

引用格式: 王玉玲, 陈涛涛, 李红浪. 基于声发射和长短时记忆神经网络的端对端燃气高压调压器故障诊断[J]. 声学技术, 2021, 40(6): 883-889.
[WANG Yuling, CHEN Taotao, LI Honglang. Acoustic emission and LSTM based end-to-end fault diagnosis of gas high-pressure regulator[J]. Technical Acoustics, 2021, 40(6): 883-889.] DOI: 10.16300/j.cnki.1000-3630.2021.06.022

基于声发射和长短时记忆神经网络的端对端 燃气高压调压器故障诊断

王玉玲^{1,2}, 陈涛涛³, 李红浪^{1,4}

(1. 中国科学院大学, 北京 100049; 2. 中国科学院声学研究所, 北京 100190; 3. 北京燃气集团有限责任公司, 北京 100011;
4. 中国科学院纳米科学卓越创新中心, 国家纳米科学中心, 北京 100190)

摘要: 在燃气输配系统中燃气调压器处于关键位置, 及时有效地诊断其故障类型具有重要意义。文章提出了一种基于声发射信号和长短时记忆神经网络的端对端故障诊断方法, 直接利用时域声发射信号对调压器的运行状态进行诊断。首先, 设计一个二阶巴特沃斯高通滤波器对采集的声发射信号进行预处理; 其次, 利用长短时记忆网络(Long Short Term Memory networks, LSTMs)的记忆特性, 构建长短时记忆网络端到端(e2e-LSTM)故障诊断模型。实验结果表明, 该模型根据输入的高压调压站采集的声发射信号, 能够以端到端模式一次性地诊断五种高压调压器故障。

关键词: 故障诊断; 声发射信号; 长短时记忆网络; 端到端方法

中图分类号: TE88

文献标识码: A

文章编号: 1000-3630(2021)-06-0883-07

Acoustic emission and LSTM based end-to-end fault diagnosis of gas high-pressure regulator

WANG Yuling^{1,2}, CHEN Taotao³, LI Honglang^{1,4}

(1. University of Chinese Academy of Sciences, Beijing 100049, China; 2. Institute of Acoustics, Chinese Academy of Science, Beijing 100190, China;
3. Beijing Gas Group Co., Ltd., Beijing 100011, China; 4. CAS Center for Excellence in Nanoscience, National Center for Nanoscience and Technology, Beijing 100190, China)

Abstract: In the gas transmission and distribution system, the gas pressure regulator is in a key position for the timely and effective diagnosis of its fault types. In this paper, a long short term memory network (LSTM) based end-to-end fault diagnosis method is proposed, in which the acoustic emission signals is used to diagnose the operation condition of the gas pressure regulator. First, a second-order Butterworth high-pass filter is designed to preprocess the acquired acoustic emission signals. Then, by using the memory characteristics of long short term memory networks, an e2e-LSTM fault diagnosis model is established. The experimental results show that, with the input acoustic emission signals collected from the high-pressure regulator station, the model can diagnose five kinds of high-pressure regulator faults at a time in the end-to-end mode.

Key words: fault diagnosis; acoustic emission signal; long short term memory networks (LSTM); end-to-end method

0 引 言

随着燃气供应规模的不断扩大, 燃气管网已经遍布城市的各个角落, 燃气调压器作为燃气管网系统中的关键设备之一, 它的稳定可靠运行是安全供应燃气的重要保障^[1-3]。当调压器出现故障无法正常运行时, 下游会出现气压不足、不稳等问题, 在得

不到有效控制的情况下, 会持续恶化导致火灾、爆炸、中毒等事故发生, 因此, 快速实时地对调压器进行故障诊断具有重要的意义^[4-5]。

故障检测、故障类型判断、故障定位及故障修复均属于故障诊断技术^[6]。故障诊断方法主要包括: (1) 基于数学模型的故障诊断方法, 系统故障采用参数估计法进行判别与分析^[7]。(2) 基于系统输入输出信号奇异性的故障诊断方法, 通过对系统输入输出的信号进行预处理, 消除噪声和输入突变, 剩余的信号奇异点则对应系统故障^[8]。(3) 基于人工智能的故障诊断方法, 其主要是应用于一些很难建立精确数学模型的复杂系统进行故障诊断^[9]。刘瑶等提出利用声发射技术对燃气调压器进行故障诊

