



面向航空发动机多传感器并行 预测模型的设计与实现

陆超^{1*}, 李晓瑜², 姚艳玲¹, 唐晓澜³, 彭宇², 王书福¹

(1. 中国航发四川燃气涡轮研究院高空模拟技术重点实验室 四川 绵阳 621000; 2. 电子科技大学信息与软件工程学院 成都 610054;
3. 西南石油大学计算机科学学院 成都 610500)

【摘要】为了准确预测航空发动机工作时传感器数据的变化趋势,有效监控航空发动机的工作状态,该文就发动机高压压气机转子转速、燃烧室燃油喷嘴压力、涡轮后温度等数个航空发动机主要传感器数据,使用滑动窗口算法截取子序列构建数据集并对其进行标准化。提出了一种基于 Seq2Seq 的面向航空发动机多传感器数据预测神经网络模型 (AMSDPNN),并对该网络进行优化,最终实现了对航空发动机多传感器数据的预测。实验表明,相较于其他传统数据预测模型,该模型有着更好的预测效果,其均方误差值为 0.1%,同时提前 320 ms 实现了对航空发动机传感器数据的预测。

关键词 数据标准化; 长短期记忆网络; Seq2Seq; 滑动窗口; 时序数据预测
中图分类号 TP391 **文献标志码** A **doi**:10.12178/1001-0548.2020365

Design and Implementation of Parallel Prediction Model for Aeroengine Multi-Sensor

LU Chao^{1*}, LI Xiao-yu², YAO Yan-ling¹, TANG Xiao-lan³, PENG Yu², and WANG Shu-fu¹

(1. Science and Technology on Altitude Simulation Laboratory, Sichuan Gas Turbine Establishment Aero Engine Corporation of China Mianyang Sichuan 621000; 2. School of Information and Software Engineering, University of Electronic Science and Technology of China Chengdu 610054;
3. School of Computer Science, Southwest Petroleum University Chengdu 610500)

Abstract In order to accurately predict the changing trend of sensor data when the aeroengine is operating, and to effectively monitor the working status of the aeroengine, the sliding window algorithm is used to intercept the subsequences to construct the time series data set and standardize them based on the data of several main aeroengine sensors: engine high pressure compressor rotor speed (N_2), combustion chamber fuel nozzle pressure (P_{tk}), turbine temperature (T_{t6}) and so on. Then we propose a multi-sensor data prediction model of aeroengine based on Seq2Seq which is called AMSDPNN (aeroengine multi-sensor data prediction neural network) and optimizes this neural network model to realize the prediction of aeroengine multi-sensor data. The experimental results show that this model has better prediction results than other traditional data prediction models and the mean square error (MSE) is 0.1%. And the prediction of aeroengine sensor data is advanced by 320ms.

Key words data standardization; LSTM; Seq2Seq; sliding window; timing data prediction

航空发动机是飞机最重要的部件之一,在飞机飞行发生的故障中发动机故障占相当大的比例,且一旦发生故障会致命。航空发动机中各传感器的数据曲线反应了当前该发动机是否处于正常的工作状态。因此,通过有效的手段监控航空发动机传感器数据变化趋势对飞机飞行安全有着重大的意义。

由于航空发动机传感器数据属于时序数据,因此对于航空发动机传感器数据的预测可以看作是时

序数据预测。传统的时间序列预测模型主要为线性模型,如 AR(autoregressive)、MR(moving average)、ARMA(autoregressive moving average)、ARIMA (autoregressive integrated moving average) 等^[1-8],针对平稳时间序列预测有着较好的效果。但大部分数据如股市数据、水文数据或者航空发动机传感器数据都具有非线性特征,传统的线性预测很难得到较好的预测结果。神经网络和自适应算法等非线性模

收稿日期: 2020-09-29; 修回日期: 2021-04-09

基金项目: 四川省科技计划重点研发项目 (2019YFG0424)

作者简介: 陆超 (1982-), 男, 高级工程师, 主要从事航空发动机高空模拟试验数据分析和数据仿真方面的研究。E-mail: LuChaoGTE@163.com

