

# 基于CNN与BLS的滚动轴承故障诊断方法\*

官源林<sup>1</sup>, 刘贵林<sup>1</sup>, 于春雨<sup>1</sup>, 杨熙鑫<sup>2</sup>, 井陆阳<sup>1</sup>

(1. 青岛理工大学机械与汽车工程学院 青岛, 266520)

(2. 青岛大学计算机科学技术学院 青岛, 266071)

**摘要** 针对传统滚动轴承故障诊断方法训练时间长和效率低的问题,提出一种基于卷积神经网络(convolutional neural networks,简称CNN)和宽度学习系统(broad learning system,简称BLS)的故障诊断方法,实现了端到端的快速准确模式识别。首先,建立CNN与BLS结合的宽度卷积学习系统(broad convolutional learning system,简称BCLS),利用CNN提取信号特征和BLS进行分类,获得系统输出;其次,通过残差学习增加BLS层数,形成堆叠宽度卷积学习系统(stacked broad convolutional learning system,简称SBCLS),优化预测输出与真实标签的误差,对轴承故障模式进行识别;最后,通过试验将所提方法与3种BLS方法的预测结果进行了比较验证。结果表明,与几种常见故障诊断方法相比,所提方法诊断效果更佳,具有更高的准确率和训练效率,在边缘端的智能故障诊断中具有较好的应用前景。

**关键词** 堆叠宽度卷积学习系统;卷积神经网络;故障诊断;滚动轴承  
**中图分类号** TH17

## 引言

旋转机械是工业发展的重要装备,在制造、冶金和化工等领域应用广泛<sup>[1]</sup>,但因工作环境严苛,易引发故障<sup>[2]</sup>,导致人员伤亡与经济损失。滚动轴承是旋转机械的关键部件,其年故障率约占35%<sup>[3]</sup>,极大影响了旋转机械设备的可靠性与安全性。因此,研究滚动轴承诊断方法具有重要意义。

传统机器学习方法已广泛应用于机械故障诊断领域。解晓婷等<sup>[4]</sup>利用快速傅里叶变换(fast Fourier transform,简称FFT)和支持向量机分类(support vector machine,简称SVM)对信号进行预处理和故障诊断。Ma等<sup>[5]</sup>利用小波包分解(wavelet packet decompose,简称WPD)提取信号特征,再输入到极限学习机(extreme learning machine,简称ELM)以实现故障分类。但是,上述方法需选取经处理的特征信号,泛化能力较差,诊断性能不高。

近年来,深度学习因其模型性能好和适应性强等优点被广泛应用于复杂故障诊断中<sup>[6]</sup>。Zhang等<sup>[7]</sup>提出基于CNN的诊断模型,将轴承原始信号直接输入到模型中,获取高故障分类准确率。Wu等<sup>[8]</sup>采用基于自编码器(autoencoder,简称AE)的诊断方法,利用AE无监督学习能力,提高模型在少标签样

本下的分类精度。深度学习模型也解决了轴承故障诊断领域中数据不平衡<sup>[9]</sup>和多工况迁移学习<sup>[10]</sup>等问题,但其训练时间长,与故障诊断响应的实时分析相矛盾,且计算资源消耗严重,难以在工业装备上得到进一步应用。

BLS<sup>[11]</sup>是一种宽度延伸网络的学习方法,具有参数少、训练速度快的优点,已应用于工业故障诊断领域<sup>[12-14]</sup>。Zhao等<sup>[15]</sup>提出利用主成分分析(principal component analysis,简称PCA)对经过FFT处理的轴承信号进行降维和BLS实现分类的方法,训练速度和准确率得到有效提升。然而,BLS因拟合能力有限,在轴承故障分类时需对数据进行特征预处理,无法实现数据端到端处理。

针对上述问题,笔者提出一种基于CNN与BLS的滚动轴承故障诊断方法,即SBCLS方法。首先,利用CNN提取信号特征,采用BLS进行分类处理,通过残差学习提升BLS层故障诊断准确率;其次,分析系统模型参数对故障诊断准确率的影响,确定最优参数;最后,设置对照试验,探究在3种负载滚动轴承数据集下不同宽度学习方法的诊断性能,并与已有智能方法进行对比,验证了其训练速度与准确率的优越性。

