

文章编号: 1005-0523(2022)06-0090-08



基于融合神经网络的发动机排气温度裕度预测

李杰, 孟凡熙, 张子辰, 朱玮

(长安大学电子与控制工程学院, 陕西 西安 710064)

摘要:民用航空发动机排气温度裕度(EGTM)的变化趋势反映了其性能衰退情况,为使用EGTM的变化趋势来映射其性能衰退情况,提出了一种经验模态分解(EMD)算法与卷积长短期记忆网络(CNN-LSTM)相融合的EGTM组合预测模型。采用EMD将原始EGTM序列分解为多个固有模态分量和残差分量,并将所有分量作为模型输入,利用卷积长短期记忆网络捕获各分量非线性相关性并提取长时依赖关系,构建深度学习模型框架。为验证所提方法的有效性,采用某航空公司10a的EGTM的实际测试数据进行实验分析,并设计了5种神经网络作为竞争模型进行对比研究。实验结果表明:相比于竞争模型,所提出的EMD-CNN-LSTM组合预测模型可使平均绝对误差和均方根误差降低37.82%和33.01%,拟合优度提高1.02%,此外,当EGTM处于敏感区域时,所提出模型的EGTM单点预测精度显著高于其他竞争模型。结果表明,该融合神经网络模型在民航发动机EGTM预测中具有较好的准确性和稳定性。

关键词:排气温度裕度预测;民航发动机;经验模态分解;融合神经网络

中图分类号: V233.7

文献标志码: A

本文引用格式: 李杰, 孟凡熙, 张子辰, 等. 基于融合神经网络的发动机排气温度裕度预测[J]. 华东交通大学学报, 2022, 39(6): 90-97.

DOI: 10.16749/j.cnki.jecjtu.20221104.009

Exhaust Gas Temperature Margin Prediction of Aeroengine Based on Fusion Neural Network

Li Jie, Meng Fanxi, Zhang Zichen, Zhu Wei

(School of Electronics and Control Engineering, Chang'an University, Xi'an 710064, China)

Abstract: The change trend of exhaust gas temperature margin (EGTM) of civil aviation engine reflects its performance degradation. In order to employ the change trend of EGTM to map the performance degradation of the engine, an deep integrated neural network prediction method based on empirical mode decomposition (EMD) algorithm and convolution short-term memory network (CNN-LSTM) is proposed in this study. EMD was used to decompose the original EGTM sequence into multiple natural mode components and residual components, and all the resulting components were used as model input. The convolution long-term and short-term memory network was used to capture the nonlinear correlation of each component and extract the long-term dependence to construct the framework of deep learning model. In order to verify the effectiveness of the proposed method, the actual test data of EGTM of an airline for 10 years were used for experimental analysis, and 5 kinds of neural networks were designed as competitive models for comparative study. The experimental results show that the proposed EMD-CNN-LSTM fusion neural network model can reduce the mean absolute error and the root mean square error by 37.82% and 33.01%, and increase the goodness for fitting by 1.02%, compared with competitive

收稿日期: 2022-01-19

基金项目: 国家市场监督管理总局科技计划项目(2021MK104); 科技部国际科技合作项目(G2021171024L)

models. Furthermore, when EGTM is in the sensitive area, EGTM single-point prediction accuracy of the proposed model is significantly higher than that of other competitive models. Therefore, the proposed fusion neural network model has good accuracy and stability in EGTM prediction of civil aviation engine.

Key words: exhaust gas temperature margin prediction; civil aeroengine; empirical mode decomposition; fusion neural network

Citation format: LI J, MENG F X, ZHANG Z C, et al. Exhaust gas temperature margin prediction of aeroengine based on fusion neural network[J]. Journal of East China Jiaotong University, 2022, 39(6): 90-97.

