

基于 GCN 的轴向柱塞泵故障诊断方法*

袁科研¹, 兰媛^{1,2}, 黄家海^{1,2}, 刘智飞¹, 王君^{1,2}, 李国彦^{1,2},
牛蔺楷^{1,2}, 钮晨光^{1,2}, 熊晓燕^{1,2}

(1. 太原理工大学机械与运载工程学院 太原, 030024)

(2. 太原理工大学新型传感器与智能控制教育部重点实验室 太原, 030024)

摘要 目前的深度学习方法在故障诊断领域中没有考虑数据之间的相互依赖关系,从而忽略了数据彼此之间的空间特征。针对此问题,提出一种基于图卷积神经网络(graph convolutional neural networks,简称 GCN)模型的轴向柱塞泵故障诊断方法。首先,将轴向柱塞泵各类故障状态的原始信号进行预处理,构建具有标签的数据集;其次,使用欧式距离判定数据集中各个样本彼此之间的特征相似度,通过相似度对比的方法将数据集转化为图结构数据;然后,使用 GCN 自适应学习图结构数据中的节点特征和节点与节点彼此之间的空间特征,确定 GCN 模型的参数;最后,对测试样本进行故障状态识别,并分析该模型在不同工况下的性能表现。结果表明,该模型结构稳定,可以在不同工况下保持良好的泛化性能。

关键词 轴向柱塞泵;故障诊断;深度学习;图卷积神经网络

中图分类号 TH133.33

引言

柱塞泵为液压系统提供动力^[1],确保系统稳定运行。其在高温高压高负荷下长期运转,易导致内部损坏,影响液压系统稳定性,进而影响设备正常运行^[2]。因此,开发高效的故障诊断方法对提高液压系统稳定性至关重要^[3]。

自深度学习理论框架被 Hinton 提出以来^[4],深度神经网络在学术界发展迅速。卷积神经网络(convolutional neural network,简称 CNN)作为神经网络中的代表,采用权值共享与局部连接的网络结构,有效减少了模型的复杂度与训练参数的数量,其在故障诊断中的应用越来越广泛^[5]。魏晓良等^[6]使用长短时记忆网络(long short-term memory,简称 LSTM)和一维卷积神经网络(1 dimension-convolutional neural network,简称 1D-CNN)构建分类模型,并将不同输入压力下的振动信号作为输入来识别柱塞泵的空化程度。Sun 等^[7]采用短时傅里叶变换和小波变换得到液压泵振动信号的时频图,用二维卷积神经网络进行特征提取和故障分类。

上述研究在故障诊断方面取得了显著成果,但多数方法仅适用于张量数据,然而,数据之间的关系难以用张量表示,需借助由顶点和边构成的图结构来表达。

近年来,深度学习分析图形的表达能力引起了广泛关注。图结构数据是一种独特的非欧几里得数据结构,侧重于节点分类、链接预测和聚类等任务。图神经网络是一种基于深度的方法,直接操作图结构数据,已成为近年来一种广泛应用的图分析方法^[8]。笔者提出基于图卷积神经网络的轴向柱塞泵故障诊断方法,为轴向柱塞泵的故障诊断提供一种新思路。

1 图神经网络

1.1 图的基本理论

在图信号处理中^[9],一张图 $G=G(X,A,E)$,其中: $X \in R^{n \times d}$, X 为图节点的特征矩阵; n 为节点数目; d 为每一个节点的维度,即每一个样本的维度; E 为边的集合,将一条连接节点 $v_i, v_j \in X$ 的边记为

* 国家自然科学基金青年科学基金资助项目(51905369);山西省关键核心技术和共性技术研发攻关资助项目(2020XXX001);山西省科技重大专项资助项目(20181102016);山西省应用基础研究计划青年科技研究基金资助项目(202103021223090)

