



引用格式:丁頔,南国防. CNN-RNN 融合法在旋转机械故障诊断中的应用[J]. 轻工学报, 2020,35(1):102-108.

中图分类号:TK05 文献标识码:A

DOI:10.12187/2020.01.013

文章编号:2096-1553(2020)01-0102-07

# CNN-RNN 融合法在旋转机械故障诊断中的应用

## Application of CNN-RNN fusion method in fault diagnosis of rotating machinery

丁頔,南国防

DING Di, NAN Guofang

**关键词:**  
卷积神经网络;递归神经网络;故障诊断;旋转机械

上海理工大学 能源与动力工程学院,上海 200093  
*School of Energy and Power Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China*

**Key words:**  
convolutional neural network(CNN); recurrent neural network(RNN); fault diagnosis; rotating machinery

**摘要:**针对目前旋转机械故障诊断存在运算时间长、精度不高等问题,将CNN的特征提取能力和RNN时序处理能力相结合,提出了CNN-RNN融合分析法。该方法使用一维CNN网络提取特征数据,剔除受环境噪音等因素影响的无效信息且依然具有时序性,再由处理时序数据精度较高的RNN对该特征数据进行计算处理进而对旋转机械进行故障诊断。在测试集上的验证实验结果表明,该方法不需要手动提取特征数据,运算时间大约减少1/2,故障诊断精度提高约2%,具有可行性。

收稿日期:2019-08-15

作者简介:丁頔(1997—),男,安徽省亳州市人,上海理工大学硕士研究生,主要研究方向为深度学习和旋转机械故障诊断。

通信作者:南国防(1980—),男,陕西省西安市人,上海理工大学副教授,主要研究方向为材料与振动、旋转机械。

**Abstract:** Aiming at the problems of current fault diagnosis of rotating machinery with long calculation time and low accuracy, a CNN-RNN fusion analysis method was proposed by combining the feature extraction capability of CNN and the processing capability of RNN timing. A one-dimensional CNN network was used to extract feature data, which removed invalid information affected by environmental noise and other factors and still had timeliness. Then, the RNN with high accuracy of processing time-series data calculated the feature data and then applied to the fault diagnosis of rotating machinery. The experimental results on the test set showed that the method did not require manual extraction of feature data, the computing time was reduced by about 1/2, and the accuracy of fault diagnosis was increased by about 2%. This method had feasibility.

## 0 引言

随着现代科技的发展,机械、机电设备的集成度越来越高且越来越复杂.当设备发生故障的时候,集成化程度越高、精密度越高的设备,通过拆卸来判断故障的发生位置就越困难.传统的故障诊断方法需要建立设备模型,使用小波分析等方法,从业人员还需要有丰富的行业经验和实践经历,要求较高.2006年深度学习理论被提出后,业界开始将深度学习法用于故障诊断<sup>[1-2]</sup>.目前,主流的深度学习网络模型有卷积神经网络(CNN)模型和递归神经网络(RNN)模型两种.H. Yu等<sup>[3]</sup>利用深度卷积模型对原始信号进行处理,并使用适应性方法进行模型训练,在测试集上的准确率为92.4%.庄雨璇等<sup>[4]</sup>使用e2e-LSTM准确地识别了不同负载情况下的轴承故障类型和故障尺寸,准确率达到98.55%.张青青<sup>[5]</sup>使用改进的AlexNet对滚动轴承变工况故障进行诊断,准确率达到90.75%.A. Rai等<sup>[6-7]</sup>手动提取时域、频域信号,使用CNN进行故障识别,准确率可达93.5%.M. Jouin等<sup>[8-9]</sup>采用改进的RNN对原始数据进行训练,可进一步提高故障诊断的准确率.

上述研究都只是单独使用CNN或者RNN进行训练,不适用于旋转机械的故障诊断.旋转机械的故障数据具有明显的时态性,CNN在处理该类型数据时,效率和精度都没有RNN高.而RNN没有特征提取能力,一般采用提取时

域、频域信号或者PCM方法作为预处理的一部分,而这两种预处理方法均没有CNN的提取效率高,并且在多工况状态下还需要手动调整相关参数.鉴于此,本文拟将CNN与RNN相融合,先使用CNN高效提取特征数据集,再利用RNN模型对提取之后的特征数据进行训练,进而对轴承等旋转机械进行故障诊断,以期达到减少人工提取时间,提高故障诊断效率和精度的目的.