在飞机起动和起飞阶段,其排气温度(exhaust gas temperature, EGT)和排气温度裕度(exhaust gas temperature margin, EGTM)是一种与发动机状态及性能强相关的气路参数,是航空发动机健康管理监测的重要参数之一^[1-2]。航空公司在实际运营中,通过监测及预测飞机EGTM的变化情况,了解飞机发动机的健康状态,对于发动机运行的安全性与经济性具有重要意义。随着人工智能技术的发展,以大数据为基础的深度学习算法在寿命预测方向的成功应用为EGTM的预测提供了新的思路。例如,Ding等^[3]提出了一种基于卷积神经网络(convolutional neural network, CNN)的锂电池剩余使用寿命预测和健康管理方法,使用CNN捕获剩余信号中的预期成分,具有较好的预测稳定性。Miao等^[4]设计并建立了以长短期记忆网络(long-short term memory, LSTM)为基础的双任务深长短时记忆网络,用于航空发动机退化评估和剩余使用寿命预测的联合学习。Ren^[5]提出了一种基于改进CNN和LSTM的锂电池寿命预测方法,来挖掘有限数据中的深层信息。

经验模态分解(empirical mode decomposition, EMD)^[6-7]和CNN-LSTM相融合的EGTM预测方法,采用EMD将原始EGTM序列分解为多个固有模态分量和残差分量,从而从不同模态上,进一步解释了EGTM信号的物理含义,将所得分量作为卷积长短期记忆网络模型输入,加深了神经网络对EGTM信号的理解。为了验证该方法的有效性,设计了多层感知机(multi-layer perceptron, MLP)、CNN、循环神经网络(recurrent neural network, RNN)、LSTM和CNNLSTM作为竞争模型,对比验证了所提出模型的性能。

1 民航发动机的排气温度裕度分析

1.1 民航发动机的排气温度裕度定义

EGTM定义为航空发动机在海平面压力以及拐

点温度条件下,全功率起飞时发动机排气温度(EGT)与EGT最大值之间的差值 T_{EGM} 计算方法为

$$T_{EGM} = T_{Emax} - T_{Ea} \quad (1)$$

式中: T_{Emax} 为发动机最大排气温度,℃,即发动机工作过程中,所容许出现的排气温度最大值,是该型发动机设计厂商给定的重要设计参数; T_{Ea} 为发动机处于全功率状态时的排气温度值,℃,当发动机处于起飞状态时,应对其进行检测,为反映发动机健康状况的关键参数之一,即EGTM包含了该型发动机在翼劣化程度的信息。

1.2 实验数据介绍与处理

本文采用某航空公司的某型30台民航发动机在采样频率为200个飞行循环(Cycle)下的EGTM历史测量数据(同一测量环境)作为数据集,以评价所提出模型的性能。本文将随机选取的25台民航发动机的EGTM数据作为训练集(包含1465个工作点,飞行循环次数为 $1465 \times 200 = 293\,000$ 次),剩余5台民航发动机的EGTM数据作为测试集(包含291个工作点,飞行循环次数为 $291 \times 200 = 58\,200$ 次)。

图1展示了该30台民航发动机的EGTM数值的正态分布情况,由图可知,数据整体符合以均值为70℃的正态分布(对称分布),这将有利于训练集和测试集的划分。值得注意的是,当民航发动机在下发一段时间后,排气温度裕度处在以均值70℃为中心的[60℃, 80℃]范围内的点占比最高,可反映此时民航发动机处于稳定的工作状态。若当EGTM值下降到60℃附近时,可说明该型民航发动机将由稳定工作区过渡到[50℃, 60℃]的敏感工作区,此时可将60℃作为敏感点。若当EGTM的值持续下降时,[40℃, 50℃]的点的数量出现了骤降情况,这意味着该型民航发动机开始出现了不同程度的性能衰退现象,即由敏感区域过渡到衰退区。




图1 民航发动机EGTM的数据分布

Fig.1 Data distribution of EGTM of civil aviation engine

另外,处在 $[105\text{ }^{\circ}\text{C}, 120\text{ }^{\circ}\text{C}]$ 范围内的点可作为航空发动机的出厂数据,其幅值较大且占比最小,不能准确反映实际的工作状态,且处在 $30\text{ }^{\circ}\text{C}$ 以下范围内的点接近于失效状态,即不在 $1\%\sim 99\%$ 范围内的数据点参与训练时,可能会导致预测模型在过拟合,对EGTM预测的准确度产生较大影响,即考虑将其在后续模型的训练过程中予以剔除。同时,为了提升模型的收敛速度和模型精度,本文采用线性函数归一化(max-min normalization)方法,将EGTM数值转换为区间 $(0, 1)$ 内的小数。归一化方法如下