收稿日期:2022-08-24;修回日期:2022-12-06

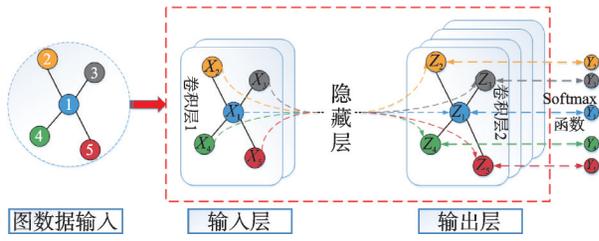


图1 两层GCN运算结构图

Fig.1 Two-layer GCN operation structure diagram

(v_i, v_j) 或者 e_{ij} ,比如图1中节点1与节点2就可以表示为 (v_1, v_2) 或者 e_{12} ; $E = \{v_i, v_j \in |X(v_i, v_j)|\}$; $A \in R^{n \times n}$,为邻接矩阵。

邻接矩阵 A 用来描述每个节点之间的关联,定义为

$$A_{ij} = \begin{cases} 1 & (v_i, v_j) \in E \\ 0 & \text{其他} \end{cases} \quad (1)$$

1.2 图的拉普拉斯矩阵

拉普拉斯矩阵是用来研究图的结构性质的核心对象,图 G 的拉普拉斯矩阵定义为

$$L = I_n - D^{-\frac{1}{2}} A D^{-\frac{1}{2}} \quad (2)$$

其中: $D_{ii} = \sum_j A_{ij}$,为 v_i 节点的度; I 为单位矩阵; A 为一张图的邻接矩阵; n 为节点数。

1.3 图傅里叶变换

图傅里叶变换输入的信号是定义在图上的信号,且图傅里叶变换的基就是图的拉普拉斯矩阵的所有特征向量。图信号 $x \in R^n$ 的图傅里叶变换的定义为

$$\hat{x} = U^T x \quad (3)$$

图傅里叶逆变换定义为 $x = U \hat{x}$ 。

1.4 图卷积理论

图信号 $x \in R^n$ 的图卷积定义为

$$(x_c * g)_\theta = U((U^T x) \cdot (U^T g)) = U g_\theta U^T x \quad (4)$$

其中: $*$ 表示图卷积运算; $g_\theta = \text{diag}(\theta)$,为由 θ 参数化的过滤器; U 为拉普拉斯矩阵 L 的特征向量矩阵。

Defferrard 等^[10] 使用切比雪夫不等式分析式(4),令

$$g_\theta = \sum_{k=0}^{k-1} \theta_k T_k(\tilde{A}) \quad (5)$$

$$h = U g_\theta U^T x = \sum_{k=0}^{k-1} \theta_k T_k(\tilde{L}) x \quad (6)$$

其中: k 为切比雪夫多项式的阶数; $\tilde{A} = \frac{2A}{\lambda_{\max}} - I_n$;

$\tilde{L} = \frac{2L}{\lambda_{\max}} - I_n$; T_k 为切比雪夫多项式,且 $T_k(\tilde{L}) = UT(\tilde{A})U^T$ 。

令 $\lambda_{\max} \approx 2$,得到

$$h = \theta_0 x + \theta_1 (L - I_n) x = \theta_0 x - \theta_1 D^{-\frac{1}{2}} A D^{-\frac{1}{2}} x \quad (7)$$

同时,令 $\theta = \theta_0 = -\theta_1$,式(7)变为

$$h = \theta (I_n + D^{-\frac{1}{2}} A D^{-\frac{1}{2}}) x \quad (8)$$

为了防止多层网络优化时出现梯度消失或爆炸,对 $\tilde{L} = I_n + D^{-\frac{1}{2}} A D^{-\frac{1}{2}}$ 进行归一化处理,得到

$\tilde{L}_{\text{sym}} = \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}}$,其中: $\tilde{A} = A + I$, $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ 。最后得到图卷积公式为

$$X' = \sigma(\tilde{L}_{\text{sym}} X W) \quad (9)$$

其中: W 为可学习参数; σ 为非线性激活函数。

2 数据图构造

实验对象是欧盛 OS-A10VSO45-TY 型斜盘式轴向柱塞泵,数据集采用轴向加速度传感器的轴向振动信号,该振动信号是一维时间序列信号,而 GCN 要求输入的数据是图结构数据,因此需要将一维时间序列转变为图结构数据。

