

基于 LSTM 神经网络的燃气轮机排温预测方法

韩国栋¹, 曹云鹏¹, 王伟影², 徐志强²

(1. 哈尔滨工程大学 动力与能源工程学院, 黑龙江 哈尔滨 150001;

2. 中国船舶集团有限公司第七〇三研究所, 黑龙江 哈尔滨 150078)

摘要: 针对燃气轮机气路性能退化的周期性与非线性特点, 提出一种基于长短期记忆(Long-Short Term Memory, LSTM)神经网络的燃气轮机排气温度趋势预测方法。利用标准化与归一化数据预处理方法提取排气温度数据中的退化特征, 减小了环境和工况变化对退化特征的影响; 通过滑窗法提取一定长度的历史数据, 增强 LSTM 模型的泛化能力; 利用 LSTM 网络的内部循环节点, 通过时序相似性搜索, 实现退化周期燃气轮机排气温度预测。最后, 采用船用燃气轮机水洗周期历史数据进行排气温度趋势预测试验。研究表明: 基于 LSTM 排气温度预测方法的预测精度大于 87.4%, 且预测结果的波动性和滞后性较小。

关键词: 燃气轮机; 性能退化; 排气温度; 趋势预测; 长短时记忆网络

中图分类号: TK478

文献标识码: A

DOI: 10.16146/j.cnki.rndlge.2022.03.005

[引用本文格式] 韩国栋, 曹云鹏, 王伟影, 等. 基于 LSTM 神经网络的燃气轮机排温预测方法[J]. 热能动力工程, 2022, 37(3): 28-34. HAN Guo-dong, CAO Yun-peng, WANG Wei-ying, et al. Prediction method of gas turbine exhaust temperature based on LSTM neural network[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(3): 28-34.

Prediction Method of Gas Turbine Exhaust Temperature based on LSTM Neural Network

HAN Guo-dong¹, CAO Yun-peng¹, WANG Wei-ying², XU Zhi-qiang²

(1. College of Power and Energy Engineering, Harbin Engineering University, Harbin, China, Post Code: 150001;

2. No. 703 Research Institute of CSSC, Harbin, China, Post Code: 150078)

Abstract: Aiming at the periodic and nonlinear characteristics of gas path performance degradation of gas turbine, a kind of prediction method of gas exhaust temperature trend based on long-short term memory (LSTM) neural network was proposed. The standardized and normalized data preprocessing method was used to extract the degradation features of exhaust temperature data, which reduced the influence of environment and working condition changes on the degradation characteristics. The sliding window method was used to extract a certain length of historical data to enhance the generalization ability of LSTM model. The internal cycle nodes of LSTM network were used to realize the gas turbine exhaust temperature prediction in degradation cycle by means of the sequential similarity search. Finally, the historical data of marine gas turbine in washing cycle was used for the exhaust temperature trend prediction test. The research results show that the prediction accuracy of exhaust temperature prediction method based on LSTM is greater than 87.4%, and the fluctuation and hysteresis of the prediction results are small.

Key words: gas turbine, performance degradation, exhaust temperature, trend prediction, long-short term memory (LSTM) network

收稿日期: 2021-06-17; 修订日期: 2021-07-02

基金项目: 国家科技重大专项(2017-I-0007-0008)

Fund-supported Project: National Science and Technology Major Project(2017-I-0007-0008)

作者简介: 韩国栋(1995-), 男, 山西太原人, 哈尔滨工程大学硕士研究生。

通讯作者: 曹云鹏(1979-), 男, 河北辛集市人, 哈尔滨工程大学副教授。

引言

在海洋盐雾、磨损和腐蚀等因素影响下,船用燃气轮机气路性能在服役期间不可避免地退化,降低了其变工况安全裕度,直接影响运行可靠性、安全性和经济性^[1-2]。因此,有必要开展燃气轮机性能退化趋势预测研究,预估劣化程度,为燃气轮机视情维修提供决策信息。