收稿日期: 2020-07-01; 修回日期: 2020-07-19

基金项目: 北京市燃气集团高压管网分公司支持项目(19JK011)。

作者简介: 王玉玲(1996—), 女, 山东青岛人, 硕士研究生, 研究方向为信号与信息处理。

通信作者: 王玉玲, E-mail: wangyuling18@mails.ucas.ac.cn

断,通过声发射信号的奇异性来检测高压调压器是否发生故障,但并没有对调压器的具体故障类型进行判断^[10]。

声发射信号本质上是一个时间序列^[11],如果能够通过时域数据进行调压器故障诊断,则更容易在实践中应用。深度学习具有自动学习提取信号内部特征的能力,在故障诊断研究方面可以得到很好的分类效果^[12]。深度学习模型的优势在于具有优良的特征提取能力,能够直接利用时域声发射信号进行燃气调压器的故障诊断,可以摆脱依赖人工进行特征选取的传统方法的束缚^[13]。理解长短期记忆(Long Short Term Memory, LSTM)是一种经过改进的特殊循环神经网络(Recurrent Neural Networks, RNN),能够解决 RNN 不能处理长距离依赖性的问题,挖掘潜在的时序信息进行计算得到预测值^[14-16]。

因此,本文提出一种基于声发射的 LSTM 端到端燃气高压调压器故障诊断方法,直接利用声发射时域信号对调压器的运行状态进行诊断。所建的基于声发射的 e2e-LSTM 模型能够有效提取声发射信号的时间和空间特征,充分学习具有时序特性的故障信息,进一步提高燃气高压调压器故障诊断率。

1 声发射技术

声发射(Acoustic Emission, AE)技术是一种检测设备声与振动信号的方法。声发射本质是一种机械波,是材料在一定应力作用后发生变形或裂纹扩展,材料局域快速释放能量而产生瞬态弹性波的现象^[17]。一般而言,声发射信号十分微弱,该信号不能被人耳直接听到,需要借助灵敏的传感器才能探测到。声发射源产生声发射信号,材料在一定外力或者内力作用下的形变或者断裂是主要的声发射源^[18]。而与材料变形或断裂无直接关系的弹性波源,如流体泄漏、物体撞击、机械摩擦、燃烧等称为二次声发射源^[19]。

因为长时间运行受到的阀座腐蚀损伤、弹簧疲劳、阀口磨损、阀口缺陷、筒壁气蚀变薄等一些原因导致调压器运行异常。当调压支路进、出口阀门全部开启时,调压器处于工作状态。调压器阀门开启前后,阀口处巨大的压力差导致内部流体天然气从阀口处喷涌而出,因此会产生波动压力场,形成湍流,调压器的声发射信号主要来源于以下两种原因:

(1) 湍流或空气动力学发声:当天然气从阀口喷涌而出时,高速流体天然气突然减速或膨胀,从而产生湍流。它是声发射信号产生的主要原因,其

大小与流体天然气速度、阀口大小、形状等有关。

(2) 机械振动发声:阀体内流体天然气压力产生的波动不规则,流体天然气对阀筒、阀门弹性等部件的冲击、扰动而产生振动,从而产生机械振动发声,此振动模式产生的声发射与金属的拍击声相类似。

五种故障的产生和发展过程中,都会伴随声发射现象的产生。经过实验发现在高压环境下,传感器能够监测到声信号的变化,调压器声发射信号是一种非平稳连续型信号。五种故障情况如下:

(1) 阀座损伤:燃气中会含有 $60 \text{ mg} \cdot \text{m}^{-3} \sim 150 \text{ mg} \cdot \text{m}^{-3}$ 的硫,与钢管发生化学反应后,生成硫化亚铁后脱落为颗粒,冲击阀座,造成阀座损伤;

(2) 弹簧异常:弹簧疲劳缩短或变形,会导致调压器关闭性能下降;

(3) 阀口磨损:缺少润滑油或 O 型圈硬化后出现的阀口磨损;

(4) 筒壁气蚀:阀筒进口或出口端外壁气蚀严重,出现减薄现象;