为了将一维时间序列转换为图结构数据,将数据集集中的每个样本配有相应的标签,得到的样本集记为

$$\Pi = [(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)] \quad (10)$$

其中: x 为样本; y 为标签; n 为数据集中样本的数量^[11]。

得到样本集之后,通过将每个子样本作为图中的一个节点,构造一个具有 n 个节点的图结构数据,然后找到每个节点的邻居节点。笔者采用3种比较常见的寻找邻居节点方法,即 K 最近邻图、辐射图和路径图。通过对3种方法的分析,得到适用于柱塞泵振动数据的构图方法。

2.1 K最近邻图

使用欧式距离公式计算每个样本之间的距离^[11],其距离定义为

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^n (x_{i(k)} - x_{j(k)})^2} \quad (11)$$

其中: x_i 为第 i 个节点; x_j 为第 j 个节点; k 为节点数据的维度。

根据式(11)将第*i*个节点与其余所有节点的距离计算出来之后,从小至大排序,取出前 ϕ 个节点作为*i*节点的邻居节点^[11],所以第*i*个节点的邻居集合可表示为

$$N(x_i)=[d_1, d_2, \dots, d_\phi] \quad (12)$$

其中: $N(x_i)$ 为 x_i 节点的邻居节点集合; d_ϕ 为 x_i 节点的第 ϕ 个最近邻。

得到每一个节点的邻居节点后,节点与邻居节点彼此之间边的权重使用高斯核来计算^[11],高斯核的定义为

$$k_{ij} = e^{-\frac{\|x_i - x_j\|^2}{2\zeta^2}} \quad (13)$$

其中: k_{ij} 为节点 x_i 和节点 x_j 之间的边权重; $\zeta = N(x_i)/\phi$,为节点*i*的高斯核带宽。

2.2 辐射图

在辐射图中利用余弦相似度来估计样本之间的距离^[11],其定义为

$$(x_i, x_j) = \frac{x_i x_j}{|x_i| |x_j|} \quad (14)$$

余弦相似度是指2个样本之间的余弦值越接近于1,说明2个样本的相关性越大;接近于0,说明2个样本相关性越小。因此,定义一个阈值 ϵ ,如果 $(x_i, x_j) > \epsilon$,则表示第*i*个样本与第*j*个样本之间有一条边;反之,2个样本之间没有边。

2.3 路径图

将所有样本打乱,按照样本顺序连接起来,每两个相邻样本之间有一条边,边的权重采用式(13)定义^[11]。

3 基于GCN的故障诊断识别方法

3.1 模型概况

图2为GCN模型结构图,模型由原始信号构图层、图卷积层、非线性函数激活层以及全连接层组成。

基于GCN模型的柱塞泵故障诊断流程如下:首先,将采集的一维原始振动信号制成图结构数据 $G=G(X, A, E)$ 作为输入,通过权值共享的图卷积层对输入的 $G=G(X, A, E)$, $X' \in R^{n \times d}$ 进行特征提取,得到降维之后的图结构数据 $X' = \sigma(\tilde{L}_{\text{sym}} X W)$, $X' \in R^{n \times d_1}$;然后,对 X' 进行归一化和Relu函数激活;最后,输入到全连接层,使用Softmax函数对 x , $x \in X'$ 进行故障诊断。

