

基于 GST-MSSTAN 的压缩机故障诊断*

刘 涛¹, 夏泽洲¹, 邬再新¹, 朱 翔²

(1. 兰州理工大学机电工程学院 兰州, 730500)

(2. 兰州理工大学电气工程与信息工程学院 兰州, 730500)

摘要 针对压缩机故障信号微弱、提取特征信息较少、无法挖掘细微特征等问题,提出一种基于广义 S 变换 (generalized S transform, 简称 GST) 和多尺度空间变换注意力网络 (multi-scale spatial transformer attention network, 简称 MSSTAN) 的故障诊断方法。首先,使用 GST 对原始信号进行预处理,将故障信号转化为二维时频图;其次,通过设置膨胀率为 1、2、5 的 3 层空洞卷积模块提取更全面的深层次故障特征信息,并利用 MSSTAN 对提取的特征进行自适应学习,聚焦重要特征信息;最后,通过全连接层输出故障识别分类结果。针对某往复式压缩机的故障诊断实验结果表明,基于 GST-MSSTAN 的故障诊断模型能够有效地提取微弱特征,在训练集上的识别准确率达到 98.14%,测试集上的准确率达到 95.51%,在不同噪声环境下的测试集数据验证了该模型的鲁棒性。

关键词 压缩机;广义 S 变换;多尺度空间变换注意力网络;故障诊断

中图分类号 TH45

0 引 言

压缩机作为一种能量转换设备,广泛应用于冶金高炉、催化裂化、压缩空气储能、制冷和远程气体输送等领域,其运行状态直接影响设备的全生命周期。因此,压缩机工作的故障诊断对优化维修资源和降低维护成本至关重要。

目前,压缩机故障诊断主要采用基于信号处理的方法。赵海洋等^[1]针对往复式压缩机的故障诊断,通过改进局部均值分解的有理 Hermite 插值法,提高了强非平稳振动信号的适应性。张明等^[2]利用多源信号融合技术解决了单一信号源故障诊断精度低的问题。刘涛等^[3]基于粒子群优化和支持向量回归算法,将多个信息熵融合为一个评价指标,用于涡旋压缩机的故障诊断。然而,这些方法通常依赖于专业知识,且通用性较低。

随着深度学习技术的迅速发展,许多学者将其应用于故障诊断领域,取得了显著成果^[4-8]。康伟等^[9]提出了一种结合联合平方包络谱和最小熵解卷积的方法,用于高噪声条件下滚动轴承的故障特征提取。樊家伟等^[10]提出了一种基于长短时

记忆神经网络和故障特征增强的行星齿轮箱故障智能诊断方法。向玲等^[11-12]建立了卷积神经网络与长短期记忆网络相结合的风电机组异常状态预测模型。汤宝平等^[13]提出了多共振分量融合卷积神经网络的行星齿轮箱故障诊断方法,增强了对振动信号的故障信息辨识能力。在压缩机故障诊断方面,马海辉等^[14]使用卷积神经网络进行自适应特征提取,实现了往复式压缩机端到端的诊断模式,但该方法在数据特征挖掘方面仍存在不足,提取的特征信息较少,无法充分挖掘信号中的细微特征。

针对压缩机故障诊断中存在的问题,笔者提出一种基于 GST-MSSTAN 的压缩机故障诊断方法。首先,使用 GST 对原始信号进行预处理,以挖掘微弱故障特征;其次,采用堆叠空洞卷积扩大感受野,增强特征提取的深度和广度;然后,利用 MSSTAN 对提取的特征进行自适应学习,并赋予不同权重,使得网络能够关注更加重要的特征信息;最后,通过全连接层输出故障识别分类结果。

* 国家自然科学基金资助项目 (52265034)

收稿日期:2024-06-12;修回日期:2024-11-06

1 相关算法与理论

1.1 卷积神经网络

卷积神经网络(convolutional neural networks, 简称CNN)是一种深度学习算法,具有局部连接和权值共享等特点,其结构包括卷积层、池化层、激活函数和全连接层。卷积层通过卷积核在特征图上的滑动实现权值共享;池化层通过降采样(如最大池化和平均池化)来减少计算量和参数量;激活函数(如ReLU、Sigmoid、Tanh等)用于学习和表达非线性特征;全连接层将特征组合起来并进行分类。