## 1 CNN-RNN 融合法

### 1.1 CNN-RNN 融合法的思路

在针对轴承等旋转机械的故障诊断中,对输入信号数据集进行处理以提取其中的有效部分是重要而又繁琐的环节<sup>[8]</sup>.这个环节需要工程师拥有多年的相关经验才能处理好,否则可能导致数据获取失败,无法正确进行故障诊断.而CNN能够自动提取数据集的特征,并进行处理<sup>[10-14]</sup>.传统处理过程与CNN处理过程的比较如图1所示.

虽然RNN需要手动提取时域、频域等特征信息,但是可以使用上一次计算的隐含层来进行计算,从而提高权重计算的准确性,适用于序列性比较强的数据,比如从0到1的故障诊断数据.RNN单层计算流程如图2所示.图2中向量 $\mathbf{x}$ 是经过特征提取后输入的时域、频域数据; $\mathbf{s}$ 表示隐藏层的值,其不仅受当前输入数据的影响,也受上次计算的隐藏层值的影响;权重矩阵 $\mathbf{W}$ 是隐藏层上一次的值,可作为这一次输

入的权重;  $U$  是输入层到隐藏层的权重矩阵, 与此相对应的是  $V$ , 它代表隐藏层到输入层的权重矩阵;  $O$  表示输入的时域、频域数据经过和上一次隐藏层数据联合计算后的输出数据。

CNN 适用于分层数据, 能够自动提取数据特征; RNN 适用于时态数据和其他类型的序列数据, 计算耗时一般较 CNN 少. 对于轴承故障诊断来说, 相比于 RNN, CNN 能够提取时域、频域等特征, 但是 CNN 无法将数据序列看成是一连串的具有时序的数据. 轴承故障数据表明了轴承从正常工作到出现故障是一个渐进、连续的过程, CNN 在计算过程中无法体现出这些时序的特征<sup>[15-16]</sup>, 而 RNN 可以, 所以本文将 CNN 与 RNN 进行融合, 先使用 CNN 进行特征提取的预处理, 处理之后的数据交给 RNN 进行训练.

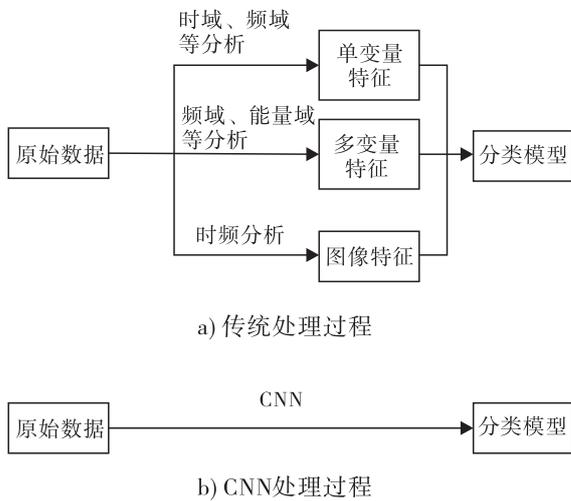


图1 传统处理过程与 CNN 处理过程的比较

Fig. 1 Comparison of traditional processing and CNN processing

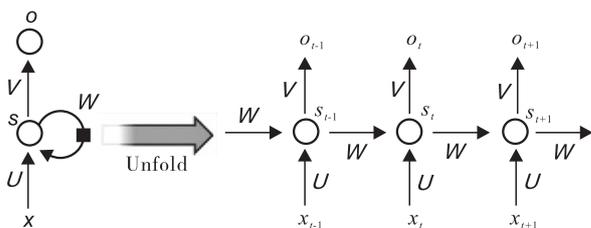


图2 RNN 单层计算流程

Fig. 2 RNN single layer calculation process

## 1.2 CNN-RNN 融合法的运算基础

### 1.2.1 激活函数 Relu

Relu 函数的表现形式如下:

$$Relu(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases}$$

当输入  $x \leq 0$  时, 抑制此神经元; 当输入  $x > 0$  时, 神经元保持线性激活的状态. 使用 Relu 激活函数有三大优点: 第一, 相比传统的 Sigmoid 函数和 Tanh 函数, 当输入偏离 0 较多时, 神经元不会陷入饱和状态而导致反向传播过程中出现梯度消失的现象; 第二, 可以加快网络的学习收敛速度; 第三, Relu 函数可以使神经元输出具有一定的稀疏性, 即一些输出为 0, 这样可以增强模型的泛化能力<sup>[17-19]</sup>.