测控系统记录了燃气轮机服役周期时序数据。其中,排气温度蕴含了燃气轮机服役周期性能退化信息,是评估气路技术状态的主要依据。目前,基于数据驱动的趋势预测方法通过学习时序数据演化规律,推测未来状态的趋势。刘保果等人^[3]利用最小二乘法、三次指数平滑和灰色模型,结合组合预测与虚拟预测的思想,对燃气轮机状态参数进行了趋势预测,能够有效提高预测精度。崔建国等人^[4]提出了一种基于 LSSVM-WNN 的燃气轮机状态趋势预测方法,结合某型燃气轮机验证,得到组合预测模型的相对预测误差结果为 0.12%。孙跃武^[5]通过时间序列 ARIMA 模型预测了燃气轮机的排气温度、燃油流量等单参数值的变化趋势,进而实现了燃气轮机清洗时刻的判断。

然而,船用燃气轮机退化过程的非线性特点,同时伴随环境温度、运行负载等工况条件的变化,给燃气轮机性能退化趋势准确预测带来了很大困难。为此,本文引入适用于处理非线性时域动态系统建模的长短期记忆(Long-Short Term Memory, LSTM)神经网络,利用 LSTM 模型隐含层内的循环记忆结构,提取服役燃气轮机排温的时序特征,建立历史数据间的非线性时域关联关系,学习历史数据中的退化规律,实现对燃气轮机气路退化状态的趋势预测。研究了特征参数标准化和归一化预处理方法,以及滑窗重叠采样技术,提高燃气轮机在复杂环境与工况因素影响下气路性能退化趋势预测模型迁移和泛化能力,为燃气轮机健康监测与评估提供了有益的技术途径。

1 长短期记忆网络

递归神经网络(Recurrent Neural Network, RNN)是深度学习的一个分支,利用内部记忆和反馈,学习复杂的非线性动态映射^[6]。图 1 为递归神经网络的

隐含层展开图模型。

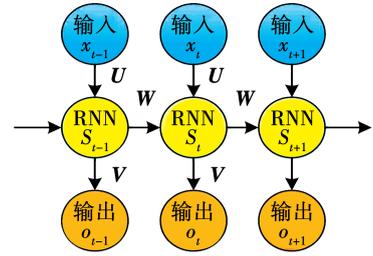


图 1 递归神经网络隐含层展开图

Fig. 1 Expanded view of hidden layers of RNN

U 、 V 和 W 为连接权值矩阵,通过这 3 个矩阵可以计算递归神经网络各层状态。对于任意 t 时刻,网络的输入为 x_t ,经过隐含层后,可以得到该时刻网络的隐藏状态 S_t ,由输入 x_t 与前一时刻的隐藏状态 S_{t-1} 共同决定:

$$S_t = \sigma \cdot (U \cdot x_t + W \cdot S_{t-1} + b) \quad (1)$$

式中: σ —隐含层的激活函数; b —线性偏置。

在 t 时刻递归神经网络输出 o_t 为:

$$o_t = V \cdot S_t + c \quad (2)$$

递归神经网络在隐藏层中除了与输出层之间有连接外,在隐藏层内部添加了连接,形成一个内部的循环,从而使其能够处理输入序列之间存在前后关联的问题。但是递归神经网络只能记忆短期的信息,对于距离相距很远的信息记忆能力差,引起“梯度消失”问题^[7]。为此,长短期记忆神经网络被提出。

长短期记忆神经元节点增加了遗忘门、输入门和输出门 3 个单元以及 1 个记忆单元^[8],如图 2 所示。

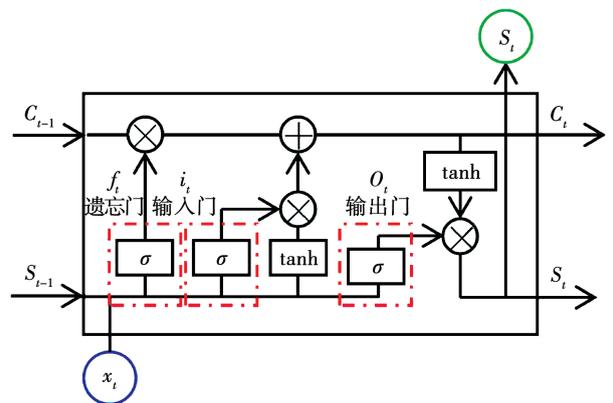


图 2 长短期记忆神经元节点

Fig. 2 Neuron nodes of LSTM

遗忘门 f_t 的计算式为:

$$f_t = \sigma(\mathbf{W}_f \cdot S_{t-1} + \mathbf{U}_f \cdot x_t + b_f) \quad (3)$$

\mathbf{W}_f 和 \mathbf{U}_f 为遗忘门的连接权值矩阵,用于分配输入 x_t 与前一时刻状态 S_{t-1} 中舍弃的部分信息,再通过激活函数 $\sigma(\cdot)$ 将输出转换为 $[0, 1]$ 之间的数。 b_f 为遗忘门的偏置。输入门 i_t 计算式为:

$$i_t = \sigma(\mathbf{W}_i \cdot S_{t-1} + \mathbf{U}_i \cdot x_t + b_i) \quad (4)$$

\mathbf{W}_i 和 \mathbf{U}_i 为输入门的连接权值矩阵,用于分配输入 x_t 与前一时刻状态 S_{t-1} 中学习的的信息。通过激活函数 $\sigma(\cdot)$ 将输出转换为 $[0, 1]$ 之间的数。 b_i 为输入门的偏置。

临时记忆单元通过 \tanh 函数进行变换。

$$l_t = \tanh(\mathbf{W}_l \cdot S_{t-1} + \mathbf{U}_l \cdot x_t + b_l) \quad (5)$$

l_t 代表临时记忆单元, \mathbf{W}_l 和 \mathbf{U}_l 为临时记忆单元的连接权值矩阵, b_l 为临时记忆单元的偏置。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot l_t \quad (6)$$

式中: C_t —记忆单元当前时刻的状态; C_{t-1} —前一时刻记忆单元的状态; “ \cdot ” 为元素乘。

通过遗忘门 f_t 丢弃掉部分无用历史信息, 再通过记忆门 i_t 加入新学习的的信息 l_t , 实现记忆单元的更新。这 3 部分结构单元的存在实现了 LSTM 的信息增减能力。

输出门 o_t 的计算式为:

$$o_t = \sigma(\mathbf{W}_o \cdot S_{t-1} + \mathbf{U}_o \cdot x_t + b_o) \quad (7)$$

$$S_t = o_t \cdot \tanh(C_t) \quad (8)$$

式中: \mathbf{W}_o 和 \mathbf{U}_o —输出门的连接权值矩阵,用于分配输出 x_t 与前一时刻状态 S_{t-1} 中学习的的信息; 同样, 通过激活函数 $\sigma(\cdot)$ 将输出转换为 $[0, 1]$ 之间的数; b_o —输出门的偏置, 通过 \tanh 函数对记忆单元的输出 C_t 进行变化, 输出的变化区间为 $[-1, 1]$, 输出的正负值表示如何对记忆单元的信息进行处理; S_t —当前时刻输出的状态信息。

通过 LSTM 内部的循环模块, 实现时序数据跨时间长度的传递, 保持长期信息记忆, 丢弃无用的信息, 解决了“梯度消失”问题。

2 基于 LSTM 的排气温度趋势预测方法

2.1 趋势预测方法实现流程

图 3 为基于 LSTM 神经网络的排气温度趋势预测算法流程, 具体实现步骤为:

步骤 1: 参数预处理阶段。选取历史检修周期内低压涡轮排气温度数据作为算法的训练数据, 对输入参数进行参数标准化与归一化, 以降低工况的影响。

步骤 2: 模型训练阶段。使用滑窗法对输入参数进行重叠采样, 构造长度为 n 的一维监测参数, 输入到搭建完成的 LSTM 神经网络模型中迭代训练, 得到 LSTM 排气温度趋势预测模型。