$$X\% = \frac{X - \text{Min}(X)}{\text{Max}(X) - \text{Min}(X)} \quad (2)$$

式中: X 为原始数据, \tilde{x} 为归一化后的数据。

1.3 时间窗的选取

由于EGTM数据和时间有着很高的依赖关系,这种依赖关系是处理时间序列的关键,所以需要选择合适的时间窗口捕获这些依赖关系。在原始数据中通过滑动时间窗口来生成网络输入,从而生成大小为 $D@S$ 的样本序列进行模型训练,其中 S 表示窗口宽度, D 表示数据特征维度(本文为1)。假设第一个输入的样本序列可由 $S_1=[x_1, x_2, \dots, x_S]$ 表示,当滑动时间窗口滑动 L 步之后,可得第2个输入样本序列 $S_2=[x_{1+L}, x_{2+L}, \dots, x_{S+L}]$,其中 $x_i \in \mathbf{R}^{1 \times D}$ 。若当训练数据共有 φ 个采样点时,则可获得 $(\varphi - S \times L + 1)$ 个样本序列。

在上述序列的构造基础上,对每个输入样本序列添加相应的标签。设所需要预测的时间标签的个数为 $N(N \geq 1)$,则 S_1 的标签可表示为 $y_1=[x_{S+1}, x_{S+2}, \dots, x_{S+N}]$, S_2 的标签可表示为 $y_2=[x_{S+L+1}, x_{S+L+2}, \dots, x_{S+L+N}]$,不失一般性地可以为所有的样本序列添加相应的标签。同时若需要预测某个时间段内的EGTM时,

则仅需要一个宽度为 S ,高度为 D 的时间窗口大小的数据即可。

在本文中,为了能够及时预测出EGTM的变化趋势,取滑动步长 $L(N$ 与 L 代表相同的含义,只是为了方便表示)的长度为1,即实时预测相邻时刻的EGTM值,同时考虑到EGTM的非线性,若 S 取值较大时,则样本序列之间的相关程度会变得稀疏,容易使得CNN丢失有用的信息;因此 S 的取值不宜过大。经过多次试验发现,当取 S 取值为7时,可满足相关的实验要求。

2 融合预测算法

2.1 经验模态分解

民航发动机EGTM受到多方面因素的影响,例如发动机气动核心部件的气动效率,外界大气温度的变化等,表现出了非线性、波动性的特点。非线性和波动性会直接影响EGTM预测的准确性,因此需要对排气温度裕度数据进行初步处理。EMD可以将具有非线性和非平稳性特点的原始信号序列,如EGTM序列,通过经验识别分解为更为稳定的一系列内涵模态分量(intrinsic oscillatory mode, IMF)和一个残余项(residual model, Res),其中残余项可作为EGTM变化的长期趋势模态,即^[6]

$$X(t) = \sum_{i=1}^m \text{IMF}_i(t) + r(t) \quad (3)$$

式中: $X(t)$ 为EGTM原始序列; $\text{IMF}_i(t)$ 为 $X(t)$ 分解出来的第 i 个IMF分量; m 为IMF分量数目, $r(t)$ 为残余项; t 为序列的时间尺度,本文中 $t=15\text{ min}$ 。由于IMF分量必须满足两个约束条件^[6]:

1) 在整个时间序列上,IMF分量的极值点和过零点的个数必须相等或相差不超过一个;

2) 任意时刻,IMF分量的局部上、下包络线均值为0;因此所分解出的IMF分量较为平稳,弱化了原始信号中包含的非线性和波动性成分,通过预测每个IMF分量,可缓解EGTM数据的非线性和波动性对预测结果的影响。

2.2 融合模型原理

本文提出了一种基于CNN-LSTM的深度融合模型用来建立EGTM的IMF分量预测模型,该网络包括两层卷积神经网络和两层长短期记忆网络,其中每层卷积神经网络均由卷积层和池化层组成,如图2所示。