型的提出解决了此问题^[9-20]。其中通过基于深度学习构建神经网络模型因其自身强大的特征提取能力和自我学习能力,对具有非线性特征的时间序列数据的预测有着良好的效果。文献[21]提出了基于LSTM的预测模型,对有明显的非线性和不确定性波动的PM2.5浓度进行了预测。文献[22]提出了一种基于注意力机制的CNN(convolutional neural networks)和LSTM(long short-term memory)的联合模型,在真实的热电联产供热时序数据上进行预测,相较于传统的时序预测模型得到了更为精确的预测结果。

本文就发动机高压压气机转子转速(N_2)、发动机燃烧室燃油喷嘴压力(P_{tk})、发动机涡轮后温度(T_{t6})等航空发动机主要传感器数据,使用滑动窗口算法构建数据集并对其进行标准化,并提出了一种基于Seq2Seq的面向航空发动机多传感器预测神经网络模型(aeroengine multi-sensor data prediction neural network, AMSDPNN)。Seq2Seq模型是基于编解码器架构的常用于时序数据预测的神经网络模型,其隐藏层可以由CNN、RNN(recurrent neural networks)、LSTM等构成,本文采用LSTM,最终以0.1%左右的均方误差实现了对多个传感器数据的预测。

1 理论基础

1.1 长短时记忆神经网络

由于数据是时间序列数据,因此在模型隐藏层的网络模型选择上优先考虑时序数据的首选神经网络——循环神经网络RNN^[23]。这是因为RNN中的每一个Cell能够记住时序数据中每一个时刻的数据信息,当前Cell的隐藏层不仅由该时刻的输入决定,也由上一时刻隐藏层的输出决定。通过这样的方式,RNN能有效分析出时序数据的语义特征信息。一般的DNN不具备此功能。但RNN在长时序信息的保存和特征提取上表现并不好,容易产生梯度消失或梯度爆炸的问题,从而影响训练效果。因此本文采用了RNN的一个变种模型,即长短时记忆神经网络模型(LSTM)^[24-25]。相较于RNN,LSTM使用了输入门、输出门和遗忘门来控制是否遗忘或保留序列中的历史信息,很好地解决了长期依赖问题。其单元结构如图1所示。

相较于一般RNN结构,每个循环网络单元变得复杂了,这是因为多了3道控制门,分别是遗忘门、输入门、输出门。这里的“门”是带有激活函

数的全连接层,能够选择性地对信息进行过滤,激活函数一般是使用Sigmoid函数(图1中 σ 表示),并且相较于原始RNN,LSTM多出了一个单元状态变量 C ,用于保存长期的状态,称为单元状态(cell state)。

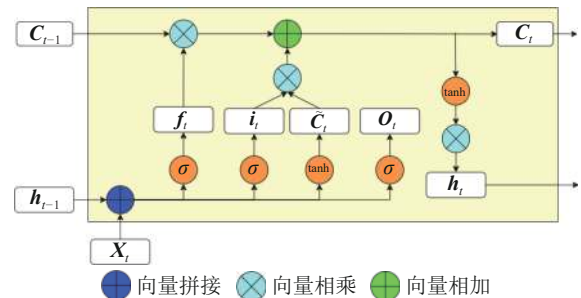


图1 LSTM单元体结构示意图

整体流程如下。当上一时刻的输出信息 h_{t-1} 经过一个LSTM单元时,首先和 X_t 进行向量拼接后经过遗忘门的Sigmoid层,得到遗忘门的值 f_t ; f_t 再与上一时刻的单元状态值 C_{t-1} 相乘得到一个中间结果,该中间结果决定要从上一时刻单元中丢弃哪些信息。然后将 h_{t-1} 和 X_t 进行向量拼接后经过输入门的Sigmoid层,得到输入门的值 i_t 。同时, h_{t-1} 和 X_t 进行再一次的向量拼接操作,经过Tanh层后得到候选单元状态值 \tilde{C}_t ,将 i_t 与 \tilde{C}_t 相乘得到另一个中间结果,该中间结果决定哪些新的信息可以存储在当前单元中。最后将该中间结果和由遗忘门输出的中间结果相加,得到当前单元状态值 C_t ,将 h_{t-1} 和 X_t 进行向量拼接后经过输出门的Sigmoid层,得到输出门的值 o_t ,将 o_t 与经过Tanh函数激活后的 C_t 相乘得到单元输出 h_t 。至此,该LSTM结构单元的所有状态更新完毕。