步骤 3: 预测阶段。选取维度为 $(1, n)$ 的低压涡轮排气温度数据, 对低压涡轮排气温度进行数据预处理, 输入已训练好的 LSTM 排气温度趋势预测模型中。预测结果进行反归一化, 得到低压涡轮排气温度预测结果。

2.2 排气温度趋势预测模型结构

用于船用三轴燃气轮机排气温度趋势预测的 LSTM 神经网络模型参数如表 1 所示。该模型由 1 层 LSTM 隐含层和 1 层全连接层构成。在 LSTM 隐含层中提取低压涡轮排气温度时间序列特征, 再通过全连接层实现特征到预测值的回归。

表 1 长短期记忆神经网络结构

Tab. 1 The structure of LSTM neural network

输入节点数	隐含层单元数	全连接层单元数	输出节点数	初始学习率	小批量样本数	训练次数
n	200	50	p	0.005	100	500

3 预测结果分析

为了验证基于 LSTM 的排气温度趋势预测模型的性能, 采用均方根误差 (Root mean square error, RMSE) 与平均绝对误差 (Mean absolute error, MAE) 作为评价指标。

$$\text{RMSE} = \sqrt{\frac{1}{M} \sum_{i=1}^M (y_i - p_i)^2} \quad (9)$$

$$\text{MAE} = \frac{1}{M} \sum_{i=1}^M |y_i - p_i| \quad (10)$$

式中: y_i —真实值; p_i —预测值; M —预测的次数。

3.1 数据预处理

图 4 为一组退化周期的排气温度原始数据。该组数据处于设计工况, 但外界环境温度是变化的。依据图 3 所示的排气温度趋势预测流程, 对排气温度 T_6 进行标准化^[9]。

$$T_{6cor} = T_6 \frac{T_{st}}{T_0} \quad (11)$$

式中: T_0 —当前工况下环境温度,标准大气压下温度
 $T_{st} = 288.15 \text{ K}$ 。

选择最大最小值法对参数进行归一化处理^[10]。
 $x^{i,j}$ 为原始数据, $x_{norm}^{i,j}$ 为参数 j 的第 i 个归一化后的

值。 x_{max}^j 与 x_{min}^j 为参数 j 的最大值与最小值。

$$x_{norm}^{i,j} = \frac{x^{i,j} - x_{min}^j}{x_{max}^j - x_{min}^j} \quad (12)$$