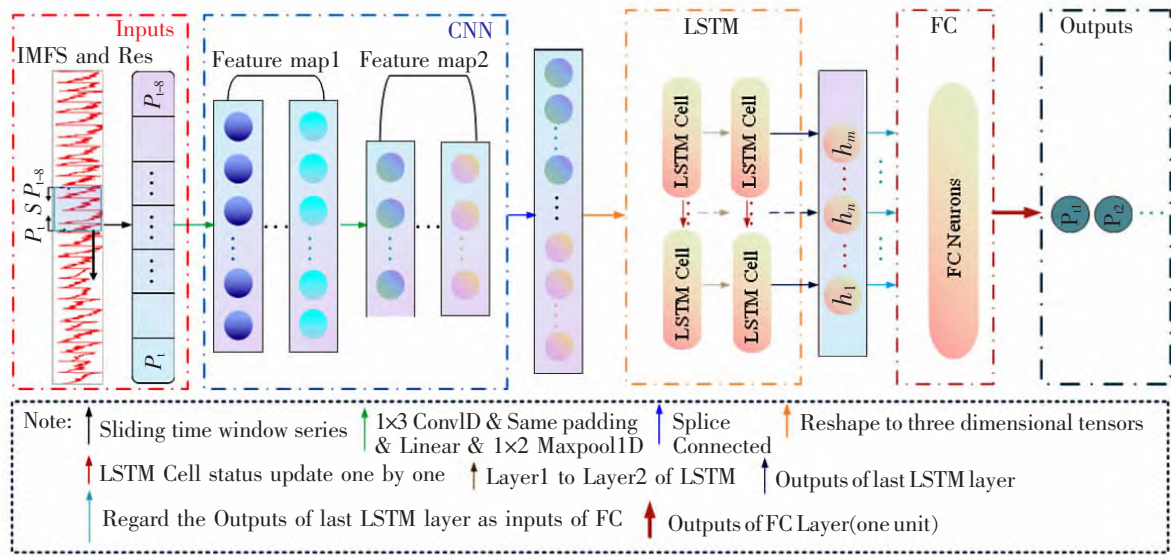


图 2 CNN-LSTM 模型结构
Fig.2 Structure of the CNN-LSTM model

图 2 所示模型首先利用 CNN 强大的空间提取能力从 IMF 分量的时间窗信息数据中提取出隐藏特征,实现数据的降维,以捕获所提取特征中的重要信息,并且可有效抑制噪声信号;其次,EGTM 的衰退过程是有关时间序列的,所以将 CNN 提取的重要特征通过全连接层拼接后作为 LSTM 的输入;随后充分利用 LSTM 的顺序敏感性提取数据中的时间特征,即根据长短期记忆层中某一时刻的单元状态和网络输出值,进行 EGTM 有关时间的衰退特征的提取,建立 EGTM 预测模型;最后将测试集放入模型中,实现对数据的拟合,输出预测的 EGTM 值。

融合模型中的长短期记忆网络如图 3 所示。首先,细胞状态中的信息通过遗忘门进行选择性的遗忘,即进行选择性记忆;其次,新的信息通过输入门选择性地记录到细胞状态中;最后将前面的信息通过输出门保存到隐层中去。

在 t 时刻,细胞状态的更新过程如下^[8-9]

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \text{th}(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (7)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = O_t \times \text{th}(C_t) \quad (9)$$

式中: i_t 为输入门的计算结果; f_t 为遗忘门的计算结果; O_t 为输出门的计算结果; x_t 以及 h_{t-1} 分别作为 t

时刻的输入以及上一时刻的 LSTM 输出值,且将两者进行拼接,作为 t 时刻的输入状态; W_f 、 W_i 、 W_c 和 W_o 分别对应遗忘门、输入门和输出门的权值矩阵, b_f 、 b_i 、 b_c 和 b_o 为相应的偏置矩阵; C_{t-1} 为旧的细胞状态, $f_t \times C_{t-1}$ 为遗忘门决定忘记的状态信息, \tilde{C}_t 为新的候选值向量, C_t 为更新后的细胞状态(t 时刻细胞状态);“ \times ”表示两个向量按元素相乘, $\sigma(*)$ 为 sigmoid 激活函数, $\text{th}(*)$ 为 \tanh 激活函数。




图 3 单个 LSTM 单元的内部结构
Fig.3 Internal structure of a single LSTM unit

2.3 融合模型参数设置

神经网络的层数和各层神经元数目对训练结果有重要影响,即训练时间和训练难度随着神经网络层数加深而增加,可能会出现过拟合问题,因此并不能依靠增加网络层数和神经元数目来提高训练结果。经过多次实验发现,建立如表 1 所示的神经网络时,可获得最优结果。

3 模拟计算与结果分析

本文所有算法是在 Python3.7 和 PyCharm 2019 上运行的,计算设备是 Intel Core i5-8250U CPU, 8 GB RAM 计算机。