1.2 Seq2Seq网络模型

上面提到的深度神经网络模型不论是RNN还是LSTM模型,它们都可以生成与输入长度一样长的固定长度序列,如果想要获得不定长的序列通常需要维度变换,效果不理想。为了解决不定长的预测序列数据的生成,文献[24]提出了Seq2Seq模型,该模型采用编解码器结构,可以采取CNN、RNN、LSTM等不同模型作为隐藏层。本文采用LSTM,其工作原理是首先输入一个序列到编码器的LSTM层,取其最后一个LSTM单元的输出为编码向量,该向量为二维向量,再将该特征向量复制生成与预测序列长度一样长的三维特征向量输入到解码器的LSTM层中,最终得到预测序列向量。Seq2Seq模型中的主要架构编解码器如图2所示。

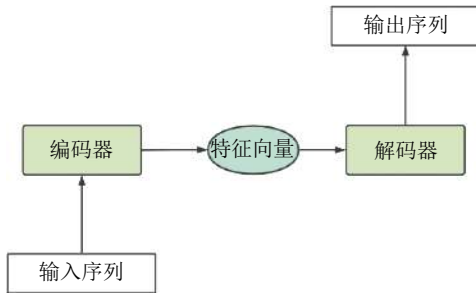


图 2 Seq2Seq 模型中的主要架构编解码器

2 数据预处理及划分

2.1 数据预处理

本文采用的数据格式为时间序列数据,是在不同时间点上收集到的数据,简称时序数据。这类数据反映了某一事物、现象等随时间的变化状态或程度。对于一般时序数据预测模型的训练而言,其数据集是由原数据集截取得到的一个个固定长度的子序列构成。本文采用滑动窗口算法实现了对航空发动机不同传感器数据的子序列截取来构建模型训练所需的数据集。该数据集包括由真实数据组成的待预测子序列和预测子序列,前者作为模型输入序列,得到预测序列数据后,后者会作为用于计算与预测序列数据之间均方误差的对比序列。其子序列个数由滑动窗口的滑动步长决定。为了能够得到更多的训练数据,本文设置滑动窗口步长为 1。

2.2 数据集划分及标准化

当使用滑动窗口成功构建数据集后,需将数据集划分为训练集和测试集。一般传统的数据集划分方式是先将数据集里的数据打乱随机排序,再按照比例进行划分,目的是防止模型训练时过拟合以及能够提高模型的鲁棒性。但本文研究的传感器数据属于时间序列数据,其数据具有高度自相关的特性,前后相邻的数据有着一定的关联度,如果打乱训练会引入来自未来的数据而导致模型容易发生严重的过拟合现象,从而影响训练效果。因此,本文划分数据集的方法是将选择一个合适的时间点,取该时间点前的来自过去的的数据作为模型的训练集,时间点后的来自未来的数据作为模型的测试集,按照训练集和测试集 4:1 的比例进行划分。

最后在划分好训练集和测试集后还需要标准化处理。目的是消除由于量纲不同、不同传感器数值范围差距过大而引起的误差,使其有利于学习率的调整,特别是在寻找模型损失函数最优解的过程中避免梯度更新时带来数值问题,从而提高模型的训

练效果。一般情况下,如果数据没有进行标准化,会因为数据中不同特征值的量纲差距过大,从而导致在进行梯度下降时,梯度的方向会偏离最快下降方向,使训练时间变得很长。而在数据标准化后,其模型目标函数呈现会变“圆”,这样梯度的下降方向能更贴近理想的最快下降方向,便能更快地找到最优解。为了防止在数据标准化的过程中引入未来数据导致训练时发生过拟合现象,本文对数据进行标准化所用的均值和标准差均来自训练集。

3 面向航空发动机多传感器数据预测模型

本文针对航空发动机多传感器数据预测多维多步预测问题,提出了一种基于 Seq2Seq 的多传感器数据预测神经网络模型 (AMSDPNN),实现了航空发动机多传感器数据的提前预测。模型的总体结构如图 3 所示。