1.2 广义S变换

S变换在保留了相位信息的同时也提供了可变的信号分解尺度,非常适用于非平稳信号的处理。连续时变信号 $x(t)$ 的S变换的数学表达式为

$$S_{(\tau,f)}=\int_{-\infty}^{\infty}x(t)\frac{|f|}{\sqrt{2\pi}}e^{-\frac{(\tau-t)^2f^2}{2}}e^{-j2\pi ft}dt\quad (1)$$

其中: τ 为时移参数; f 为信号的频率; $\frac{1}{\sqrt{2\pi}\sigma}e^{-\frac{(\tau-t)^2}{2\sigma^2}}$

为高斯窗函数。

虽然S变换具有良好的时频特性,但因高斯窗函数的标准差不变,使其在处理不同频段信号时存在局限^[15-16]。研究人员引入了调节因子 λ 和 ρ 来控制窗口大小,改善时频能量聚集特性,得到了广义S变换。其表达式为

$$GST_{(\tau,f)}=\int_{-\infty}^{\infty}x(t)\frac{\lambda|f|^{\rho}}{\sqrt{2\pi}}e^{-\frac{\lambda^2(\tau-t)^2f^{2\rho}}{2}}e^{-j2\pi ft}dt\quad (2)$$

其中: λ 和 ρ 为调节因子($\lambda>0,0<\rho\leq 1$),当 $\lambda=1,\rho=1$ 时,GST为标准S变换。

GST的逆变换式为

$$x(t)=\int_{-\infty}^{\infty}\left[\int_{-\infty}^{\infty}GST_{(\tau,f)}d\tau\right]e^{j2\pi ft}df\quad (3)$$

2 故障诊断网络模型结构设计

为了在故障信号微弱、有用信息提取较少的情况下提高对压缩机故障的诊断精度,笔者提出了一种基于GST-MSSTAN的压缩机故障诊断模型,如图1所示。该模型主要包括4个模块:数据预处理模块、特征提取模块、特征学习模块和特征分类模块。故障诊断模型结构参数见表1。




图1 故障诊断模型

Fig.1 Fault diagnosis model

表1 故障诊断模型结构参数

Tab.1 Structure parameters of fault diagnosis model

网络层	卷积核大小/步长	输出大小
输入层	—	3×32×32
堆叠空洞卷积	3×3/1	64×32×32
最大池化	1×1/2	64×16×16
残差连接	3×3/5×5/7×7/1	128×16×16
平均池化	—	128×1×1
全连接层	—	8×1×1

2.1 堆叠空洞卷积

在特征提取阶段,使用特征金字塔结构,通过堆叠空洞卷积来增强特征提取能力。特征金字塔如图2所示。堆叠空洞卷积相比标准卷积,具有更加丰富的特征细节,适合提取微弱特征。整个堆叠空洞卷积的卷积核大小为3,层数设置为3层。第1层膨胀率为1,主要用于捕捉局部信息;第2层膨胀率为2,允许模型捕捉图像更大尺度的全局特征;第3层膨胀率为5,能够捕捉整个物体的结构或者场景的全局特征。这种层次化设计在局部和全局信息之间优化了特征提取的能力。




图2 特征金字塔

Fig.2 Feature pyramid

等效卷积核大小的计算公式为

$$k' = k + (k - 1)(r - 1) \quad (4)$$

其中: k 为卷积核大小; k' 为空洞卷积的等效卷积核大小; r 为膨胀率。

膨胀率选取条件公式为

$$M_i = [M_{i+1} - 2r_i, 2r_i - M_{i+1}, r_i] \quad (5)$$

其中: M_i 为第 i 层2个非零元素之间的最大距离; r_i 为第 i 层的膨胀率。

当满足 $M_2 \leq k$,即第2层的2个非零元素之间的最大距离小于或等于该层卷积核大小时,膨胀率选取合适。

2.2 多尺度空间变换注意力网络

特征学习层以残差连接为基本框架,将MS-STAN结构嵌入其中。残差连接如图3所示。




图3 残差连接

Fig.3 Residual connection

MSSTAN结构引入空间变换注意力模块,使网络能够动态关注输入特征空间的不同区域,可更好地把握细节特征,提高特征学习的准确度。MSSTAN结构如图4所示,主要包括分叉、融合及选择3部分。