表 1 模型参数设置

Tab.1 Parameter settings of the model

Type	Parameters
First layer of Conv1D	5(size=1×3)
Second layer of Conv1D	5(size=1×3)
First layer of LSTM	200
Second layer of LSTM	50
Dense	1
learning_rate	3.5e-2
batch_size	64
epoch	50
Loss function	MAE
Stride	1
Time step	7
Optimizer	Adam
Dropout	0.5
Pooling size	1×2
Activation function	Relu

3.1 性能评价指标

选用平均绝对误差(mean absolute error,MAE),均方根误差(root mean square error, RMSE)以及拟合优度 R^2 作为本文所提出算法的性能指标,对 EGTM 的预测性能做评价。其中 MAE 和 RMSE, R^2 分别衡量预测值与真实值之间的误差,以及评价预测值与真实值之间预测拟合度,且定义 MAE 为损失函数(Loss)。MAE, RMSE 以及 R^2 的计算方法为^[10]

$$MAE = \frac{1}{m} \left(\sum_{i=1}^m |h_i - h_i^k| \right) \quad (10)$$

$$RMSE = \sqrt{\frac{1}{m} \left(\sum_{i=1}^m |h_i - h_i^k|^2 \right)} \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^m (h_i - h_i^k)^2}{\sum_{i=1}^m (\bar{h}_i - h_i^k)^2} \quad (12)$$

从 MAE、RMSE 以及 R^2 的表达式可知,当预测值与真实值越接近时,MAE, RMSE 的值越小, R^2 值

越大,即误差越小,拟合度越高,模型的准确度和精度越高。

3.2 经验模态分解分析

EGMT 序列经过 EMD 进行经验模态分解后,得到 8 个 IMF 分量和 1 个残余项(Residual),如图 4 所示。由图 4 可知,单台发动机原始的 EGTM 具有较为明显的下降趋势,但原始 EGTM 数据仍然存在波动性和不稳定性。经过 EMD 分解后的残差分量的趋势与原始数据相符,且残差分量具有较大的幅值,但相较于原始数据而言更加平滑稳定。相较而言,IMFS 分量存在不同程度的波动,包含短期波动,如 IMF1~IMF4 分量;中期波动,如 IMF5~IMF6,短期波动,如 IMF7~IMF8,且 IMFS 分量具有较小的幅值,这说明 IMFS 分量代表了原始数据中的多种波动成分,体现出原始数据的波动性。由此可见,IMFS 分量决定了原始数据的波动性,是原始数据不稳定的原因;残差分量决定了原始数据的整体趋势,是原始数据的主要组成部分。对 IMFS 的精准预测有利于提高预测精度,而对残差分量的精准预测是整体预测结果准确的关键。




图 4 EMD 分解结果

Fig.4 The result of EMD decomposition

3.3 模型验证与误差分析

本节设计了 MLP, CNN, RNN 和 LSTM 等深度神经网络模型作为竞争模型, 对比验证所提出的 EMD-CNN-LSTM 组合预测模型的精度和可靠性, 同时为了验证 EMD 的贡献, 考虑竞争模型在 EMD 作用下的预测性能。

图 5 展示了上述不同模型在训练过程中的损失函数变化情况, 其中横坐标表示模型训练过程中的迭代次数。

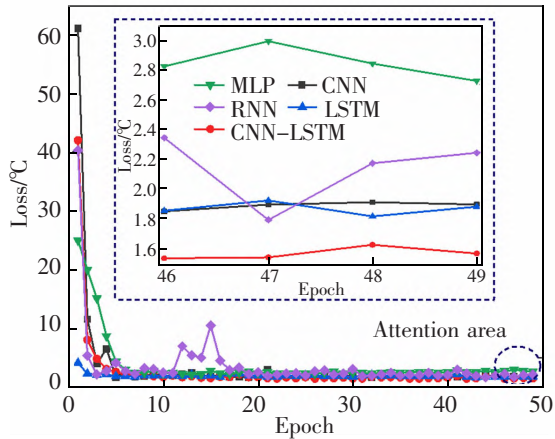



图 5 训练过程中的 loss 值变化

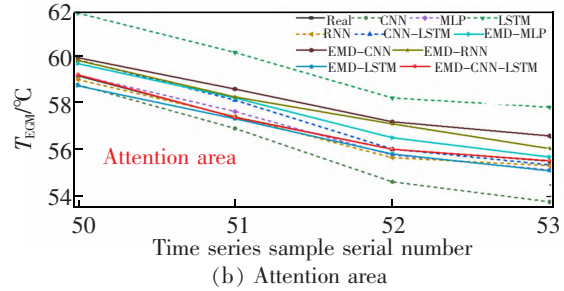
Fig.5 Iterative trend of loss value during training