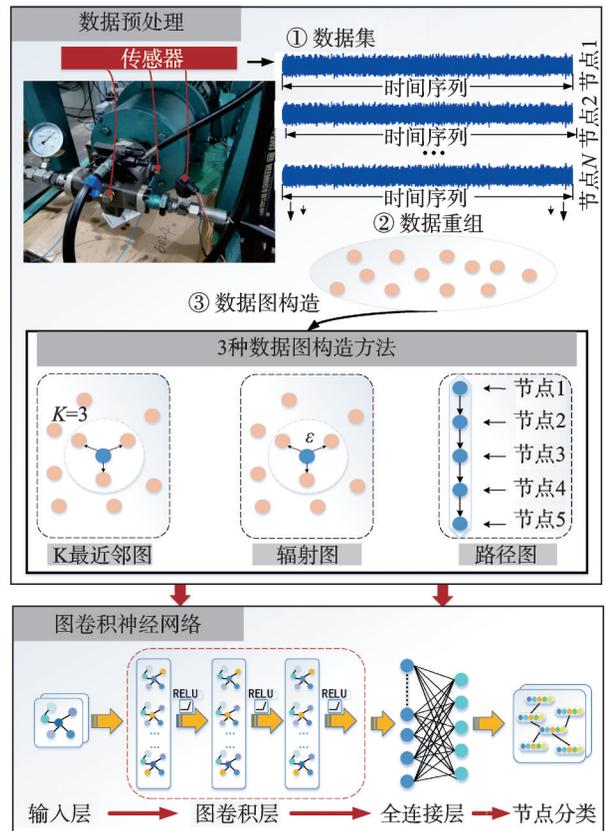


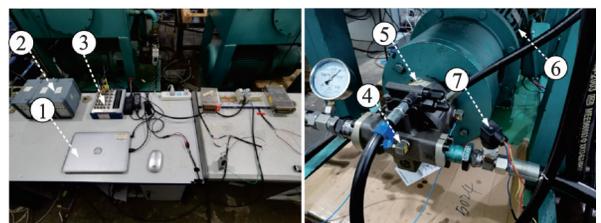
图2 GCN模型结构图

Fig.2 GCN model structure diagram

3.2 实验台及数据采集

为有效识别柱塞泵故障类型,选取欧盛OS-A10VSO45-TY斜盘式轴向柱塞泵作为实验对象,并在37 kW液压工作站上采集其5种状态数据:正常、松靴故障、滑靴磨损、配流盘磨损及中心弹簧失效。

轴向柱塞泵典型故障实验台如图3所示。驱动电机带动泵缸与柱塞旋转,加速度传感器采集振动信号,经耦合器放大后由NI-USB-6343采集卡采集并储存至电脑。采样频率为45 kHz,采样时间为2 s,每种状态采集20组数据,每组90 000个数据点。



1-电脑;2-耦合器;3-数字采集卡;4-加速度传感器;5-轴向柱塞泵;6-驱动电机;7-压力传感器

图3 轴向柱塞泵典型故障实验台

Fig.3 Axial piston pump typical failure test bench

3.3 数据集生成

采集数据后将信号切片,每个切片作为一个样本,切片原则为保留至少一个转动周期的振动信息^[6],每段信号的点数为

$$K \geq k \frac{60}{n} f \quad (15)$$

其中: K 为每段切片信号包含的点数; k 为正整数,表示转动 k 圈的信号; n 为泵的转速; f 为采样频率。

将每 2 500 个点作为一个样本,每种故障的 20 组数据(每组 90 000 点)生成 720 个样本,共 3 600 个样本。将每个样本作为图结构的一个节点,最终生成 3 600 个节点,训练节点与测试节点按 7:3 划分。数据集如表 1 所示。

表 1 数据集
Tab.1 Data set

状态	标签	样本数	训练集	测试集	合计
正常	0	720	—	—	—
松靴	1	720	—	—	—
滑靴磨损	2	720	2 520	1 080	3 600
配流盘磨损	3	720	—	—	—
中心弹簧失效	4	720	—	—	—

4 实验及结果分析

4.1 构图方法比较

不同构图方法在计算邻居节点上有所不同,生成的图结构数据也不同。为找到适合本应用的构图方法,笔者将同一组数据用 3 种常见构图方法分别输入图卷积神经网络并比较其结果。图 4 为不同构图方法对诊断结果的影响。