### 1.2.2 交叉熵损失函数

交叉熵损失函数常被用在分类问题上, 它一般具有两个性质: 一是非负性; 二是当实际输出  $a$  与目标输出  $y$  接近时, 代价函数接近于 0. 其表达形式如下:

$$c(w, b) = -\frac{1}{n} \sum_j [y \ln a + (1 - y) \ln(1 - a)]$$

对  $w$  和  $b$  求导可得

$$\frac{\partial c}{\partial b} = -\frac{1}{n} \sum_j \left( \frac{y}{\sigma(z)} - \frac{1 - y}{1 - \sigma(z)} \right) \sigma'(z)$$

$\sigma(z)$  为网络的激活函数, 当  $\sigma(z)$  为 Sigmoid 函数时, 有

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

$$\sigma'(z) = \frac{e^{-z}}{(1 + e^{-z})^2} =$$

$$\frac{1}{1 + e^{-z}} - \frac{1}{(1 + e^{-z})^2} = \sigma(z)(1 - \sigma(z))$$

将  $\sigma'(z) = \sigma(z)(1 - \sigma(z))$  代入交叉熵损失函数的导函数中, 可推导出:

$$\frac{\partial C}{\partial w} = \frac{1}{n} \sum_j (\sigma(z) - y) \times x$$

$$\frac{\partial C}{\partial b} = \frac{1}{n} \sum_j (\sigma(z) - y)$$

交叉熵导函数可以避免由于  $\sigma'(z)$  达到极

小值而造成的模型迭代速度缓慢的问题,同时由  $\sigma(z) - y$  控制梯度下降,在误差较大时,学习率相同,  $w$  和  $b$  更新步长更大<sup>[20]</sup>.

**1.2.3 Softmax 函数** 在 Logistic regression 二分类问题中, Sigmoid 函数会将一个 real value 映射到  $(0, 1)$  区间. 将这个问题泛化, 推广到多分类问题中, 可以使用 Softmax 函数将输出的值归一化为概率值. Softmax 函数形式如下:

$$\sigma(z_j) = e^{z_j} / \sum_{j=1}^n e^{z_j}$$

其中,  $n$  是输出层的神经元个数, 即分类问题的类别数. 所有的  $\sigma(z_j)$  取值都在  $(0, 1)$  区间, 而  $\sum_{j=1}^n e^{z_j}$  作为归一化因子可保证所有  $\sigma(z_j)$  的和为 1. 对 Softmax 函数求导过程如下.

当  $i = j$  时, 有

$$\sigma'(z_i) = \frac{\partial}{\partial z_i} \left( \frac{e^{z_j}}{\sum_{j=1}^n e^{z_j}} \right) =$$

$$\frac{(e^{z_j})' \times \sum_{j=1}^n e^{z_j} - e^{z_j} \times e^{z_j}}{\left( \sum_{j=1}^n e^{z_j} \right)^2} =$$

$$\frac{e^{z_j}}{\sum_{j=1}^n e^{z_j}} - \frac{e^{z_j}}{\sum_{j=1}^n e^{z_j}} \times \frac{e^{z_j}}{\sum_{j=1}^n e^{z_j}} = \sigma(z_j) (1 - \sigma(z_j))$$

当  $i \neq j$  时, 有

$$\sigma'(z_i) = \frac{\partial}{\partial(z_i)} \left( \frac{e^{z_j}}{\sum_{k=1}^n e^{z_k}} \right) =$$

$$\frac{0 \times \sum_{k=1}^n e^{z_k} - e^{z_j} \times e^{z_i}}{\left( \sum_{k=1}^n e^{z_k} \right)^2}$$

交叉熵表示的是两个概率分布之间的距离, 概率分布体现了不同事件发生的概率. 在多分类问题中, 所有 Softmax 交叉熵损失函数与二分类交叉熵函数略有不同, 它与最大似然估计是等价的, 函数的公式为

$$C = - \frac{1}{n} \sum_j y_j \ln a_j$$

权重  $w$  和  $b$  的梯度公式如下:

$$\begin{aligned} \frac{\partial C}{\partial b_i} &= - \frac{1}{n} \left( \sum_j y_j \times \frac{1}{a_j} \times \frac{\partial a_j}{\partial z_i} \right) = \\ &= - \frac{y_i}{a_i} \times a_i (1 - a_i) - \sum_{j \neq i} y_j \times \frac{1}{a_j} \times (-a_j a_i) = \\ &= - y_i (1 - a_i) + \sum_{j \neq i} y_j a_i = - y_i + \sum_{j=1} y_j a_i = a_i - y_i \end{aligned}$$

梯度公式中没有  $\sigma'(z_i)$ , 可以避免由其造成的训练速度变慢的问题<sup>[21]</sup>.