(5) 阀口缺陷:阀口处出现多处缺口。

2 基于声发射的 e2e-LSTM 的故障诊断系统

2.1 基于声发射的 e2e-LSTM 的故障诊断流程

本研究提出的基于声发射的 e2e-LSTM 故障诊断模型流程如图 1 所示。首先,对声发射信号进行预处理,划分得到训练集和测试集;其次,构建 e2e-LSTM 模型,通过训练集数据对 e2e-LSTM 模型进行训练,通过调整模型参数来优化模型,当交叉阈值达到设定值时,结束训练,保存训练好的模型;最后将测试集输入该模型,通过评价指标值是否接近最优,输出模型训练结果。故障诊断率计算如公式 1 所示,对故障数据集进行学习并诊断故障类型:

$$\text{故障诊断率} = \frac{\text{测试集总数} - \text{分类错误数}}{\text{测试集总数}} \times 100\% \quad (1)$$

2.2 声发射预处理

燃气调压器由于其工作环境的特殊性,存在干扰噪声,所以需要对采集的声发射信号进行预处理。通过 FFT 确定噪声的大致范围,输入信号时频域波形图如图 2 所示,根据频域波形可看出低频干扰严重。1 Hz 以下信号滤波后波形如图 3 所示,滤波前后时域放大图如图 4 所示。




图1 基于声发射的 e2e-LSTM 故障诊断模型流程图

Fig.1 Flow chart of e2e-LSTM fault diagnosis model based on acoustic emission




图2 输入声发射信号的时域波形和频谱

Fig.2 Time domain waveform of input acoustic emission signal and its frequency spectrum

高通滤波器可以滤掉若干高次谐波, 有综合滤波功能。通过图4中的滤波前1 Hz放大图, 发现低频段干扰严重, 因此设计一个二阶巴特沃斯高通滤波器, 截止频率保守设定为1 Hz, 对信号中的低频段干扰进行预处理结果如图3所示。由图4可以看出小于1 Hz的信号全部被过滤。




图3 滤波后信号时频域波形

Fig.3 Time domain waveform of the signal after filtering and its frequency spectrum




图4 滤波前后1 Hz以下的信号频谱

Fig.4 The frequency spectrum below 1 Hz of the signal before and after filtering

五种故障滤波后信号频域波形图如图5所示, 可以看出不同故障声发射信号的特征差异。


2.3 基于声发射的 e2e-LSTM 模型构建

一个 LSTM 里面包含三个门来控制细胞状态, 这三个门分别称为遗忘门、输入门和输出门^[20]。门实际上就是一层全连接层, 输入是一个向量, 输出是 $[0,1]$ 之间的一个实数向量, 这代表有多少信息能够流过 sigmoid 层, 如式(2)^[21]所示:


$$g(x) = \sigma(Wx + b) \quad (2)$$

其中, W 是门权重矩阵, b 是门的偏置项, σ 是 sigmoid 函数。利用 LSTM 的长期记忆特性, 构建基于声发射的 e2e-LSTM 模型, 模型结构如图6所示, 实现燃气高压调压器故障类型诊断。


首先对采集到的原始声发射数据进行预处理，并将其输入 LSTM 层中，利用 LSTM 的长期记忆性，输入波形与前期输出在该层得到融合，对声发




(a) 阀座损伤




(b) 弹簧异常



(c) 阀口磨损



(d) 筒壁气蚀



(e) 阀口缺陷

图 5 五种故障声发射信号的频谱图
Fig.5 Spectrum diagrams of five kinds of fault emitted acoustic signals




图 6 基于声发射的 e2e-LSTM 模型结构图
Fig.6 Structural diagram of e2e-LSTM model based on acoustic emission

射数据信息进行连续处理同时输出特征；然后全连接层通过加权计算燃气调压器的故障特征来实现特征空间转换，模型的诊断能力、复杂程度受到全连接层的层数影响，全连接层的层数过少将会导致模型的非线性表达能力受到限制，全连接层的层数过多将会导致模型参数剧增^[13]；最后经过 softmax 层分类输出作为 e2e-LSTM 模型的输入，实现信息的传递，e2e-LSTM 模型对故障数据样本进行训练，并且实现对未知样本的故障类型进行诊断。

基于声发射的 e2e-LSTM 模型的构建流程如下：

- (1) 将原始的声发射数据预处理后进行特征提取，构成训练集。
- (2) 对训练集中的数据进行标准化，处理后的训练集表示为 $X=[X_1 \ X_2 \ X_3 \ \cdots \ X_L]$ ，对应的理论输出为 $Y=[Y_1 \ Y_2 \ Y_3 \ \cdots \ Y_L]$ 。
- (3) 初始化 LSTM 网络。给出初始权值矩阵，初始权值是 0~1 间均匀分布的随机数，设定合理的最大迭代训练次数和最小误差值^[22]。
- (4) 前向计算过程。输入到隐含层的 X ，首先