\* 山东省自然科学基金资助项目(ZR2019PEE018, ZR2020QE158);山东省科技型中小企业创新能力提升资助项目(2021TSGC1063);青岛市自然科学基金资助项目(23-2-1-216-zyyd-jch)

收稿日期:2022-04-29;修回日期:2022-09-06

## 1 基础理论

### 1.1 宽度学习系统

宽度学习系统结构示意图如图1所示。




图1 宽度学习系统结构示意图

Fig.1 The structure of broad learning system

已知数据样本 $X$ ,通过BLS模型将数据样本映射成 $n$ 组特征节点,将 $n$ 组特征节点整合得到 $n$ 组特征部分 $F^n$ ,即

$$\begin{cases} F_i = \phi_i(XW_{fi} + \beta_{fi}) & (i = 1, 2, \dots, n) \\ F^n = [F_1, F_2, \dots, F_n] \end{cases} \quad (1)$$

其中: $F_i$ 为第 $i$ 组特征节点。

将 $F^n$ 代入式(2),得

$$\begin{cases} E_j = \xi_j(F^n W_{ej} + \beta_{ej}) & (j = 1, 2, \dots, m) \\ E^m = [E_1, E_2, \dots, E_m] \end{cases} \quad (2)$$

其中: $E^m$ 为 $m$ 组增强节点; $E_j$ 为第 $j$ 组增强节点。

BLS所有节点构成的特征矩阵 $A$ 为

$$A = [F^n \ E^m] \quad (3)$$

其中: $W_{fi}, \beta_{fi}, W_{ej}$ 和 $\beta_{ej}$ 为随机参数矩阵; $\phi_i$ 为线性函数; $\xi_j$ 为非线性函数。

结合BLS网络模型 $Y = AW$ ,获得输出分类结果。其中,连接权重 $W$ 为

$$W = (A^T A + \lambda I)^{-1} A^T Y \quad (4)$$

其中: $\lambda$ 为正则化系数; $I$ 为单位矩阵; $Y$ 为样本标签。

### 1.2 卷积神经网络

CNN主要由卷积层和池化层组成。卷积层由1组卷积核对输入数据按照固定步长通过局部滑动进行卷积运算形成,实现对输入数据的特征提取,其计算公式为

$$X_h^l = \sum_{j \in M_h} X_j^{l-1} * K_{hj}^l + b_h^l \quad (5)$$

其中: $X_h^l$ 为第 $l$ 层第 $h$ 个卷积特征; $M_h$ 为输入特征向量集合; $X_j^{l-1}$ 为第 $l-1$ 层输出; $*$ 为卷积运算; $K_{hj}^l, b_h^l$ 分别为卷积核参数和偏置项。

池化层位于卷积层后,利用采样方法来减小特征图尺寸。池化操作能够增加平移不变性,提高网络泛化能力。

## 2 堆叠宽度卷积学习系统

为进一步提高故障诊断的训练速度与准确率,提出一种SBCLS方法。堆叠宽度卷积学习系统结构示意图如图2所示,具体工作流程如下。

1) 构建BCLS模块提取特征。

BCLS模块由卷积层、池化层和BLS层组成。

卷积层:根据式(5)对数据 $X$ 进行卷积运算,得到 $N$ 个卷积特征,其中第 $h$ 个卷积特征的第 $j$ 个元素计算式为

$$\begin{cases} C_h(j) = \sum_{j \in d} X_j * K_h + b_h \\ \text{s.t. } KK^T = I \end{cases} \quad (6)$$

其中: $K = [K_1, K_2, \dots, K_N]$ ;  $KK^T = I$ ,表示卷积权值矩阵正交化处理,可使提取特征更加完备; $d$ 为输出特征图尺寸。