可以看出,使用 K 近邻法构图并输入 GCN 模型

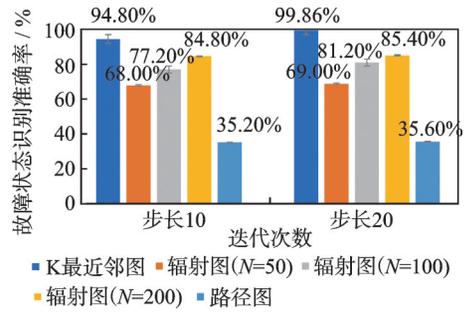


图 4 不同构图方法对诊断结果的影响

Fig.4 The influence of different composition methods on the diagnosis results

的故障识别率达 99.86%,明显高于其他 2 种构图方法。尽管辐射图的准确率随着邻居节点数 N 增加而提升,但当 N 取 200 时,训练参数增至 $3 600 \times 200$,导致训练时间大幅延长。K 近邻法的图边数为 $3 600 \times 5$,训练时间大大缩短,且准确率在 3 种构图方法中也是比较高的。

可见,采用 K 最近邻方法对样本进行构图,在保证识别准确率的前提下,可以提前结束训练,节省计算成本。

4.2 模型鲁棒性分析

考虑到设备在实际使用中负载会发生变化,笔者对 10 MPa 和 15 MPa 负载下的柱塞泵的各种故障状态识别进行研究。对每一个数据集分别进行 10 次重复实验,不同负载下故障状态的识别率为 99.86% 和 99.88%,最后的结果由混淆矩阵表示。负载为 10 MPa 时的识别结果如图 5 所示。负载为 15 MPa 时的识别结果如图 6 所示。然而,设备可能在不同负载下连续运行,笔者在 10 MPa 和 15 MPa 负载下分别采集数据并进行混合分析。混合负载识别结果如图 7 所示。

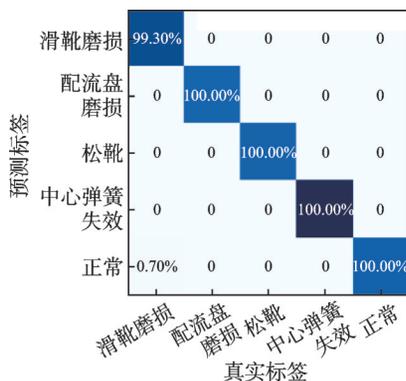


图 5 10 MPa 时的识别结果

Fig.5 Identification result at 10 MPa

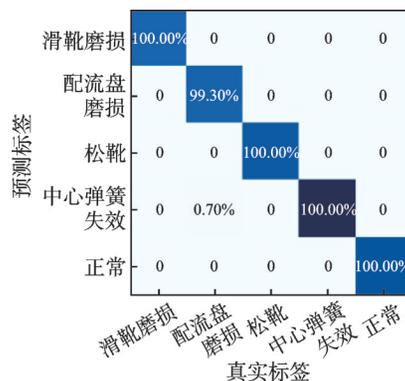


图 6 15 MPa 时的识别结果

Fig.6 Identification result at 15 MPa

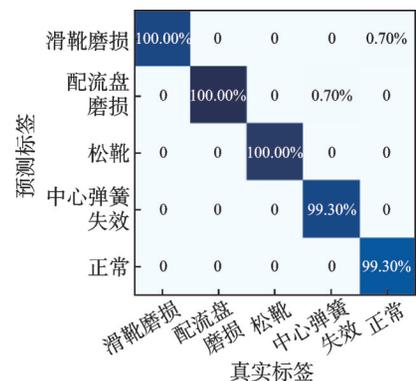


图 7 混合负载识别结果

Fig.7 Identification result at mixed load

4.3 模型对比实验

为了验证 GCN 提取特征对于斜盘式柱塞泵故障诊断的敏感程度,笔者使用 1DCNN 和极限学习机(extreme learning machine, 简称 ELM)与其进行对比。

Ince 等^[12]提出 1D-CNN 模型,其相对于 2 维卷积^[13-15],计算复杂度更低,训练时间更短,计算成本更小。在 1D CNN 中,卷积核沿 1 个方向移动,主要用于时间序列数据。本研究的 1DCNN 模型包含一维卷积层、激活函数、Dropout 层以及全连接层。

ELM^[16]方法仅确定隐含层神经元的个数,神经网络就有唯一的最优解。为了防止隐含层神经元的个数对识别结果造成影响,笔者使用不同样本数量的准确率对该模型进行测试,选用 ELM 隐含层神经元的个数为 300。3 种模型的故障状态识别率对比如图 8 所示。