图5为预处理后的数据。可以看到,数据预处理将数据归一化至 $[0,1]$ 之间,减小工况与环境的影响,数据表征的退化趋势清晰化。

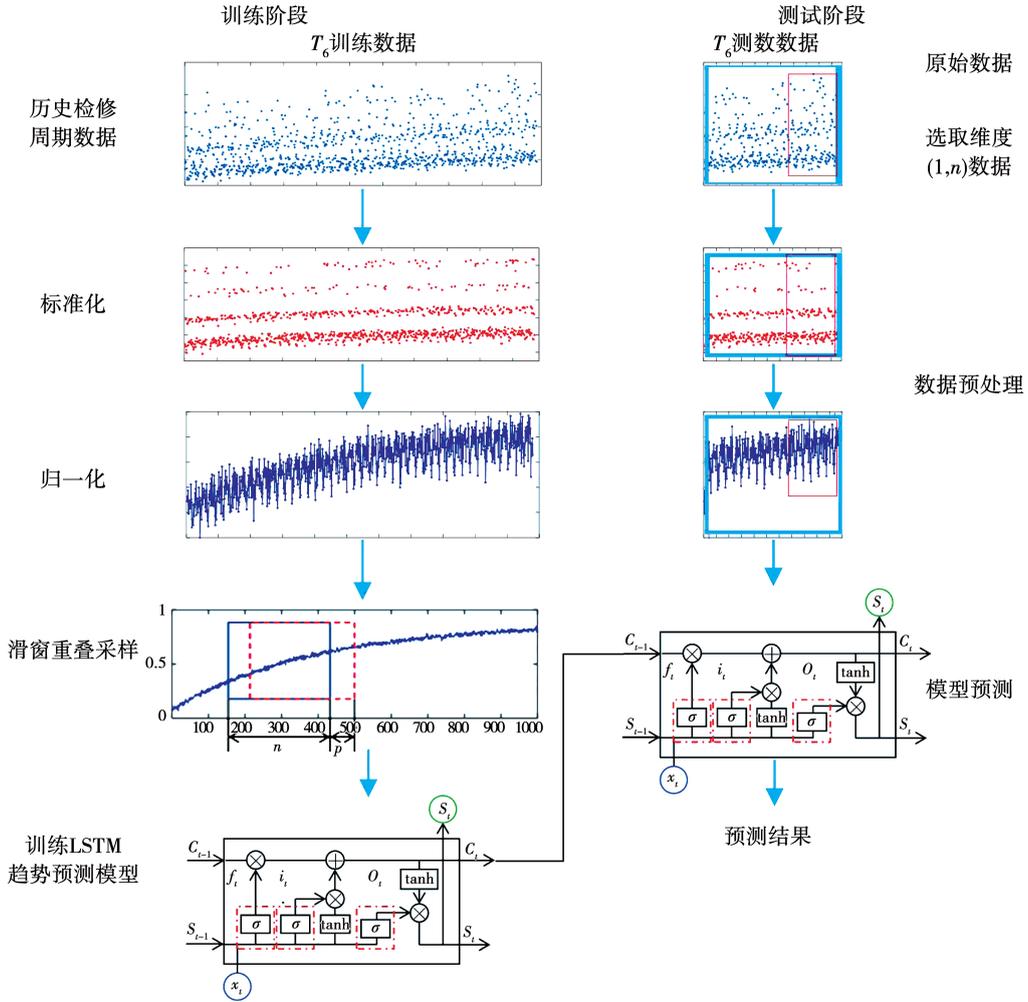


图3 基于 LSTM 的排温趋势预测方法流程

Fig.3 The flow chart of exhaust temperature trend prediction method based on LSTM

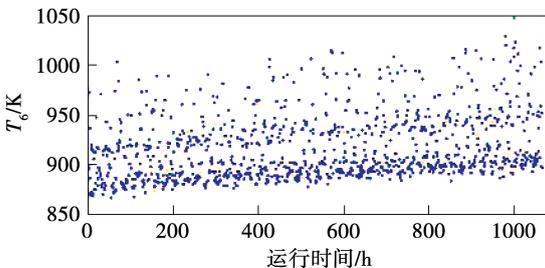


图4 退化周期内 T_6 原始数据

Fig.4 T_6 raw data in the degradation cycle

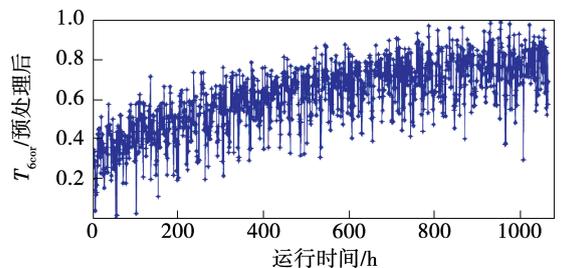


图5 退化周期内 T_{6cor} 修正值

Fig.5 T_{6cor} correction values in the degradation cycle

3.2 模型训练

由于所收集的历史样本相对稀少,采用滑窗法进行重叠采样,对训练数据进行扩充,增强预测模型的泛化能力。图 6 为重叠采样的过程。窗口长度为 n ,因此构造的一维监测参数输入维度为 $(1, n)$,对应的输出维度为 $(1, p)$,即用 n 个历史数据,向后预测 p 步长后趋势。将 $p = 1$,输入至 LSTM 模型中,训练 LSTM 趋势预测模型,可实现未来 1 h 变化趋势的预测。