通过 N 个 LSTM 层, 再通过 N 个全连接层, 将提取的特征映射到样本标记空间, 最后经过 softmax 层输出该模型的预测值 $\mathbf{Y}'^{[23]}$ 。

(5) 误差反向传播。计算 $\mathbf{Y}'$ 与 $\mathbf{Y}$ 之间的交叉熵值, 得到损失函数值, 经过多次迭代训练, 采用梯

度下降算法调节输入门、遗忘门、输出门以及全连接层的权重 $\mathbf{W}$ 和偏置 $\mathbf{b}$, 使得损失函数值逐渐减小。

对检修结果标签中五种不同的故障(如表 1 所示), 分别建立基于声发射的 e2e-LSTM 模型, 表 1 给出了五种故障模型的主要参数。

表 1 五种故障的模型参数
Table 1 Parameters of e2e-LSTM model of five faults

故障编号	故障类型	学习速率	LSTM 层的基础单元个数	全连接层的节点数	softmax 层的节点数	训练时的 keep_prob
S1	阀座损伤	0.1	2 层 LSTM 均为 5	2	2	—
S2	弹簧异常	0.1	3 层 LSTM 均为 5	2	2	—
S3	阀口磨损	0.1	2 层 LSTM 均为 5	2	2	0.2
S4	筒壁气蚀	0.1	2 层 LSTM 均为 5	2	2	—
S5	阀口缺陷	0.1	2 层 LSTM 均为 5	2	2	—

针对 S1、S4、S5 故障, 建立的 e2e-LSTM 模型包含: 两个 LSTM 基础单元模型层、一层全连接层以及一个 softmax 层。其中, 两个 LSTM 层进行特征提取, 全连接层无激活函数, 前几层提取的特征被映射到样本标记空间, 最后经过 softmax 层输出该模型的预测诊断结果。

针对 S2 故障, 建立的 e2e-LSTM 模型包含: 3 个 LSTM 基础单元模型层、一层全连接层以及一个 Softmax 层。其中, 3 个 LSTM 层进行特征提取, 全连接层无激活函数, 前几层提取的特征被映射到样本标记空间, 最后经过 softmax 层输出该模型的预测诊断结果。

针对 S3 故障, 建立的 e2e-LSTM 模型包含: 两个 LSTM 基础单元模型层、两层全连接层、一个 dropout 层以及一个 Softmax 层。其中, 2 个 LSTM 层进行特征提取, 激活函数为第一层全连接层 Relu, 第二层全连接层无激活函数, dropout 层是用来减少过拟合的, 前几层提取的特征被映射到样本标记空间, 最后经过 softmax 层输出该模型的预测诊断结果。

3 实验设置和结果

为了验证本文提出的基于声发射信号的长短时记忆网络端到端故障诊断方法的可靠性, 在燃气高压调压站进行数据采集与实验, 在调压器实际运行状态正常基础上采集的声发射数据, 配合检修中心的检修结果, 进行燃气高压调压器故障诊断的研究。

3.1 实验设置

据统计高压燃气调压站中多数为 FL 型调压器, 所以本研究是在 FL 型调压器基础上进行研究。FL 型调压器属于轴流式调压器, 进口压力范围 0.1~

9.0 MPa, 其流通能力好, 通过能力强, 可以适应较复杂情况的流体, 其性能稳定, 精密度高。

在各个燃气调压站采集数据, 补充调压站环境下各种故障类型调压器的声发射数据, 为高准确率的调压器故障诊断模型打下坚实基础。在某台调压器上进行了不同位置的声发射信号采集对比实验, 对比传感器在调压器阀桶两侧和管道两侧的声发射信号。发现在阀桶两侧能够采集到较多高频声发射信号, 管道两侧采集到高频声发射信号较少, 因此在整个数据采集实验中都选取在调压器阀桶两侧吸附传感器的方案, 更能观测到调压器的故障特征, 具体位置如图 7 所示。



图 7 待测高压调压器图
Fig.7 High pressure regulator to be tested

实验中声发射数据采集装置包括: 多个传感器, 数据采集卡以及计算机。如图 8 所示, 同一燃气管道上有运行台和监控台两个燃气调压器, 燃气流动方向是从运行台到监控台, 传感器吸附在待测的燃气高压调压器壁上, 每个传感器获得来自所在燃气调压器的声发射数据, 将所采集的声发射数据通过数据采集卡传送至计算机进行数据储存。