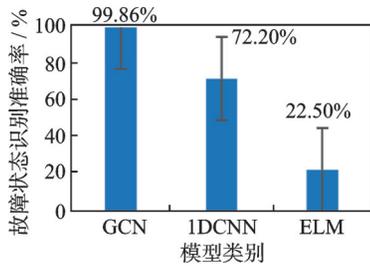


图 8 3 种模型的故障状态识别率对比

Fig.8 Comparison of fault state recognition rates of the three models

4.4 模型可视化

图卷积神经网络在故障诊断中的效果得到了验证,但是其学习过程难以表达。为了直观地了解原始信号的特征提取过程,当测试样本为 720 时,使用 T 分布随机近邻嵌入(T-stochastic neighbor embedding, 简称 T-SNE)降维方法对本研究模型提取的特征进行降维与可视化。提取特征的 T-SNE 可视化如图 9 所示。

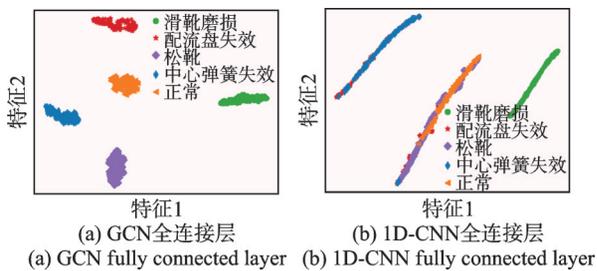
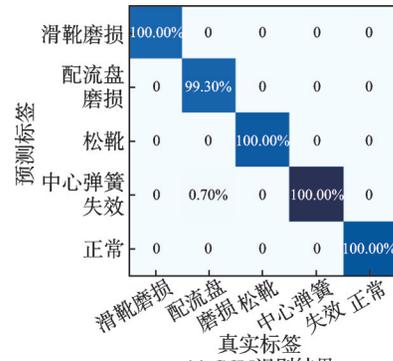


图 9 提取特征的 T-SNE 可视化

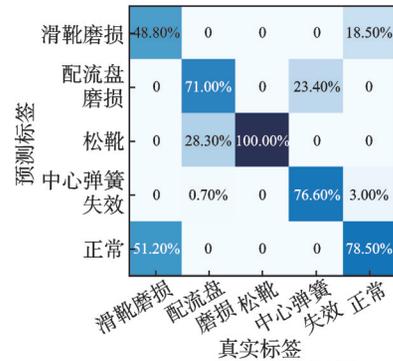
Fig.9 T-SNE visualization of extracted features

模型诊断结果混淆矩阵如图 10 所示。可以看出,与 1D-CNN 相比,GCN 可以更好地将相同故障状态数据聚在一起,不同故障状态的数据具有较好的可分性和较高的识别精度。这也验证了 GCN 能够在原始时域内自适应提取振动信号的有效特征,以识别柱塞泵的各种故障状态。



(a) GCN 识别结果

(a) GCN identification results



(b) 1D-CNN 识别结果

(b) 1D-CNN identification results

图 10 模型诊断结果混淆矩阵

Fig.10 Model diagnostic results confusion matrix

5 结论

1) 使用 3 种将原始信号转换为图结构数据的方法,通过实验数据集测试,确定了一种最优的图数据构造方法,即 K 最近邻法。K 最近邻法构图可以将柱塞泵各种故障状态的原始信号之间的空间特征表示出来,提高了模型的故障状态识别率。

2) GCN 可以自适应提取柱塞泵原始振动信号的特征以及信号彼此之间的空间特征。在用一种工况下的数据训练模型时,分别用另一种工况下的数据和 2 种工况下的混合数据进行测试时,本研究模型准确率均在 99% 以上,表明该模型具有很强的鲁棒性。

3) 在训练样本数量以及训练迭代次数相同的条件下,GCN 模型的识别准确率达到 99% 以上,比 1D-CNN 高大约 28%;与传统模型 ELM 相比,比 ELM 高大约 77%。可以看出,基于 GCN 模型的故