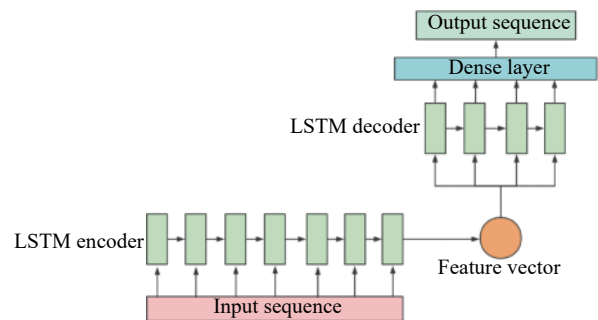


图 3 AMSDPNN 模型的整体结构

将奥卡姆剃刀原理延伸到深度学习模型的构建上,选择适当复杂程度的模型能有效地防止过拟合,得到满意的效果。基于本文模型的 Encoder 和 Decoder 模型都由一层 LSTM 层构成,其中间结果为编码器中最后一个 LSTM 单元的输出向量,而解码器的输入则都为该中间输出向量,且解码器的输出能够根据需求输出对应时间步大小的矩阵向量,最后通过一层全连接层得到与需求输出相对应的特征个数的预测序列数据。

而在模型的激活函数选择上并没有使用如 Relu、Sigmoid、Tanh 等激活函数,而是直接输出值。这是因为首先在 LSTM 层中本身默认使用了 Tanh 函数进行最后输出的激活,因此并没有再次使用 Tanh 函数和与之类似的 Sigmoid 函数; Relu 函数本身常用于避免深度神经网络训练中经常出现的梯度消失问题,而本文模型是属于浅层神经网络,故没有采用。

关于损失函数的选择上则采用均方误差函数MSE。这里假设预测的序列数据为 y_p ,与之对应的真实数据为 y_i 。此时损失函数 L 的表达式为:

$$L = \frac{1}{N} \sum_i (y_p - y_i)^2 \quad (1)$$

选择AMSDPNN模型来搭建时序预测模型,相较于传统的基于LSTM的时序预测模型有两点优势:1)基于编解码器结构的Seq2Seq模型输入和输出都是序列且长度可变,而传统的LSTM模型通常需要将输出的矩阵向量经过一系列的矩阵变换才能做到;2)1.2节提到的解码器工作时每个LSTM单元里都会带入编码器输出的编码向量,其编码向量可以看作是包含了输入序列全部语义的语义向量,能够在解码器生成预测序列时充分吸纳上一序列的语义信息,得到更好的预测结果。

4 实验与分析

4.1 实验环境

本文实验所使用的操作系统为Windows10, CPU为i7-6700K,主频4 GHz, GPU型号GTX 1060,显存6 GB,电脑内存16 GB。主要采用的编程语言为Python3.6,神经网络结构的搭建选用Keras2.2.3。

在数据集方面,本文以多型涡扇发动机在空中惯性起动、空中风车起动、进气畸变条件下的地面起动,及起动失速/喘振等12个不同场景下,约30万条故障数据作为本文模型的训练及测试数据。

4.2 试验过程及分析

模型采用的训练方法是基于批次的梯度下降法,批量大小根据整个数据集的规模而定,整个试验采用Python的第三方工具库Matplotlib对整个训练过程进行可视化。

使用梯度下降法时,根据训练效果来控制学习速率是模型能否训练成功的关键。本文选取了Adadelta、Adam、Adagrad、RMSprop这4种优化算法进行比较,每个优化算法在整个训练过程中的Loss曲线如图4所示。

从图4可以看到,相较于其余3个优化算法,Adam优化效果最好,其损失函数Loss能降至0.01左右,且收敛过程也较为稳定,故在模型搭建时,选择Adam作为模型的优化函数。