吸附在待测的燃气高压调压器壁上的传感器, 频率响应范围为 0.8~15 000 Hz 的耐高压防爆型, 动态范围为±50 g(峰峰值), $g=9.8\text{ m}\cdot\text{s}^{-2}$, 共振频率

为 23 kHz, 稳定时间小于 2.5 s。数据采集卡通道采样频率为 96 kHz, AD 分辨率为 24 bit, 输入为 4 通道电压或 IEPE 型电压输出传感器(2mA/+24V 直流), 频率范围为电压输入直流 30 kHz 或 IEPE 输入 0.3 Hz~30 kHz, 多通道并行采集、连续大容量数据传输。




图 8 声发射测试系统
Fig.8 Acoustic emission testing system

3.2 实验结果

每个燃气调压器故障诊断样本的采样频率为 96 kHz 的声发射信号。实验中共采集来自于不同调压器的 78 个样本, 其中, 训练样本 58 个, 测试样本 20 个。将 58 个训练样本输入到 e2e-LSTM 模型中, 数据特征经过 N 层 LSTM 模型和 N 层全连接层进行提取和处理, 最后经过 softmax 层进行分类输出。

通过多次迭代, 采用梯度下降算法不断调节 e2e-LSTM 输入门、遗忘门、输出门以及全连接层的权重 W 和偏置 b , 使得损失函数值逐渐减小至 0, 如图 9 所示。




图 9 损失函数值
Fig.9 Loss function curve

针对五种故障分别建立五种模型, 20 个测试样本输入模型后得到的实验结果如表 2 所示。输入到任意故障模型中, 正确预测正常或者正确预测异常, 则说明预测正确, 输出为 1; 正常预测为异常,

或者异常预测为正常, 则说明预测错误, 输出 0。S1、S5 故障模型输出全为 1, 20 个测试样本分类都正确; S2、S4 故障模型输出两个 0, 20 个测试样本分类错误两个; S3 故障模型输出一个 0, 20 个测试样本分类错误 1 个。诊断率计算方法见式(1), 对故障类型及诊断率进行可视化, 如图 10 所示。

表 2 五种故障诊断结果
Table 2 Diagnosis results of five faults

样本编号	模型输出				
	S1	S2	S3	S4	S5
1	1	0	1	0	1
2	1	1	0	0	1
3	1	1	1	1	1
4	1	1	1	1	1
5	1	1	1	1	1
6	1	1	1	1	1
7	1	1	1	1	1
8	1	1	1	1	1
9	1	1	1	1	1
10	1	1	1	1	1
11	1	1	1	1	1
12	1	1	1	1	1
13	1	1	1	1	1
14	1	1	1	1	1
15	1	1	1	1	1
16	1	1	0	1	1
17	1	1	1	1	1
18	1	1	1	1	1
19	1	1	1	1	1
20	1	1	1	1	1




图 10 故障类型及诊断率
Fig.10 Fault types and diagnostic rates

4 结 论

在前人基于声发射信号的燃气高压调压器故障诊断研究的基础上, 本文提出了一种基于声发射信号的 LSTM 端到端故障诊断方法, 直接利用声发射时域信号对调压器的运行状态进行诊断。利用 LSTM 的记忆特性, 建立基于声发射的 LSTM 端到端(e2e-LSTM)故障诊断模型。根据采集的声发射信号及检修标签, 实验结果表明, 该模型能够以端到