由图 5 可知, 竞争模型的损失函数在迭代过程中存在不同程度的波动情况, 这说明竞争模型在训练过程中陷入了局部最优点。而 EMD-CNN-LSTM 的损失函数在迭代过程中不存在波动情况, 且保持较低的稳定值。

在上述训练的基础上, 为了全面展示所提模型的性能, 随机从测试集中选择一台发动机进行分析, 结果如图 6 所示。图 6 中展示了不同的深度神经网络模型预测的 EGTm 变化趋势。由图 6 可知, 在 EGTm 的早期预测时, 所有模型均存在不同程度的波动, 导致其无法准确捕捉到 EGTm 的变化趋势, 即敏感区域内 EGTm 的准确预测的实际意义更大, 这是因为敏感区域内的 EGTm 较低, 发动机会接近维修或者下发边界, 若能提前准确获知随后飞行循环中 EGTm 的变化情况, 可为发动机及时维修、维护、飞行计划制定提供技术依据。在 EGTm 处于敏感区域内时, 竞争模型均不同程度地偏离真实值, CNN-LSTM 也出现了较为严重的超前预测或滞后预测情况, 这说明原始数据的非线性和非平稳性对于 EGTm 的准确预测具有严重的干扰作用。在 EMD



(a) EGTm prediction results



(b) Attention area

图 6 单一民航发动机的 EGTm 预测

Fig.6 EGTm prediction results of a single civil aviation engine

的作用下, CNN-LSTM 的预测偏离有所改善, 其在敏感区域内展示出了最好的精确度和稳定性。测试集中的预测结果如表 2 所示。

表 2 实验结果的比较

Tab.2 Comparison of the experimental results

Model	MAE	RMSE	R ²
MLP	2.62	3.69	0.942
CNN	1.88	2.72	0.967
RNN	2.23	3.01	0.962
LSTM	1.84	2.52	0.973
CNN-LSTM	1.56	2.09	0.982
EMD-MLP	1.46	2.26	0.980
EMD-CNN	1.54	1.98	0.983
EMD-RNN	1.35	1.88	0.985
EMD-LSTM	1.22	1.74	0.987
EMD-CNN-LSTM	0.97	1.40	0.992

由表 2 可知, 相较于 MLP, CNN, RNN, LSTM, CNN-LSTM 等竞争模型, EMD-CNN-LSTM 的 MAE 分别下降了 62.98%, 48.40%, 56.50%, 47.28%, 37.82%; RMSE 分别下降了 62.06%, 48.53%, 53.49%, 44.44%, 33.01%; R² 分别上升了 5.31%、2.59%、3.12%、1.95%、1.02%, 另外, 相较于 EMD-MLP, EMD-CNN, EMD-RNN, EMD-LSTM 等模型, EMD-CNN-LSTM 的 MAE 分别下降了 33.56%, 37.01%, 28.15%, 20.49%; RMSE 分别下降了 38.05%, 29.29%, 25.53%, 24.29%; R² 分别上升了 1.22%,

0.92%,0.71%,0.51%。预测结果的误差范围在一定程度上可以反映预测结果的稳定性。

图7展示了模型在测试集下的预测误差分布图。




图7 不同模型的预测误差范围比较

Fig.7 Comparison of the prediction error ranges of different models

由图7的箱线图可知,EMD-CNN-LSTM的1%~99%的预测误差落在[-4,4]范围内,远小于其他模型的分布范围,且[-0.2,0.2]范围内的误差值占比最高,且更接近于0,同时并没有出现异常点,这表明所提出的模型具有最佳的预测稳定性。

3.4 拟合度分析

为了验证所提出模型的单点预测性能,本文对测试集的EGTM预测值和EGTM真实值通过回归函数进行线性回归分析,回归函数可以表示由式(13)所示。

$$Y = \theta \times T + b \quad (13)$$

其中: Y 为预测值; T 为真实值; θ 和 b 分别为最佳线性回归直线的截距和斜率。

由回归函数的定义式可知,在理想条件下,5台发动机的所有预测值完全等于其真实值时,回归曲线是一条斜率为1,截距为0的直线。同时为了进一步强化回归的可靠性,引入 R (皮尔逊相关系数)表示所提模型的EGTM预测趋势与实际的EGTM变化趋势的相关性, R 值越大相关性越强。