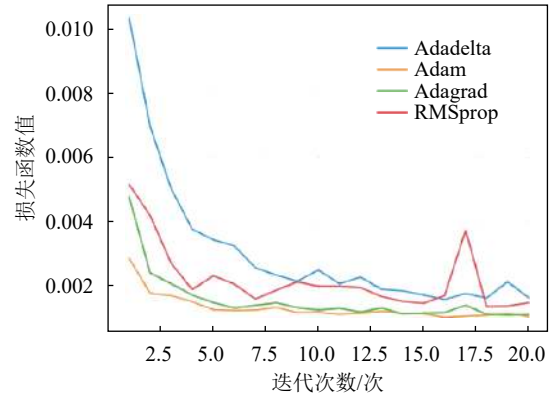


图4 不同优化算法的loss曲线对比

4.3 试验结果及分析

模型训练完成后,某发动机发生喘振时多个传感器的真实数据曲线以及预测数据曲线对比如图5所示。

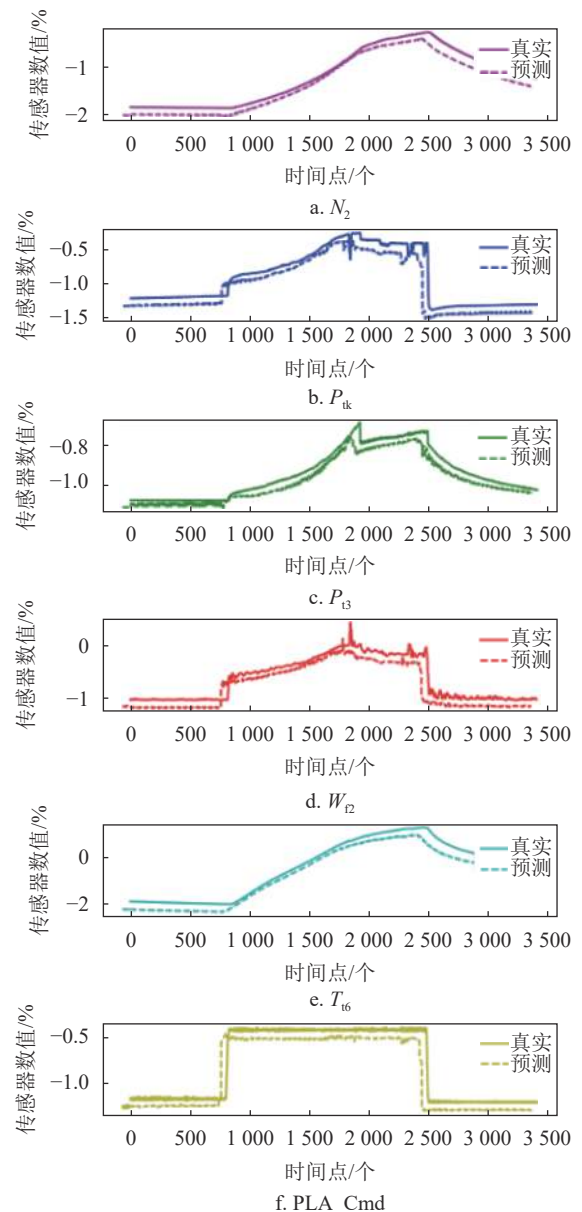


图5 某发动机真实数据曲线与预测数据曲线对比

为了对模型的最终效果进行整体评估。本文以均方差 MSE 作为评估指标,将本文模型 AMSDPNN 与其他神经网络 CNN、RNN、LSTM 的测试结果对比,结果如表 1 所示。

表 1 各个算法的数据预测误差对比

模型	AMSDPNN	LSTM	CNN	RNN
误差	1.0×10^{-3}	1.4×10^{-3}	1.5×10^{-3}	1.8×10^{-3}

由表 1 的实验结果可知,AMSDPNN 模型相较其他 3 个模型,其预测误差更小,说明使用基于 Seq2Seq 的 AMSDPNN 模型数据预测效果更好。

4.4 预测耗时评估

本文模型的最终目标是能够预测发动机多传感器的未来数据。因此需要通过模型的单次预测耗时计算出可以预测多长时间之后的数据。经实验得到模型单次数据预测的耗时平均约为 80 ms,由于预测序列的时间跨度达到了 400 ms,因此经过计算模型可以提前预测 320 ms 后发动机的传感器数据,如图 6 所示。




图 6 AMSDPNN 模型单次预测耗时曲线

5 结束语

本文基于航空发动机传感器数据集使用滑动窗口算法截取子序列构建时序数据集,并对其进行标准化。提出了一种面向航空发动机多传感器数据预测神经网络模型 AMSDPNN,该模型主要基于 Seq2Seq 模型构成,其隐藏层使用 LSTM 网络结构。实验结果表明,该模型能够以极短的时间预测出航空发动机未来的传感器数据。

参 考 文 献

[1] LIU Feng, WANG Ru-jing, LI Chuan-xi. Application of ARIMA model in forecasting agricultural product price[J]. Computer Engineering and Applications, 2009, 45(25):