### 1.3 CNN-RNN 融合法深度学习网络构建

CNN-RNN 融合法深度学习网络图如图 3 所示.



图 3 CNN-RNN 融合法深度学习网络图

Fig. 3 CNN-RNN fusion method deep learning network diagram

由图 3 可知, CNN-RNN 融合法深度学习网络第一层是 ReLU 激活函数的卷积层, 用来提取特征数据; 第二层是池化层, 进行降维和特征压缩; 第三层同样是卷积层, 做一些数据的预处理工作; 第四层是 GRU 层, 也就是真正用来计算的网路层; 最后一层是全连接层, 输出的数据使用 adm 优化器和 categorical 损失函数处理验证.

## 2 验证实验

### 2.1 数据来源

本次研究数据均来自美国西储大学轴承数据中心. 实验平台由电机、转矩传感器、功率计和电子控制设备构成. 轴承故障是使用电火花制造的, 为了对这个影响进行定量研究, 实验中分别在单点驱动端和风扇端的轴承外圈 3 点钟 (直接位于受载区)、6 点钟 (正交于受载区)、12 点钟方向布置故障. 分别采集正常轴承、单点驱动端和风扇端故障数据用于故障诊断分析<sup>[22]</sup>.

### 2.2 样本设置

本次实验数据为深沟球轴承的12K驱动端故障数据,其提取范围如下:故障深度为0.177 8 mm;故障位置分别为轴承外圈3点钟、6点钟、12点钟方向;电机载荷分别为0.7 kW,1.4 kW,2.1 kW,2.8 kW.轴承转一圈采样400个点,从每一个故障时间序列数据选择120 000个采样点.将400个采样点作为1个样本,所以一个故障时间序列有300个样本.每种故障位置取1000个故障序列,总共 $3 \times 10^5$ 个样本.验证数据为 $1 \times 10^5$ 个样本.

### 2.3 结果与分析

为验证本文方法在训练精度和时间上的优势,将轴承故障数据分别输入使用CNN处理和CNN-RNN融合法处理的网络中进行计算,结果如图4—图8所示.

由图4和图5可知,在仅使用CNN的情况下,经过10次训练,验证损失率降低到15.1%,验证精度达92.8%.由图6和图7可知,在使用CNN做特征提取、RNN做迭代计算的情况下,经过10次训练,验证损失率降至9.13%,验证精度达98.18%.由图8可知,在负载分别为0.7 kW,1.4 kW,2.1 kW,2.8 kW时,CNN运算时间基本均为本文方法的2倍,由

此证明了使用CNN-RNN融合法能够大幅度减少计算所需时间.

为验证本文方法针对轴承不同位置的故障均具有良好的泛化性,将轴承外圈3点钟、6点钟、12点钟位置的故障数据和轴承内圈的故障数据分别使用CNN,RNN与本文方法进行训练验证.CNN,RNN与本文方法测试集精度的对比结果如图9所示.