池化层:采用平方-开方池化结构<sup>[16]</sup>,在使用随机权重时具有较好的频率选择性,其输出形式为

$$P_h(j) = \sqrt{\sum_{j \in S} (C_h(j))^2} \quad (7)$$

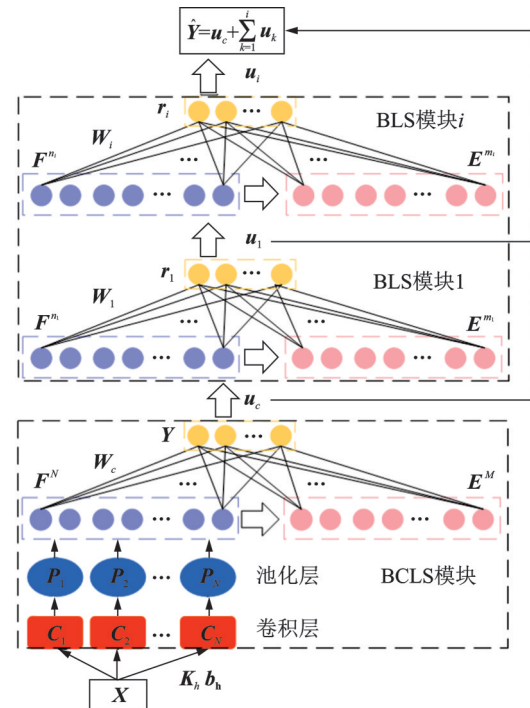


图2 堆叠宽度卷积学习系统结构示意图

Fig.2 The structure of stacked broad convolutional learning system

其中: $P_h(j)$ 为第 $h$ 个池化层第 $j$ 个元素; $S$ 为池化层尺寸。

将 $P_h$ 展平合并得到对应CNN特征 $F^N = [F_1, F_2, \dots, F_N]$ 。

BLS层:为进一步引入非线性,将CNN特征 $F^N$ 作为特征节点,由式(2)得到相应增强部分 $E^M = [E_1, E_2, \dots, E_M]$ ,结合式(3)和式(4)得到特征矩阵 $A_c$ 和连接权重 $W_c$ ,从而计算出BCLS模块输出 $u_c$ 。

$$u_c = A_c W_c = A_c (A_c^T A_c + \lambda I)^{-1} A_c^T Y \quad (8)$$

2) 堆叠BLS模块输出预测结果。

为提升网络学习效率,引入堆叠宽度学习系统中的残差学习方法<sup>[17]</sup>,形成SBCLS网络模型。以 $u_c$ 为第1层BLS模块输入,残差 $r_1 = Y - u_c$ 为拟合对象。根据式(1)和式(2)分别得到对应的 $F^{n_1}$ 和 $E^{m_1}$ ,获得连接权重 $W_1$ 和输出 $u_1$ 。

$$\begin{cases} A_1 = [F^{n_1} & E^{m_1}] \\ W_1 = (A_1^T A_1 + \lambda I)^{-1} A_1^T Y_1 \\ u_1 = A_1 W_1 \end{cases} \quad (9)$$

根据上述过程依次类推,以 $u_{i-1}$ 作为第 $i$ 层BLS模块的输入,拟合残差 $r_i = Y - u_c - \sum_{k=1}^{i-1} u_k$ ,则 $A_i = [F^{n_i} \ E^{m_i}]$ ,权重 $W_i = (A_i^T A_i + \lambda I)^{-1} A_i^T r_i$ ,输出 $u_i = A_i W_i$ 。最后,汇总SBCLS所有层的输出,获得模型预测输出为 $\hat{Y} = u_c + \sum_{k=1}^i u_k$ 。

### 3 实验

#### 3.1 数据描述

实验数据来自凯斯西储大学的滚动轴承数据集,采样频率为12 kHz,选取驱动端0, 735, 1470和2205 W等4种负载数据,包含10种轴承状态。实验样本参数如表1所示。每种轴承状态取1000个样本,每个样本有1024个数据点。实验样本按7:3的比例分为训练集和测试集。

滚动轴承故障诊断流程如图3所示。具体过程如下:①获取轴承振动信号,按比例划分为训练集和测试集,对数据进行归一化处理;②将训练集用于BCLS模块进行训练,得到初始准确率 $Z_0$ ,加入BLS模块拟合残差 $r_i$ ,得到输出 $u_i$ ,更新模型输出 $\hat{Y}$ 和准确率 $Z_i$ ,当模型准确率不高于上一层准确率时,停止增加BLS模块,训练结束;③将测试集输入到SBCLS模型中,获取测试结果。

表1 实验样本参数

Tab.1 Parameter of experimental samples

轴承状态	故障直径/mm	标签
滚子故障	0.18	1
滚子故障	0.36	2
滚子故障	0.54	3
内圈故障	0.18	4
内圈故障	0.36	5
内圈故障	0.54	6
外圈故障	0.18	7
外圈故障	0.36	8
外圈故障	0.54	9
正常	—	10