238-239.
 [2] MENG Tian-xing, ZHANG Hou-sheng. Wind speed short-term forecast for wind farms based on ARIMA model[J]. Science Technology and Engineering, 2013, 13(33): 220-230.
 [3] WEI Hui-yuan, ZHANG Yue-dong, ZHANG Li-ye. Defense cost forecast based on ARMA time series model[J]. Ordnance Industry Automation, 2018, 37(12): 72-75.
 [4] CAI Z, TIWARI R C. Application of a local linear autoregressive model to BOD time series[J]. Environmetrics, 2015, 11(3): 198-210.
 [5] GOIA A. A functional linear model for time series prediction with exogenous variables[J]. Statistics & Probability Letters, 2012, 82(5): 1005-1011.
 [6] SENGUPTA A, PRATHOSH A P, SHUKLA S N, et al. Prediction and imputation in irregularly sampled clinical time series data using hierarchical linear dynamical models[C]//Engineering in Medicine & Biology Society. [S. l.]: IEEE, 2017: 122-130.
 [7] DEVI B U, SUNDAR D, ALLI P. An effective time series analysis for stock trend prediction using ARIMA model for nifty midcap-50[J]. International Journal of Data Mining & Knowledge Management Process, 2013, 3(1): 65-78.
 [8] SUN C J, LIU F, LIN L, et al. Prediction of search data volume based on time-series clustering and ARMA models[J]. Journal of South China University of Technology (Natural Science Edition), 2011, 10(8): 88-96.
 [9] HAN Q, DING J, AIROLDI E, et al. SLANTS: Sequential adaptive nonlinear modeling of time series[J]. IEEE Transactions on Signal Processing, 2016, 65(19): 4994-5005.
 [10] LIU J. Adaptive forgetting factor OS-ELM and bootstrap for time series prediction[J]. International Journal of Modeling Simulation & Scientific Computing, 2017, 3(8): 1750029.
 [11] LI Yi-ran, YANG Juan. Hydrological time series prediction model based on attention-LSTM neural network[C]//The Second International Conference on Machine Learning and Machine Intelligence. Indonesia: [s. n.], 2019: 39-46.
 [12] DUAN J, WANG W, ZENG J, et al. A prediction algorithm for time series based on adaptive model selection[J]. Expert Systems with Applications, 2009, 36(2): 1308-1314.
 [13] RU Y, LI B, LIU J, et al. An effective daily box office prediction model based on deep neural networks[J]. Cognitive Systems Research, 2018, 52: 182-191.
 [14] ZHENG D, RAN Z, LIU Z, et al. An efficient bar code image recognition algorithm for sorting system[J]. CMC-Computers Materials & Continua, 2020, 64(3): 1885-1895.
 [15] TIAN L, CHENG Y, YIN C, et al. Design of the MOI method based on the artificial neural network for crack detection[J]. Neurocomputing, 2017, 3(11): 101-112.
 [16] CHENG Y, TIAN L, YIN C, et al. A magnetic domain spots filtering method with self-adapting threshold value selecting for crack detection based on the MOI[J].

- Nonlinear Dynamics, 2016, 86(2): 1-10.
- [17] WEN M, LI P, ZHANG L, et al. Stock market trend prediction using high-order information of time series[J]. IEEE Access, 2019, 2(11): 28299-28308.
- [18] ZHANG M, JIANG X, FANG Z, et al. High-order hidden Markov model for trend prediction in financial time series[J]. Physica A: Statistical Mechanics and its Applications, 2018, 517(23): 1-12.
- [19] DUAN Da-gao, ZHAO Zheng-dong, LIANG Shao-hu, et al. Research on PM2 concentration prediction based on LSTM[J]. Computer Measurement & Control, 2019, 27(3): 215-219.
- [20] LI Mei, NING De-jun, GUO Jia-cheng. Attention mechanism-based CNN-LSTM model and its application[J]. Computer Engineering and Application, 2019, 55(13): 20-27.
- [21] ZHANG X, ZHAO M, DONG R. Time-series prediction of environmental noise for urban IOT based on long short-term memory recurrent neural network[J]. Applied Science, 2020, 10(3): 1144-1144.
- [22] RAN Z, ZHENG D, LAI Y, et al. Applying stack bidirectional LSTM model to intrusion detection[J]. CMC-Computers, Materials & Continua, 2020, 65(1): 309-320.
- [23] YUAN M, WU Y, LIN L. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network[C]//IEEE International Conference on Aircraft Utility Systems. [S. l.]: IEEE, 2016: 23-36.
- [24] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[J]. Advances in Neural Information Processing Systems, 2014, 10(5): 110-131.

编辑 税红