端模式一次性地诊断五种高压调压器故障, 每种类型故障准确率可以达到 90%以上, 为基于声发射信号的 LSTM 端对端燃气高压调压器故障诊断提供了依据及方法。

参 考 文 献

- [1] 柴浚源. 中国城市燃气事业现状及发展趋势[J]. 化工设计通讯, 2017, 43(10): 21.
CHAI Junyuan. Current situation and development trend of urban gas industry in China[J]. Chemical Engineering Design Communications, 2017, 43(10): 21.
- [2] 李远, 刘成, 高远. 浅析城市燃气输配管网现状及优化研究[J]. 中国石油和化工标准与质量, 2019, 39(19): 106-107.
CHEN Yuan, LIU Cheng, GAO Yuan. Analysis on the status and optimization of urban gas transmission and distribution networks[J]. China Petroleum and Chemical Standards and Quality, 2019, 39(19): 106-107.
- [3] 郭杰, 刘勇, 张道洪, 等. 天然气在我国燃气行业的利用现状[J]. 煤气与热力, 2018, 38(10): 18-22.
GUO Jie, LIU Yong, ZHANG Daohong, et al. Utilization status of natural gas in China gas industry[J]. Gas & Heat, 2018, 38(10): 18-22.
- [4] 刘强. 燃气调压器故障诊断与安全预警技术研究[D]. 北京: 北京建筑大学, 2016.
- [5] 刘月骁. 燃气调压器故障智能诊断技术的应用研究[D]. 北京: 北京建筑大学, 2017.
- [6] 故障诊断. 百度百科[EB/OL]. <https://baike.baidu.com/item/>.
- [7] 周东华, 王庆林. 基于模型的控制系统的故障诊断技术的最新进展[J]. 自动化学报, 1995, 21(2): 244-248.
- [8] 崔金玉. 高中压燃气调压器故障特征研究与安全预警应用[D]. 北京: 北京建筑大学, 2018.
- [9] 吴今培, 肖健华. 智能故障诊断与专家系统[M]. 北京: 科学出版社, 1997.
- [10] 刘瑶, 位亚鹏, 邢琳琳, 等. 基于声发射技术的燃气调压器故障诊断[J]. 管道技术与设备, 2018(6): 25-28.
LIU Yao, WEI Yapeng, XING Linlin, et al. Gas pressure regulator fault diagnosis based on acoustic emission technology[J]. Pipeline Technique and Equipment, 2018(6): 25-28.
- [11] VICUÑA C M, HÖWELER C. A method for reduction of Acoustic Emission (AE) data with application in machine failure detection and diagnosis[J]. Mechanical Systems and Signal Processing, 2017, 97: 44-58.
- [12] BAO W, YUE J, RAO Y. A deep learning framework for financial time series using stacked autoencoders and long-short term memory[J]. PLoS One, 2017, 12(7): e0180944.
- [13] 庄雨璇, 李奇, 杨冰如, 等. 基于 LSTM 的轴承故障诊断端到端方法[J]. 噪声与振动控制, 2019, 39(6): 187-193.
ZHUANG Yuxuan, LI Qi, YANG Bingru, et al. An end-to-end approach for bearing fault diagnosis based on LSTM[J]. Noise and Vibration Control, 2019, 39(6): 187-193.
- [14] BOGAERTS T, MASEGOSA A D, ANGARITA-ZAPATA J S, et al. A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data[J]. Transportation Research Part C: Emerging Technologies, 2020, 112: 62-77.
- [15] WANG J Q, DU Y, WANG J. LSTM based long-term energy consumption prediction with periodicity[J]. Energy, 2020, 197: 117197.
- [16] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306.
- [17] 严心涛. 基于声发射的阀门泄漏检测方法的研究[D]. 哈尔滨: 哈尔滨工业大学, 2011.
- [18] 刘贵杰, 徐萌, 王欣, 等. 基于 HHT 的管道阀门内漏声发射检测研究[J]. 振动与冲击, 2012, 31(23): 62-66.
LIU Guijie, XU Meng, WANG Xin, et al. AE detection for pipeline valve leakage based on HHT[J]. Journal of Vibration and Shock, 2012, 31(23): 62-66.
- [19] 高倩霞. 声发射技术在阀门泄漏故障检测中的应用研究[D]. 长沙: 长沙理工大学, 2011.
- [20] 梁建增. 用于客服辅助的对话模型研究[D]. 杭州: 浙江大学, 2017.
- [21] 曾慧洁, 郭建胜. 双向 LSTM 神经网络的航空发动机故障预测[J]. 空军工程大学学报(自然科学版), 2019, 20(4): 26-32.
ZENG Huijie, GUO Jiansheng. Fault prognostic of aeroengine using bidirectional LSTM neural network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(4): 26-32.
- [22] 上官伟, 孟月月, 杨嘉明, 等. 基于 LSTM-BP 级联网络的列车车载设备故障诊断[J]. 北京交通大学学报, 2019, 43(1): 54-62.
SHANGGUAN Wei, MENG Yueyue, YANG Jiaming, et al. LSTM-BP neural network based fault diagnosis for on-board equipment of Chinese train control system[J]. Journal of Beijing Jiaotong University, 2019, 43(1): 54-62.
- [23] JAIN M, A V S, DENMAN S, et al. LSTM guided ensemble correlation filter tracking with appearance model pool[J]. Computer Vision and Image Understanding, 2020, 195: 102935.