具有显著优势。

表 3 数据集 FD003 的评价结果对比

评价指标	模型	最后周期个数					
		0	10	20	30	40	50
s_f	LSTM 无衰减起始点	0.48	0.43	0.62	0.91	1.01	1.65
	RNN 固定衰减起始点	0.51	0.23	0.52	0.71	0.98	1.86
	LSTM 固定衰减起始点	0.40	0.49	0.61	0.86	1.88	1.25
	Dual-LSTM	0.10	0.20	0.49	0.62	0.95	1.10
	TCDCNN	0.19	0.34	0.21	0.22	0.27	0.31
E_{RMS}	LSTM 无衰减起始点	4.01	3.29	5.09	7.69	12.04	8.97
	RNN 固定衰减起始点	4.16	2.61	4.92	6.56	7.61	7.85
	LSTM 固定衰减起始点	3.63	4.35	5.28	8.96	11.55	7.05
	Dual-LSTM	1.38	2.53	5.43	5.27	7.09	7.11
	TCDCNN	2.31	2.51	2.50	2.57	2.71	2.83

表 4 数据集 FD001 和 FD003 的评价结果对比

数据集	模型	最后 50 个周期				最后 10 个周期				最后 5 个周期			
		$p_5/\%$	$p_{10}/\%$	$p_{20}/\%$	s_f	$p_5/\%$	$p_{10}/\%$	$p_{20}/\%$	s_f	$p_5/\%$	$p_{10}/\%$	$p_{20}/\%$	s_f
FD001	Standard RNN	10	35	60	5 581.41	75	90	95	256.34	85	95	95	118.52
	Vanilla LSTM	30	55	70	37.51	100	100	100	0.43	100	100	100	0.30
	Dual-LSTM	40	70	100	1.15	100	100	100	0.22	100	100	100	0.12
	GRU	45	85	85	17.96	100	100	100	0.35	100	100	100	0.53
	TCDCNN	87	100	100	0.36	100	100	100	0.37	100	10	100	0.30
FD003	Standard RNN	35	60	85	48.96	100	100	100	0.36	95	100	100	0.45
	GRU	40	65	95	14.26	90	100	100	1.45	85	100	100	1.74
	Vanilla LSTM	50	70	90	30.58	100	100	100	0.23	100	100	100	0.21
	Dual-LSTM	60	90	100	1.10	100	100	100	0.20	100	100	100	0.12
	TCDCNN	75	100	100	0.31	100	100	100	0.34	100	100	100	0.23

5 结语

本文针对航空发动机 RUL 难以准确预测的问题,提出了 TCDCNN 方法,通过对 2 种寿命衰减模型进行分类,实现 C-MAPSS 涡轮风扇发动机寿命退化数据的预测,并与其他算法的预测结果进行比较分析,验证了该方法在测试数据范围较大时,可以更加准确地判断航空发动机寿命衰减起始点和 RUL,进一步提高预测准确度。决策者可以根据预测结果,及时地做出有效的维修决策,防止剩余使用寿命浪费和因航空发动机故障而导致其他部件的损坏,以提高寿命利用率、降低维修成本和事故频率。

参考文献

- [1] SAXENA A, GOEBEL K. Turbofan Engine Degradation Simulation Data Set [EB/OL]. (2010-12-22) [2021-12-06]. <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>.
- [2] CHEHADE A, BONK S, LIU K. Sensory-Based Failure Threshold Estimation for Remaining Useful Life Prediction[J]. IEEE Transactions on Reliability, 2017, 66(3):939-949.
- [3] TIAN Z. An Artificial Neural Network Method for Remaining Useful Life Prediction of Equipment Subject to Condition Monitoring [J]. Journal of Intelligent Manufacturing, 2012, 23(2):227-237.
- [4] HEIME F O. Recurrent Neural Networks for Remaining Useful Life Estimation[C]// Prognostics and Health Management. Piscataway, NJ: IEEE, 2008:1-6.
- [5] GUGULOTHU N, TV V, MALHOTRA P, et al. Predicting Remaining Useful Life Using Time Series Embeddings Based on Recurrent Neural Networks [J]. ACM, 2017, 9(1):1-10.
- [6] SHUAI Z, RISTOVSKI K, FARAHAT A, et al. Long Short-Term Memory Network for Remaining Useful Life Estimation[C]// 2017 IEEE International Confer-

ence on Prognostics and Health Management (ICPHM). Piscataway, NJ: IEEE, 2017:1-8.

- [7] ZHOU F, HU P, YANG X. RUL Prognostics Method Based on Real Time Updating of LSTM Parameters [C]//2018 Chinese Control and Decision Conference (CCDC). Piscataway, NJ: IEEE, 2018:3966-3971.
- [8] HSU C S, JIANG J R. Remaining Useful Life Estimation Using Long Short-Term Memory Deep Learning [C]//2018 IEEE International Conference on Applied System Invention (ICASI). Piscataway, NJ: IEEE, 2018:58-61.
- [9] AL-DULAIMI A, ZABIHI S, ASIF A, et al. NBLSTM: Noisy and Hybrid CNN and BLSTM-Based Deep Architecture for Remaining Useful Life Estimation[J]. Journal of Computing and Information Science in Engineering, 2019, 20(2):1-14.
- [10] ZHANG C, LIM P, QIN A K, et al. Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10):2306-2318.
- [11] 张国辉. 基于深度置信网络的时间序列预测方法及其应用研究[D]. 哈尔滨:哈尔滨工业大学, 2017:1-51.
- [12] 罗华柱. 基于改进 SVM 的航空发动机预测方法研究[D]. 南昌:南昌航空大学, 2017:2-22.
- [13] BABU G S, ZHAO P, LI X L. Deep Convolutional Neural Network-Based Regression Approach for Estimation of Remaining Useful Life [C]//International Conference on Database Systems for Advanced Applications. Berlin:Springer, 2016:214-228.
- [14] 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.
- [15] SHI Z, CHEHADE A. A Dual-LSTM Framework Combining Change Point Detection and Remaining Useful Life Prediction[J]. Reliability Engineering & System Safety, 2021, 205:107257.

(编辑:姚树峰)