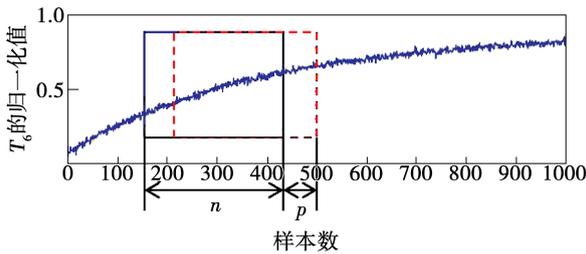


图 6 重叠采样过程

Fig. 6 Overlap sampling process

3.3 预测结果分析

使用两组燃气轮机盐雾积垢退化试验数据,开展 LSTM 趋势预测算法的试验^[11]。图 7 为经预处理后的退化试验数据。分别针对窗口大小与训练数据长度对预测精度的影响进行分析。

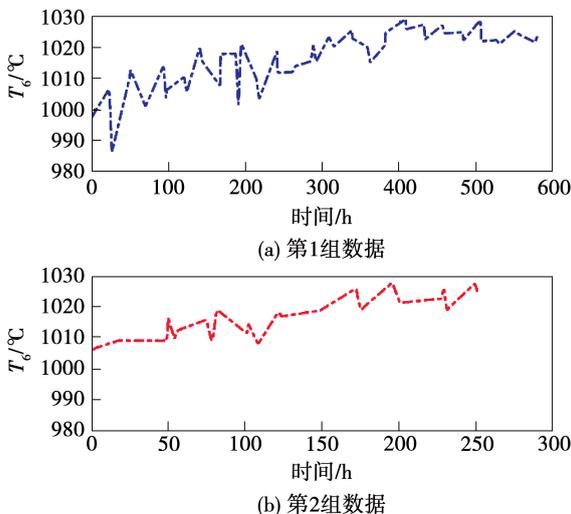


图 7 预处理后的退化试验数据

Fig. 7 Degradation test data after pre-processing

3.3.1 窗口大小影响分析

以第 1 组数据作为训练数据,训练基于 LSTM 的排气温度趋势预测模型,对第 2 组数据的排气温度进行趋势预测。在构造 LSTM 排气温度趋势预测模型的输入层时,选取不同的滑动窗口大小,以改变输入步长。图 8 ~ 图 10 为滑动窗口 w 分别为 4, 8, 12 条件下的预测结果。