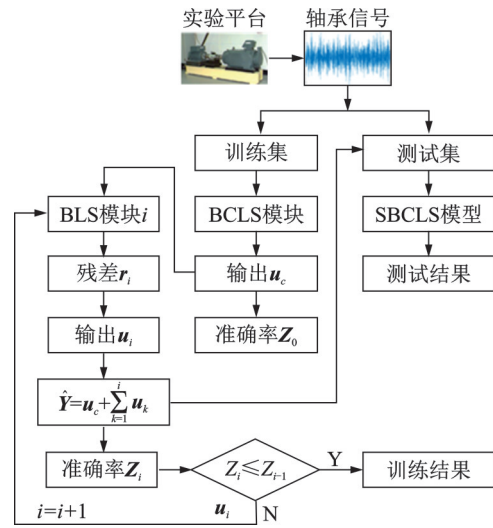


图3 滚动轴承故障诊断流程图

Fig.3 The flowchart of rolling bearing fault diagnosis

#### 3.2 模型参数设置

SBCLS模型参数主要包括CNN参数(卷积核大小 $k$ 和卷积核数量 $N$ )、层数与BLS参数(特征窗口隐藏节点数量 $N_1$ 、特征窗口数量 $N_2$ 和增强节点数量 $N_3$ )。具体参数设置如下。

1) CNN参数。

卷积核大小和数量对模型训练具有重要影响<sup>[18]</sup>。为获取BCLS方法最优的卷积核大小与数量,以735 W负载下轴承数据为例,根据网格搜索法<sup>[19]</sup>,设定卷积步长、池化步长和窗口大小均为4,增强节点数量为130,非线性激活函数为tanh函数,正则化系数 $\lambda = 2 \times 10^{-30}$ ,分析卷积核尺寸和数量对故障分类准确性的影响。不同卷积核尺寸和数量的诊断结果如图4所示。可以发现:大卷积核比小卷积核的诊断准确率高,卷积核大小 $k$ 超过23时准确率变化较小;随着卷积核数量 $N$ 的增加,准确率逐渐提高,但 $N$ 大于20时,变化范围较小,且易出现过拟合现象。因此,本研究参数设置为 $k = 23, N = 20$ 。






图4 不同卷积核尺寸和数量的诊断结果

Fig.4 Diagnostic results under different convolution kernel sizes and numbers

2) 层数和BLS参数。

为了验证所提方法的有效性,选取BLS, BCLS, SBLS与SBCLS模型进行比较。每个模型的最优参数都通过网格搜索法获取,设定SBLS层数为3,SBCLS层数为2。其中:第1层 $N_1$ 和 $N_2$ 的取值范围设为 $\{2, 4, \dots, 20\}$ , $N_3$ 的取值范围设为 $\{500, 510, \dots, 1\ 000\}$ ;其余层 $N_1$ 和 $N_2$ 取值范围设为 $\{1, 2, \dots, 10\}$ , $N_3$ 的取值范围设为 $\{100, 110, \dots, 500\}$ 。不同BLS模型的参数设置见表2。

表2 不同BLS模型的参数设置

模型	层数	参数				
		$N_1$	$N_2$	$N_3$	$k$	$N$
BLS	1	16	12	690	—	—
BCLS	1	—	—	130	23	20
SBLS	2	5	3	300	—	—
	3	2	4	100	—	—
SBCLS	1	—	—	130	23	20
	2	5	3	300	—	—

3.3 基于不同宽度学习方法的实验结果

为了验证上述4种模型的性能与结果的可靠性,选取735, 1 470和2 205 W这3种负载下的轴承数据进行实验,每类实验进行10次,以10次平均值作为最终实验结果。4种模型不同负载下的平均准确率如表3所示。

表3 4种模型不同负载下的平均准确率

模型	735 W	1 470 W	2 205 W	平均值
BLS	81.19	84.42	88.95	84.85
BCLS	99.00	99.44	99.71	99.38
SBLS	83.47	86.85	93.47	87.93
SBCLS	99.86	99.92	100.00	99.93

从表3可以看出:BLS在3种负载下的诊断准确率都最低,平均准确率为84.85%;BCLS的准确率比BLS高,达到99.38%,验证了CNN方法的有效性;SBLS的平均准确率比BLS高3.08%,说明通过堆叠拟合残差能够提高诊断精度;SBCLS精度最高,达到99.93%,相比于BLS,BCLS和SBLS,分别提升了15.08%,0.55%和12.00%。因此,SBCLS模型具有更好的轴承故障诊断性能。