由图9可知,在轴承外圈3点钟、6点钟、12点钟位置和轴承内圈出现电火花故障的测试集下,CNN-RNN融合法的精度比单独使用CNN或

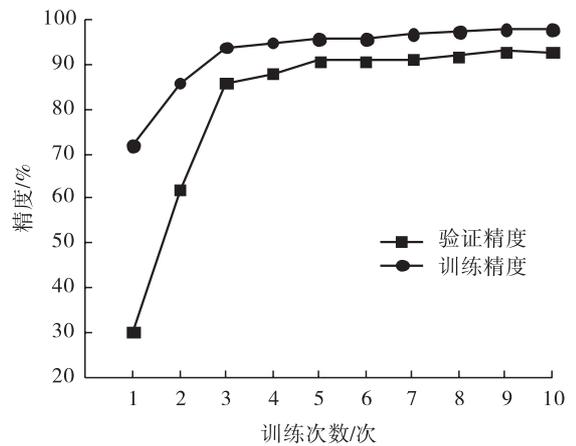


图5 CNN训练精度和验证精度  
Fig. 5 CNN training accuracy and verification accuracy

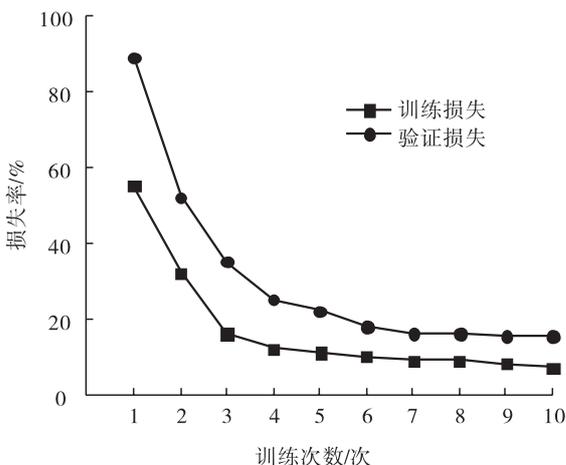


图4 CNN训练损失和验证损失

Fig. 4 CNN training loss and verification loss

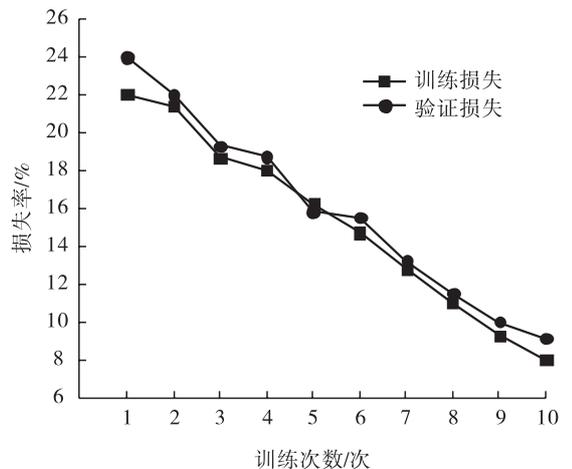


图6 本文方法的训练损失和验证损失

Fig. 6 Training loss and validation loss of the method in this paper

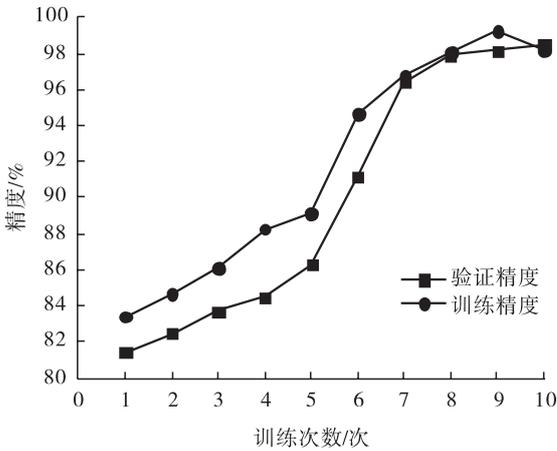


图7 本文方法的训练精度和验证精度

Fig.7 Training accuracy and verification accuracy of the method in this paper

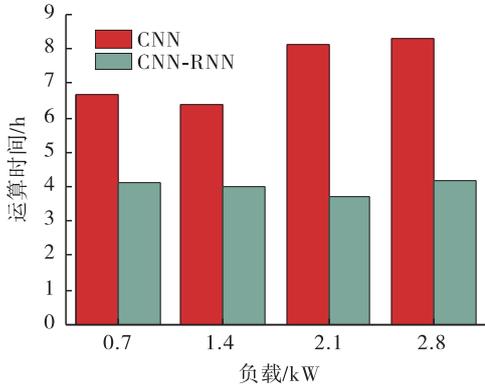


图8 CNN与本文方法的运算时间对比

Fig.8 Comparison of computing time between CNN and the method in this paper

者RNN提高约2%,证明该方法在故障诊断实践中具有可行性.

### 3 结语

本文将CNN的特征提取能力与RNN的时序处理能力相结合,提出了CNN-RNN融合法,并将其应用于轴承类旋转机械的故障诊断.该方法先使用CNN进行数据处理,提取相应特征并过滤无效信息,处理后的数据再经RNN网络进行计算.在测试集上的验证实验表明,将CNN与RNN结合之后,减少了大约1/2的计算时间,故障诊断精度提高约2%,该方法在实践