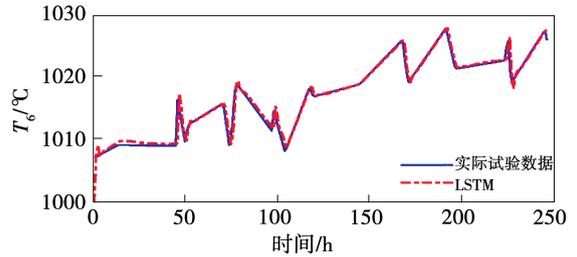


图 8 窗口 $w = 4$ 时的预测结果

Fig. 8 The predicted results at $w = 4$

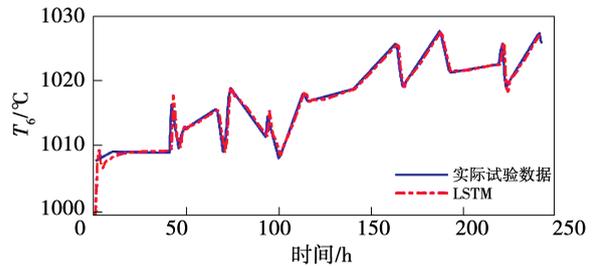


图 9 窗口 $w = 8$ 时的预测结果

Fig. 9 The predicted results at $w = 8$

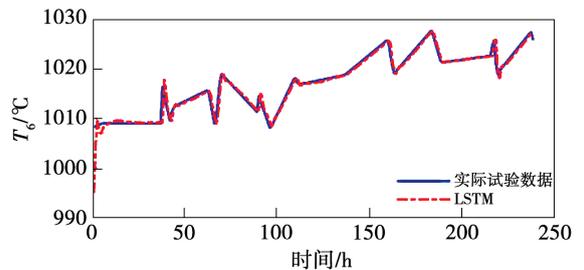


图 10 窗口 $w = 12$ 时的预测结果

Fig. 10 The predicted results at $w = 12$

由图 8 ~ 图 10 可知,LSTM 排温趋势预测模型的预测结果存在一定的滞后预测现象,但是 T_g 预测结果的趋势与真实值的趋势基本相同。由表 2 所示的平均绝对误差与均方误差指标也可以看出,预测结果的误差非常小。当输入步长 $w = 4$ 时,预测模

型有着更好的预测精度。体现出 LSTM 排温预测模型在贫信息下,具有较好预测效果的能力。

表2 不同窗口大小的预测结果

Tab.2 The predicted results at different window sizes

窗口 w	平均绝对误差 MAE	均方根误差 RMSE
4	0.491 4	0.992 8
8	0.516 6	1.092 2
12	0.551 2	1.247 8

3.3.2 训练数据长度影响分析

通过 LSTM 模型的内部循环节点,学习船用燃气轮机水洗周期排气温度历史数据内的退化规律,进一步通过时序相似性搜索,实现对排气温度的趋势预测。因此,在趋势模型的训练过程中,用于学习的训练数据长度是影响模型预测精度的重要因素。

从图7可以看出,两组试验数据的时间跨度相差明显。使用数据长度短的第2组数据作为训练数据,对第1组数据进行趋势预测,预测结果如图11所示。

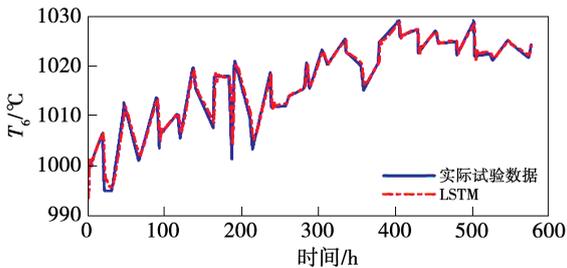


图11 使用第2组数据训练的预测结果

Fig.11 The predicted results based on the second dataset

当训练数据的长度为250 h时,预测结果的平均绝对误差和均方根误差分别为0.686 5和1.234 8;将训练数据的长度增加到580 h时,两项指标分别提升到0.491 4和0.992 8。在训练数据相对长的条件下,LSTM排温预测模型学习到更丰富的燃机历史退化信息,提升了燃机排气温度预测的精度。

3.3.3 预测精度对比分析

利用前期建立的自回归滑动平均 ARMA 算法^[12]对第2组排气温度进行预测,结果如图12所示。相对于 ARMA 算法,LSTM 算法($w=4$,训练长

度580 h)的平均绝对误差从0.627 3减小到0.491 4,减小了21.7%;均方根误差从1.671 8减小到0.992 8,减小了40.6%。

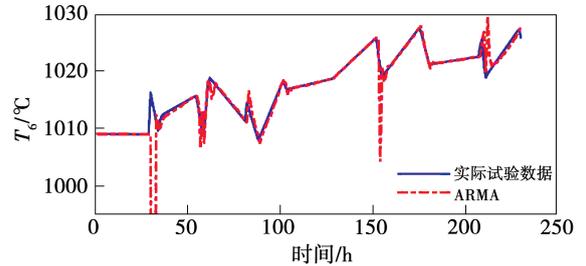


图12 ARMA 算法的预测结果

Fig.12 The predicted results of the ARMA algorithm

同时,排温时间序列出现突变时,ARMA 模型受历史时序信息影响,如在42,164和222 h处产生了较大的误差。相比之下,图8和图11,LSTM 预测算法在排温突变情况下有更强的趋势跟踪能力,预测精度大于87.4%。