图4 MSSTAN结构

Fig.4 MSSTAN schematic

分叉:通过3个不同大小的卷积核对输入特征图进行卷积,以学习不同尺度的特征信息,然后利用逐元素相加将这些特征图融合成一个新的特征图 U ,其数学表达式为

$$U = U_1 + U_2 + U_3 \quad (6)$$

其中: U_1 、 U_2 、 U_3 为3个卷积操作后对应的3个特征图。

融合:将得到的特征图 U 输入到空间变换注意力模块中并学习其空间特性,该操作包括定位网络、网络生成器和采样器等部分。首先,计算输入特征图不同空间位置的权重参数,这些权重信息反映了特征图不同空间位置的重要性和受关注度;其次,根据计算得到的注意力权重对输入特征图进行仿射变换,使网络能够动态调整特征图的不同区域;最后,将经过仿射变换的特征图与采样器收集到的采样集合进行融合,得到输出特征图 U' ,再经过批归一化(batch normalization,简称BN)、ReLU激活函数处理,最后由Softmax层进行分类。

定位网络的数学表达式为

$$\theta = f_{\text{loc}}(U) \quad (7)$$

其中: θ 为变换参数; $U \in \mathbb{R}^{H \times W \times C}$, H 、 W 、 C 分别为特征图的高度、宽度和通道数; $f_{\text{loc}}()$ 为定位网络函数,用于计算变换参数 θ 。

网络生成器的数学表达式为

$$\begin{pmatrix} x'_i \\ y'_i \end{pmatrix} = T_\theta(G_i) = A_\theta \begin{pmatrix} x'_i \\ y'_i \end{pmatrix} \quad (8)$$

$$A_\theta = \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \end{bmatrix} \quad (9)$$

其中: $T_\theta(G_i)$ 为仿射变换函数,假设是一个二维仿射变换; A_θ 为仿射矩阵; (x'_i, y'_i) 为输出特征图上某个位置; (x_i^s, y_i^s) 为根据变换参数 θ 映射到输入特征图上的某个位置; $-1 \leq x'_i, y'_i \leq 1, -1 \leq x_i^s, y_i^s \leq 1$ 。

采样器的数学表达式为

$$U_i^c = \sum_n \sum_m U_{nm}^c k(x_i^s - m; \phi_x) k(y_i^s - n; \phi_y) \quad (10)$$

其中: $i \in [1 \ 2 \ \cdots \ H'W']$; $c \in [1 \ 2 \ \cdots \ C]$; ϕ_x, ϕ_y 为采样内核 $k()$ 的参数, 用来定义图像的插值 (如双线性、整数); U_{nm}^c 为通道数是 C 的输入特征图上坐标为 (n, m) 的值; U_i^c 为通道数是 C 的输出特征图上坐标为 (x_i', y_i') 的值。

$$Z = f_{\text{Relu}}(\delta(U')) \tag{11}$$

其中: $f_{\text{Relu}}()$ 为 ReLU 激活函数; δ 为 BN 处理; Z 为经过 BN 处理和 ReLU 激活函数后得到特征图; U' 为经过 STA 模块处理的特征图。

选择: 特征图 Z 经 Softmax 层处理成 3 个权重系数 a_i, b_i, c_i , 相应的数学表达式为

$$a_i = \frac{e^{A_i Z}}{e^{A_i Z} + e^{B_i Z} + e^{C_i Z}} \tag{12}$$

$$b_i = \frac{e^{B_i Z}}{e^{A_i Z} + e^{B_i Z} + e^{C_i Z}} \tag{13}$$

$$c_i = \frac{e^{C_i Z}}{e^{A_i Z} + e^{B_i Z} + e^{C_i Z}} \tag{14}$$

$$a_i + b_i + c_i = 1 \tag{15}$$

$$V = a_i U_1 + b_i U_2 + c_i U_3 \tag{16}$$

其中: a_i, b_i, c_i 分别为 U_1, U_2, U_3 的软注意力向量权重; $e^{A_i Z}$ 为第 i 个卷积核的权重响应指数; A_i, B_i, C_i 分别为线性变换矩阵 A, B, C 的第 i 行; V 为最后得到的输出特征图。

3 GST-MSSTAN 故障诊断模型

3.1 数据来源

本研究使用的数据来源于某单级往复式空气压缩机。实验设备及仪器如图 5 所示。



图 5 实验设备及仪器

Fig.5 Experimental equipment and instruments

实验中, 通过故障植入的方式设置了以下 8 种故障类型: 健康状态、轴承间隙、飞轮不平衡、进气阀阀片断裂、排气阀阀片断裂、止回阀密封不良、活塞环磨损和皮带轮松动。麦克风被布置在距离压缩机 1.5 cm 处以收集声音信号。数据采集使用 NI 9234 数据采集卡, 采样率为 50 kHz, 采样时间为 5 s。通过 NI 9172 USB 接口和 LabVIEW 接口将信号存储到计算机中。故障类型及样本划分见表 2。