为了研究上述方法的训练和测试效率,分析4种模型的训练时间与测试时间,如图5所示。可以看出:BLS虽然比BCLS训练速度快,但后者准确率高,且训练时间仅相差0.17 s;SBLS和SBCLS的训练时间分别比BLS和BCLS增加0.29 s和0.22 s,但前面2个模型准确率更高。这说明残差学习方法消耗较小的训练时间就提升了较高的准确率。




图5 4种模型的训练时间和测试时间

Fig.5 Training time and testing time of four models

为了进一步直观理解SBCLS的分类能力,通过t-分布邻域嵌入(t-distributed stochastic neighbor embedding,简称t-SNE)可视化技术,将模型提取特征降到二维平面。特征可视化如图6所示,其中不同颜色代表不同轴承状态类别。从图6(a)可以看出,原始数据分布混乱,难以区分每个故障类别;从图6(b)可以看出,经第1层BCLS网络后能够得到清晰分离出的10种故障特征;从图6(c)可以看出,经过第2层BLS网络后10种故障特征分布聚集更加紧密。结果表明,SBCLS模型具有强大的特征提取能力和分类性能。

为了分析训练样本比例对SBCLS模型诊断性能的影响,设置不同比例的训练样本进行实验,不同训练样本比例下的诊断准确率如图7所示。结果表明,当训练样本比例较小时,SBCLS模型相比其他模型具有强鲁棒性。例如在2 205 W负载下,训练样本比例为30%时,BLS,BCLS和SBLS的准确率分别为82.71%,97.91%和87.00%,SBCLS的准确率达到99.66%。随着训练样本比例的增加,SBCLS的收敛速度更快。




图6 特征可视化

Fig.6 Feature visualization




图7 不同训练样本比例下的诊断准确率

Fig.7 Diagnostic accuracy under different ratios of training samples

3.4 不同故障诊断方法的比较

为进一步验证所提方法的优越性,将其与2组不同参数的经典CNN模型、ELM和AE等已有智能故障诊断方法进行对比实验。其中:ELM模型参数见文献[19];第1组CNN<sub>1</sub>模型参数见文献[7];第2组CNN<sub>2</sub>模型参数见文献[20];AE参数见文献[21]。迭代次数均为50次,实验结果735,1470和2205W这三种负载下的平均值。不同方法的准确率和训练时间如表4所示。

从表4可以看出:ELM的训练时间虽然较短,但是准确率较低;而CNN<sub>1</sub>,CNN<sub>2</sub>和AE的准确率都较高,但是训练时间较长;本研究所提SBCLS方法故障诊断准确率均优于其他方法,且训练时间更少。因此,所提方法在训练效率与准确率方面具有明显的优越性。

表4 不同方法的准确率和训练时间

Tab.4 Accuracy and training time of different methods

模型	准确率/%	训练时间/s
ELM	82.11	5.06
CNN <sub>1</sub>	99.92	155.85
CNN <sub>2</sub>	99.60	325.63
AE	97.53	173.86
所提方法	99.93	2.19

4 结论

1) 提出了一种基于CNN和BLS的BCLS滚动轴承故障诊断方法,其兼具CNN的特征提取能力和BLS的训练速度,提高了BLS的诊断准确率。将残差学习方法融入到BCLS得到SBCLS方法,进一步提升了模型的预测性能。

2) 通过实验分析了不同BLS方法的轴承故障分类性能,结果表明,SBCLS方法能够获取极高的诊断准确性和鲁棒性。

3) 与几种已有故障诊断方法进行实验对比,本研究所提方法诊断效果更优,训练效率更高。

参 考 文 献

[1] 雷亚国,杨彬,杜兆钧,等.大数据下机械装备故障的深度迁移诊断方法[J].机械工程学报,2019,55(7):1-8. LEI Yaguo, YANG Bin, DU Zhaojun, et al. Deep transfer diagnosis method for machinery in big data era [J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8.(in Chinese)

[2] 李可,熊檬,宿磊,等.基于改进深层极限学习机的故障诊断方法[J].振动、测试与诊断,2020,40(6):1120-1127. LI Ke, XIONG Meng, SU Lei, et al. Research on mechanical fault diagnosis method based on improved deep