4 结论

(1) 通过对燃气轮机低压涡轮排气温度进行预处理,降低了工况、环境因素对时序退化特征的影响,获得了具有更明显退化趋势的时间序列数据。

(2) LSTM 排温趋势预测模型隐含层节点的内部循环模块,可以实现时序信息的传递,提取输入数据内的时序关系,相对于自回归滑动平均算法,排气温度趋势预测平均相对误差减小21.7%,均方根误差减小40.6%。

(3) 通过 LSTM 神经网络挖掘燃气轮机退化周期内的退化信息,学习的特征丰富全面,减小了算法的自相关性,在排温突变情况下有更强的趋势跟踪能力,预测精度大于87.4%。

参考文献:

- [1] 刘东风,房友龙,刘永葆,等.船用三轴燃气轮机性能退化指标体系的构建[J].燃气轮机技术,2019,32(1):30-37.
LIU Dong-feng, FANG You-long, LIU Yong-bao, et al. Construction of performance degradation indices system of three-shaft marine gas turbine[J]. Gas Turbine Technology, 2019, 32(1): 30-37.
- [2] 赵宁波,吴森,闻雪友.燃气轮机异常检测技术研究进展[J].热能动力工程,2017,32(10):1-10,137.

- ZHAO Ning-bo, WU Sen, WEN Xue-you, Research progress of abnormal detection technology for gas turbine [J]. Thermal Energy and Power Engineering, 2017, 32(10): 1-10, 137.
- [3] 刘保果, 黄雅琳, 陈卓. 船用燃气轮机状态趋势预测算法研究[J]. 计算机测量与控制, 2014(6): 76-79.
- LIU Bao-guo, HUANG Ya-lin, CHEN Zhuo. Research on the state trend prediction algorithm of marine gas turbine [J]. Computer Measurement and Control, 2014(6): 76-79.
- [4] 崔建国, 李慧华, 于明月, 等. 基于 LSSVM 与 WNN 的燃气轮机状态趋势预测[J]. 火力与指挥控制, 2018, 43(8): 160-163.
- CUI Jian-guo, LI Hui-hua, YU Ming-yue, et al. Trend prediction of gas turbine status based on LSSVM and WNN [J]. Firepower and Command Control, 2018, 43(8): 160-163.
- [5] 孙跃武. 燃气轮机性能退化及趋势预测技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2014.
- SUN Yue-wu. Research on gas turbine performance degradation and trend prediction technology [D]. Harbin: Harbin Engineering University, 2014.
- [6] GRAVES A. Supervised sequence labeling with recurrent neural networks [M]. Berlin: Berlin Springer-Verlag, 2012.
- [7] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313: 504-506.
- [8] KARIM F, MAJUMDAR S, DARABI H, et al. LSTM fully convolutional networks for time series classification [J]. IEEE Access, 2018, 6(99): 1662-1669.
- [9] JAW L C, MATTINGLY J D. Aircraft engine controls: design, system analysis, and health monitoring [M]. Reston: American Institute of Aeronautics and Astronautics, 2009.
- [10] 刘康, 肖娜. 基于堆叠稀疏自编码神经网络的航空发动机剩余寿命预测方法研究[J]. 计算机测量与控制, 2019, 27(12): 29-33, 38.
- LIU Kang, XIAO Na. Research on aero-engine remaining life prediction method based on stacked sparse auto-encoding neural network [J]. Computer Measurement and Control, 2019, 27(12): 29-33, 38.
- [11] FANG Y, LIU D, YU L. Remaining useful life prognostic of three-shaft gas turbine based on the low-pressure turbine outlet temperature [C] // IEEE Prognostics and System Health Management Conference, Harbin, China, 2017.
- [12] 王伟影, 王建丰, 崔宝, 等. 基于时间序列模型的燃气轮机气路性能退化预测[J]. 热能动力工程, 2016, 31(3): 50-55.
- WANG Wei-ying, WANG Jian-feng, CUI Bao, et al. Prediction on gas path performance degradation of gas turbine based on time series mode [J]. Thermal Energy and Power Engineering, 2016, 31(3): 50-55.

(姜雪梅 编辑)