表 2 故障类型及样本划分

Tab.2 Fault types and sample division

标签	故障类型	训练集个数	测试集个数
0	健康状态	1 800	450
1	轴承间隙	1 800	450
2	飞轮不平衡	1 800	450
3	进气阀阀片断裂	1 800	450
4	排气阀阀片断裂	1 800	450
5	止回阀密封不良	1 800	450
6	活塞环磨损	1 800	450
7	皮带轮松动	1 800	450

3.2 数据预处理

本研究分别采用短时傅里叶变换、连续小波变换、Winger-Ville 分布和 GST 这 4 种信号处理方法对数据进行时频分析。以轴承故障信号为例, 不同信号处理方法的时频图如图 6 所示。其中: 采样时间为 0.4 s; 最大频率为 2.5 kHz; 彩条数值表示该时间和该频率下幅度的强弱。




图 6 不同信号处理方法的时频图

Fig.6 The time-frequency diagram of different signal processing methods

由图 6 可以看出, 包含时频特征信息的频率范围为 0~500 Hz。GST 提取的时频特征信息更加丰富, 这有助于故障诊断模型更准确地把握和学习, 从而提高诊断准确率。将上述 4 种时频图分别压缩成 32×32 大小的图像, 并存储为样本集。

3.3 实验验证

本研究提出的故障诊断模型基于 Windows10

操作系统和Pytorch框架搭载,CPU为Intel Core i5-12600kf。训练中采用交叉熵损失函数对真实值与预测值进行衡量,并使用Adam优化算法自动更新网络参数。模型训练的迭代次数设置为120,学习率为0.01,批处理大小为32。

损失值曲线和准确率曲线如图7所示。由图可知:经过40轮迭代后,本模型在训练集上的表现趋于稳定;经过65轮迭代后,在测试集上的表现趋于稳定,表明模型能够有效地识别测试集中的样本。在完成120轮迭代训练后,本模型在训练集上的准确率达到98.14%,训练集的损失值稳定在 5.17×10^{-5} 左右;测试集上的准确率达到95.51%,测试集的损失值稳定在 9.55×10^{-5} 左右。




图7 损失值曲线和准确率曲线

Fig.7 Loss and accuracy curve

混淆矩阵如图8所示。其中,左对角线上的数值表示模型准确识别的样本数。由图可知,本模型对健康状态的识别完全准确,对其余几种故障类型的识别准确率保持在95%左右。




图8 混淆矩阵

Fig.8 Confusion matrix

在模型训练过程中,随着网络层数的增加,模型逐步学习到更多特征信息,并在每一层对原始信号特征进行逐步分解和分类,最终输出特征分类图。经过T-SNE可视化后的分布图如图9所示,为GST-MSSTAN故障诊断模型在4个不同阶段的特征分类图。原始信号在空间中是杂乱无序的,经过

特征提取层和特征学习层之后,健康状态的特征信息被准确分类,表明本模型能够有效区分故障信号与健康信号。经过特征分类层之后,所有特征信息呈现出较强的聚类效果,表明本模型能够很好地将不可分的特征映射到非线性可分空间。




图9 经过T-SNE可视化后的分布图

Fig.9 Distribution map after T-SNE visualization

3.4 不同时频处理方法对比

为更加准确地评估GST时频处理方法的优越性,在保证其他条件不变的情况下,仅改变数据预处理手段,将其余3种时频处理方法与本研究所提方法进行对比。不同时频处理方法下的损失值和准确率曲线如图10所示。由图可见,GST时频处理方法在训练集和测试集上的表现都优于其他3种方法。




图10 不同时频处理方法下的损失值和准确率曲线

Fig.10 The loss and accuracy curve of different time-frequency processing methods

其在训练集上收敛速度更快,且准确率更高;在测试集上整体波动较小,且损失值更低。这表明 GST 作为数据预处理手段能够更有效地分辨和提取微弱特征。不同时频处理方法下的损失值和准确率见表 3。