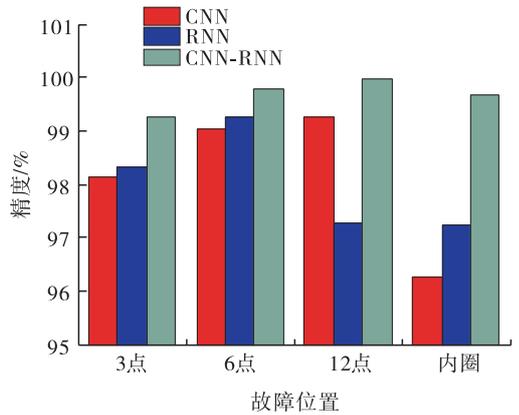


图9 CNN,RNN与本文方法在测试集精度的对比

Fig.9 Comparison of CNN,RNN and the method in this paper on test set accuracy

中是可行的.因为实验设备限制,本文未对现实中机械故障发生的时序性进行研究.下一步将对振动故障从0到1的时序数据进行研究,以实现根据当前数据预测可能发生故障的概率,从而及时采取措施,避免安全事故的发生.

### 参考文献:

- [1] 陈长征,张省,虞和济.基于神经网络的旋转机械故障诊断研究[J].机械强度,2000,22(2):104.
- [2] 任浩,屈剑锋,柴毅,等.深度学习在故障诊断领域中的研究现状与挑战[J].控制与决策,2017,32(8):1345.
- [3] YU H,HATZIVASSILOGLOU V.Towards answering opinion questions: Separating facts from opinions and identifying the polarity of opinion sentences[C]//Proceedings of Conference on Empirical Methods in Natural Language Processing. Sapporo:ACL,2003:129.
- [4] 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.
- [5] 张青青.基于改进AlexNet的滚动轴承变工况故障诊断研究[D].兰州:兰州理工大学,

- 2019.
- [6] RAI A, UPADHYAY S H. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings [J]. Tribology International, 2016, 96: 289.
- [7] WANG L, WANG Z G, LIU S. An effective multivariate time series classification approach using echo state network and adaptive differential evolution algorithm [J]. Expert Systems with Applications, 2016, 43: 237.
- [8] JOUIN M, GOURIVEAU R, HISSEL D, et al. Particle filter-based prognostics: Review, discussion and perspectives [J]. Mechanical Systems and Signal Processing, 2015, 72/73: 194.
- [9] 赵光权, 葛强强, 刘小勇, 等. 基于 DBN 的故障特征提取及诊断方法研究 [J]. 仪器仪表学报, 2016, 37(9): 1946.
- [10] 李巍华, 单外平, 曾雪琼. 基于深度信念网络的轴承故障分类识别 [J]. 振动工程学报, 2016, 29(2): 340.
- [11] 刘辉海, 赵星宇, 赵洪山, 等. 基于深度自编码网络模型的风电机组齿轮箱故障检测 [J]. 电工技术学报, 2017, 32(17): 156.
- [12] 时培明, 梁凯, 赵娜, 等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断 [J]. 中国机械工程, 2017, 28(9): 1056.
- [13] 李巍华, 单外平, 曾雪琼. 基于深度信念网络的轴承故障分类识别 [J]. 振动工程学报, 2016, 29(2): 340.
- [14] 侯文擎, 叶鸣, 李巍华. 基于改进堆叠降噪自编码的滚动轴承故障分类 [J]. 机械工程学报, 2018, 54(7): 87.
- [15] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification [C] // 2015 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE Conference Publications, 2015: 14.
- [16] 张倩. 基于共振解调原理和转速阶比谱分析的滚动轴承故障诊断方法研究 [D]. 杭州: 浙江大学, 2012: 37.
- [17] EL-THALJI I, JANTUNEN E. A summary of fault modelling and predictive health monitoring of rolling element bearings [J]. Mechanical Systems and Signal Processing, 2015, 60/61: 252.
- [18] VINYALS O, TOSHEV A, BENGIO S, et al. Show and tell: A neural image caption generator [C] // Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Conference Publications, 2015: 47.
- [19] 石鑫, 朱永利. 深度学习神经网络在电力变压器故障诊断中的应用 [J]. 电力建设, 2015, 36(12): 116.
- [20] 吴国文, 肖翱. 基于深度学习神经网络的齿轮箱故障识别研究 [J]. 网络安全技术与应用, 2016(12): 162.
- [21] 侯荣涛, 周子贤, 赵晓平, 等. 基于堆叠稀疏自编码的滚动轴承故障诊断 [J]. 轴承, 2018(3): 49.
- [22] 张西宁, 向宙, 唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用 [J]. 西安交通大学学报, 2018, 52(7): 6.