由表3统计的回归参数可知,相较于竞争模型,所提模型的 R 具有最大值,这说明,所提模型的EGTM预测趋势与实际的EGTM变化趋势具有较强的相关性,即融合模型对于EGTM的变化趋势具有较好的跟随性。同时结合斜率 θ 和截距 b 的指标

进一步分析可知,所提出模型的回归直线最接近于理想状态,即拟合效果最优。

表3 拟合分析的参数比较

Tab.3 Parameter comparison of fitting analysis

Model	θ	b	R
MLP	1.139 95	-8.274 19	0.987 19
CNN	1.004 06	0.519 20	0.986 08
RNN	0.931 66	6.110 02	0.986 90
LSTM	1.014 08	-0.223 97	0.988 25
CNN-LSTM	0.992 04	0.395 68	0.990 81
EMD-CNN-LSTM	0.996 45	0.304 88	0.995 83

4 结论

1) EMD使得神经网络实现了对EGTM时间序列在不同模态上的深入理解,全面提升了神经网络的预测效果。CNN和LSTM两者融合可实现数据的深度挖掘,从而提升了EGTM预测的准确度、稳定性。

2) 当EGTM处于敏感区域时,竞争模型的预测值与真实值出现了较大的偏差,即出现了较为严重的滞后或超前预测,而EMD-CNN-LSTM仍能保持较好的预测精度及稳定性。这表明了所提出的融合神经网络在EGTM预测中具有较好的适用性。

参考文献:

- [1] GHAROUN H, KERAMATI A, NASIRI M M, et al. An integrated approach for aircraft turbofan engine fault detection based on data mining techniques[J]. Expert Systems, 2019, 36(2): 1-18.
- [2] PENG J A, FENG L A, JH A, et al. Life cycle gas path performance monitoring with control loop parameters uncertainty for aeroengine[J]. Aerospace Science and Technology, 2021, 115: 106775.
- [3] DING P, LIU X J, LI H Q, et al. Useful life prediction based on wavelet packet decomposition and two-dimensional convolutional neural network for lithium-ion batteries [J]. Renewable and Sustainable Energy Reviews, 2021, 148: 111287.
- [4] MIAO H, LI B, SUN C, et al. Joint learning of degradation assessment and RUL prediction for aeroengines via dual-task deep LSTM networks[J]. IEEE Transactions on Industrial Informatics, 2019, 15(9): 5023-5032.

- [5] REN L, DONG J, WANG X, et al. A Data-Driven Auto-CNN-LSTM prediction model for lithium-ion battery remaining useful life[J]. IEEE Transactions on Industrial Informatics, 2021, 7(5): 3478-3487.
- [6] ZE H, CAO, CHIN T, et al. Inherent fuzzy entropy for the improvement of EEG complexity evaluation[J]. IEEE Transactions on Fuzzy Systems, 2018, 26(2): 1035-1035.
- [7] 朱颖, 赵欣欣, 孙大奇, 等. 北斗卫星监测大跨桥梁基础变位算法[J]. 哈尔滨工业大学学报, 2021, 53(2): 168-174.
- ZHU Y, ZHAO X X, SUN D Q, et al. Algorithm of Beidou satellite monitoring long span bridge foundation displacement[J]. Journal of Harbin Institute of Technology, 2021, 53(2): 168-174.
- [8] HUANG Y M, DAI X Y, WANG Q, et al. A hybrid model for carbon price forecasting using GARCH and long short-term memory network[J]. Applied Energy, 2021, 285: 116485.
- [9] KOUCHAK S M, GAFFAR A. Detecting driver behavior using stacked long short term memory network with attention layer[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(6): 3420-3429.
- [10] YIN H, OU Z, FU J. A novel transfer learning approach for

wind power prediction based on a serio-parallel deep learning architecture[J]. Energy, 2021, 234: 121271.



第一作者: 李杰(1984—), 男, 副教授, 博士, 研究方向为机器学习, 智能交通等。E-mail: jli@chd.edu.cn。



通信作者: 朱玮(1984—), 女, 副教授, 博士, 研究方向为人工智能, 类脑计算等。E-mail: wzhu@chd.edu.cn。

(责任编辑: 姜红贵)