表 3 不同时频处理方法下的损失值和准确率

Tab.3 The loss and accuracy of different time-frequency processing methods

处理方法	训练集准确率/%	训练集损失值	测试集准确率/%	测试集损失值
GST	98.14	5.17×10^{-5}	95.51	9.55×10^{-5}
连续小波变换	96.72	9.31×10^{-5}	93.37	2.04×10^{-4}
短时傅里叶变换	96.46	9.33×10^{-5}	93.61	1.12×10^{-4}
Winger-Ville 分布	89.77	2.57×10^{-4}	85.39	4.06×10^{-4}

3.5 抗噪能力分析

信噪比(signal to noise ratio,简称 SNR)是衡量模型抗噪能力的一种标准。较低的信噪比表示噪声成分占主导,模型学习到的特征中包含大量噪声;较高的信噪比表示信号成分占主导,模型能够学习到更多有效的特征信息。信噪比的计算式为

$$SNR = 10\log \frac{P_{\text{signal}}}{P_{\text{noise}}} \tag{17}$$

其中: P_{signal} 为信号功率; P_{noise} 为噪声功率。

为了更好地评估所提模型的抗噪能力,本研究基于不同信噪比,分别使用 GST-MSSTAN、ResNet-18、DenseNet-121、MobileNet-V2 和 Xception 这 5 种网络模型进行训练,每种模型均训练 10 次,并将最终结果取平均值。5 种模型在不同信噪比下的准确率对比如图 11 所示。




图 11 5 种模型在不同信噪比下的准确率对比
Fig.11 The accuracy comparison of five models under different SNR

由图 11 可知,当 SNR 较大时,GST-MSSTAN 模型的识别准确率略高于 ResNet-18 模型,且明显优于其他 3 种模型;当 SNR 较小时,GST-MSSTAN 模型显著高于其他 4 种模型。这表明 GST-MSSTAN 故障诊断模型在噪声环境中的识别准确率明显优于其他几种智能故障诊断模型,显示出较强的抗噪能力。

4 结 论

- 1) 采用 GST 作为时频处理方法,能够有效提取压缩机原始信号中的细微特征,丰富特征信息,从而提高模型的识别准确率。
- 2) 特征提取层采用堆叠空洞卷积,可以增大感受野,获取更多的特征信息。在此基础上,设计了一种 MSSTAN 结构用于特征学习,通过注意力机制捕捉重要特征信息,提高了模型的特征提取和学习能力。
- 3) 往复式压缩机实验结果表明,GST-MSSTAN 故障诊断模型在训练集和测试集上的识别准确率分别达到了 98.14% 和 95.51%,在不同噪声环境下,GST-MSSTAN 故障诊断模型表现出更好的鲁棒性。

参 考 文 献

[1] 赵海洋,徐敏强,王金东.有理 Hermite 插值局部均值分解方法及其往复压缩机故障诊断应用[J].机械工程学报,2015,51(1):83-89.
ZHAO Haiyang, XU Minqiang, WANG Jindong. Local mean decomposition based on rational hermite interpolation and its application for fault diagnosis of reciprocating compressor[J]. Journal of Mechanical Engineering, 2015, 51(1): 83-89.(in Chinese)

[2] 张明,江志农.基于多源信息融合的往复压缩机故障诊断方法[J].机械工程学报,2017,53(23):46-52.
ZHANG Ming, JIANG Zhinong. Reciprocating compressor fault diagnosis technology based on multi-source information fusion[J]. Journal of Mechanical Engineering, 2017, 53(23): 46-52.(in Chinese)

[3] 刘涛,梁成玉.信息熵融合的 PSO-SVC 涡旋压缩机故障诊断[J].振动、测试与诊断,2022,42(1):141-147.
LIU Tao, LIANG Chengyu. PSO-SVC fault diagnosis of scroll compressor based on information entropy fusion