障诊断方法可以很好地将柱塞泵各种故障状态识别出来。

4) 在后续的研究中,将分析柱塞泵复合故障状态振动信号,并结合故障解耦机理,在考虑不同复合故障状态之间空间特征的情况下,训练出复合故障诊断模型,以实现复合故障进行诊断的目的。

参 考 文 献

- [1] TANG S N, ZHU Y, YUAN S Q, et al. Intelligent diagnosis towards hydraulic axial piston pump using a novel integrated CNN model [J]. *Sensors*, 2020, 20(24): 7152.
- [2] KUMAR S, BERGADA J M, WATTON J. Axial piston pump grooved slipper analysis by CFD simulation of three-dimensional NVS equation in cylindrical coordinates [J]. *Computers & Fluids*, 2009, 38(3): 648-663.
- [3] 高浩寒, 潮群, 徐孜, 等. 小样本下基于孪生神经网络的柱塞泵故障诊断[J]. *北京航空航天大学学报*, 2023, 49(1): 155-164.
GAO Haohan, CHAO Qun, XU Zi, et al. Piston pump fault diagnosis based on siamese neural network with small samples [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2023, 49(1): 155-164. (in Chinese)
- [4] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [5] 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): 1345-1358.
REN Hao, QU Jianfeng, CHAI Yi, et al. Deep learning for fault diagnosis: the state of the art and challenge [J]. *Control and Decision*, 2017, 32(8): 1345-1358. (in Chinese)
- [6] 魏晓良, 潮群, 陶建峰, 等. 基于LSTM和CNN的高速柱塞泵故障诊断[J]. *航空学报*, 2021, 42(3): 429-439.
WEI Xiaoliang, CHAO Qun, TAO Jianfeng, et al. Cavitation fault diagnosis method for high-speed plunger pumps based on LSTM and CNN[J]. *Acta Aeronautica ET Astronautica Sinica*, 2021, 42(3): 429-439. (in Chinese)
- [7] SUN S W, ZHANG S, JIANG W L, et al. Study on the health condition monitoring method of hydraulic pump based on convolutional neural network [C]//2020 12th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA). Phuket: IEEE, 2020: 149-153.
- [8] ZHOU J, CUI G Q, HU S D, et al. Graph neural networks: a review of methods and applications [J]. *AI Open*, 2020, 1: 57-81.
- [9] SHUMAN D I, NARANG S K, FROSSARD P, et al. The emerging field of signal processing on graphs: extending high-dimensional data analysis to networks and other irregular domains [J]. *IEEE Signal Processing Magazine*, 2013, 30(3): 83-98.
- [10] DEFFERRARD M, BRESSON X, VANDERGRHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering [C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2016: 3844-3852.
- [11] LI T F, ZHOU Z, LI S N, et al. The emerging graph neural networks for intelligent fault diagnostics and prognostics: a guideline and a benchmark study [J]. *Mechanical Systems and Signal Processing*, 2022, 168: 108653.
- [12] INCE T, KIRANYAZ S, EREN L, et al. Real-Time motor fault detection by 1-D convolutional neural networks [J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(11): 7067-7075.
- [13] KIRANYAZ S, INCE T, HAMILA R, et al. Convolutional neural networks for patient-specific ECG classification [C]//2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Milan: IEEE, 2015: 2608-2611.
- [14] KIRANYAZ S, INCE T, GABBOUJ M. Personalized monitoring and advance warning system for cardiac arrhythmias [J]. *Scientific Reports*, 2017, 7(1): 9270.
- [15] ABDELJABER O, AVCI O, KIRANYAZ S, et al. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks [J]. *Journal of Sound and Vibration*, 2017, 388: 154-170.
- [16] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks [C]//2004 IEEE International Joint Conference on Neural Networks. Budapest: IEEE, 2004: 985-990.



第一作者简介:袁科研,男,1997年6月生,硕士生。主要研究方向为轴向柱塞泵故障诊断。

E-mail:925542063@qq.com

通信作者简介:兰媛,女,1982年10月生,博士、副教授。主要研究方向为液压系统智能故障诊断、计算机视觉。

E-mail:lanyuan@tyut.edu.cn