- extreme learning machine [J]. *Journal of Vibration, Measurement & Diagnosis*, 2020, 40(6): 1120-1127. (in Chinese)
- [3] ZHANG S, ZHANG S B, WANG B N, et al. Deep learning algorithms for bearing fault diagnostics-a comprehensive review [J]. *IEEE Access*, 2020, 8: 29857-29881.
- [4] 解晓婷, 李少波, 杨观赐, 等. 基于FFT与CS-SVM的滚动轴承故障诊断[J]. *组合机床与自动化加工技术*, 2019(4): 90-94.  
XIE Xiaoting, LI Shaobo, YANG Guanci, et al. Fault diagnosis of rolling bearing based on FFT and CS-SVM [J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2019(4): 90-94.(in Chinese)
- [5] MA J, WU J, WANG X. Fault diagnosis method based on wavelet packet-energy entropy and fuzzy kernel extreme learning machine [J]. *Advances in Mechanical Engineering*, 2018, 10(1): 1687814017751446.
- [6] HOANG D T, KANG H J. A survey on deep learning based bearing fault diagnosis[J]. *Neurocomputing*, 2018, 335: 327-335.
- [7] ZHANG W, PENG G L, LI C H, et al. A new deep learning model for fault diagnosis with good Anti-Noise and domain adaptation ability on raw vibration signals [J]. *Sensors*, 2017, 17(2): 425.
- [8] WU X Y, ZHANG Y, CHENG C M, et al. A hybrid classification autoencoder for semi-supervised fault diagnosis in rotating machinery[J]. *Mechanical Systems and Signal Processing*, 2021, 149: 107327.
- [9] LUO J Q, ZHU L C, CHEN M, et al. Imbalanced fault diagnosis of rotating machinery based on deep generative adversarial networks with gradient penalty [J]. *Processes*, 2021, 9(10): 1751.
- [10] GUO L, LEI Y G, XING S B, et al. Deep convolutional transfer learning network: a new method for intelligent fault diagnosis of machines with unlabeled data[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(9): 7316-7325.
- [11] CHEN C L P, LIU Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(1): 10-24.
- [12] WANG Y, WANG C, KANG S, et al. Network-combined broad learning and transfer learning: a new intelligent fault diagnosis method for rolling bearings [J]. *Measurement Science and Technology*, 2020, 31(11): 115013.
- [13] YU W K, ZHAO C H. Broad convolutional neural network based industrial process fault diagnosis with incremental learning capability [J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(6): 5081-5091.
- [14] ZHAO H M, ZHENG A A, DENG W, et al. Semi-supervised broad learning system based on manifold regularization and broad network[J]. *IEEE Transactions on Circuits and Systems I-Regular Papers*, 2020, 67(3): 983-994.
- [15] ZHAO H M, ZHENG A A, XU J J, et al. Fault diagnosis method based on principal component analysis and broad learning system[J]. *IEEE Access*, 2019, 7: 99263-99272.
- [16] SAXE A M, KOH P W, CHEN Z H, et al. On random weights and unsupervised feature learning[C]// *Proceedings of the 28th International Conference on International Conference on Machine Learning*. Madison, WI, USA: Omnipress, 2011: 1089-1096.
- [17] LIU Z L, CHEN C L P, FENG S, et al. Stacked broad learning system: from incremental flattened structure to deep model [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2021, 51(1): 209-222.
- [18] LUO W J, LI Y J, URTASUN R, et al. Understanding the effective receptive field in deep convolutional neural networks[C]// *Proceedings of the 30th International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2016: 4905-4913.
- [19] CHEN Z Y, GRYLLIAS K, LI W H. Mechanical fault diagnosis using Convolutional Neural Networks and Extreme Learning Machine[J]. *Mechanical Systems and Signal Processing*, 2019, 133: 106272.
- [20] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. *仪器仪表学报*, 2018, 39(7): 134-143.  
QU Jianling, YU Lu, YUAN Tao, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(7): 134-143.(in Chinese)
- [21] SHAO H, JIANG H, ZHAO H, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2017, 95: 187-204.



**第一作者简介:**官源林,男,1983年5月生,博士、讲师、硕士生导师。主要研究方向为设备状态监测、深度学习等。  
E-mail: guanyuanlin@qut.edu.cn