- [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(1): 141-147.(in Chinese)
- [4] WANG D F, GUO Y, WU X, et al. Planetary-gearbox fault classification by convolutional neural network and recurrence plot[J]. Applied Sciences, 2020, 10(3): 932.
- [5] HAN Y, TANG B P, DENG L. An enhanced convolutional neural network with enlarged receptive fields for fault diagnosis of planetary gearboxes[J]. Computers in Industry, 2019, 107: 50-58.
- [6] 刘涛,梁成玉. 信息熵融合的PSO-SVC涡旋压缩机故障诊断[J]. 振动、测试与诊断, 2022, 42(1): 141-147.
- LIU Tao, LIANG Chengyu. PSO-SVC fault diagnosis of scroll compressor based on information entropy fusion [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(1): 141-147. (in Chinese)
- [7] 胡爱军,连俭,向玲. 基于ACNN和Bi-LSTM的风电机组故障早期识别[J]. 太阳能学报, 2021, 42(12): 143-149.
- HU Aijun, LIAN Jian, XIANG Ling. Early fault identification of wind turbine based on ACNN and Bi-LSTM [J]. Acta Energeiae Solaris Sinica, 2021, 42(12): 143-149.(in Chinese)
- [8] 刘涛,麻德权. 基于CBAM-CNN的涡旋压缩机故障诊断[J]. 振动、测试与诊断, 2024, 44(5): 900-906.
- LIU Tao, MA Dequan. Fault diagnosis of scroll compressor based on improved CBAM-CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(5): 900-906.
- [9] 康伟,朱永生,闫柯,等. 基于CSES和MED的滚动轴承微弱故障特征提取[J]. 振动、测试与诊断, 2021, 41(4): 660-666.
- KANG Wei, ZHU Yongsheng, YAN Ke, et al. Weak fault extraction of rolling element bearings based on CSES and MED[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(4): 660-666.(in Chinese)
- [10] 樊家伟,郭瑜,伍星,等. 基于LSTM神经网络和故障特征增强的行星齿轮箱故障诊断[J]. 振动与冲击, 2021, 40(20): 271-277.
- FAN Jiawei, GUO Yu, WU Xing, et al. Fault diagnosis of planetary gearboxes based on LSTM neural network and fault feature enhancement[J]. Journal of Vibration and Shock, 2021, 40(20): 271-277.(in Chinese)
- [11] 向玲,王朋鹤,李京蓄. 基于CNN-LSTM的风电机组异常状态检测[J]. 振动与冲击, 2021, 40(22): 11-17.
- XIANG Ling, WANG Penghe, LI Jingxu. Abnormal state detection of wind turbines based on CNN-LSTM [J]. Journal of Vibration and Shock, 2021, 40(22): 11-17.(in Chinese)
- [12] 向玲,苏浩,胡爱军,等. CDBN-IKELM的轴承变工况故障诊断方法[J]. 振动、测试与诊断, 2022, 42(3): 432-438.
- XIANG Ling, SU Hao, HU Aijun, et al. Bearing fault diagnosis based on cdbn ikelm under varying conditions [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(3): 432-438. (in Chinese)
- [13] 汤宝平,熊学嫣,赵明航,等. 多共振分量融合CNN的行星齿轮箱故障诊断[J]. 振动、测试与诊断, 2020, 40(3): 507-512.
- TANG Baoping, XIONG Xueyan, ZHAO Minghang, et al. A multi-resonance component fusion based convolutional neural network for fault diagnosis of planetary gearboxes[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(3): 507-512.(in Chinese)
- [14] 马海辉,余小玲,吕倩,等. 一维卷积神经网络在往复式压缩机气阀故障诊断中的应用[J]. 西安交通大学学报, 2022, 56(4): 101-108.
- MA Haihui, YU Xiaoling, LÜ Qian, et al. Application of one-dimensional convolutional neural network in fault diagnosis of reciprocating compressor air valve[J]. Journal of Xi'an Jiaotong University, 2022, 56(4): 101-108.(in Chinese)
- [15] 李巍华,林龙,单外平. 基于广义S变换与双向2DPCA的轴承故障诊断[J]. 振动、测试与诊断, 2015, 35(3): 499-506.
- LI Weihua, LIN Long, SHAN Waiping. Bearing fault diagnosis based on generalized S-transform and two-directional 2DPCA [J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(3): 499-506.(in Chinese)
- [16] 于洋,马军,王晓东,等. 基于GST与改进CNN的滚动轴承智能故障诊断[J]. 铁道科学与工程学报, 2022, 19(7): 2050-2060.
- YU Yang, MA Jun, WANG Xiaodong, et al. Intelligent fault diagnosis of rolling bearings based on GST and improved CNN[J]. Journal of Railway Science and Engineering, 2022, 19(7): 2050-2060.(in Chinese)



第一作者简介:刘涛,女,1971年7月生,博士、教授、博士生导师。主要研究方向为机械设计理论与方法、复杂型面精密制造、机械测试技术与信号处理。
E-mail:liutao1971@lut.edu.cn