

电连接器连接状态的双通道特征动态融合检测*

李仔真¹, 滕浩然², 姜军强^{1,3}, 崔玉国¹, 魏燕定³, 李国平¹

(1. 宁波大学宁波市微纳运动及智能控制重点实验室 宁波, 315211)

(2. 杭州航天电子技术有限公司 杭州, 310000)

(3. 浙江大学浙江省先进制造技术重点研究实验室 杭州, 310000)

摘要 针对航空电连接器在复杂工况下连接状态声学检测中存在的单一特征表征不足、融合不充分导致的识别精度与泛化性能受限的问题,提出了一种基于双通道特征动态融合网络(dual-channel feature dynamic fusion network, 简称 DCFDFN)的连接状态检测方法。首先,将敲击声信号转换为连续小波变换(continuous wavelet transform, 简称 CWT)时频图和语谱图两类特征图谱;其次,采用多尺度特征提取残差模块 Res2Net 对两类图谱进行多尺度特征提取;然后,引入基于多尺度通道注意力模块(multi-scale channel attention module, 简称 MS-CAM)的动态融合机制对双通道特征进行自适应加权,并结合附加角度边距损失函数增强相似连接状态的类间可分性,实现连接状态识别;最后,在固定敲击、随机敲击强度及加噪条件下进行验证。结果表明:所提方法在固定敲击多工况测试中准确率达到 99.33%,在随机敲击强度的非训练分布数据上准确率为 90.17%,且在信噪比 $SNR \geq 0$ dB 时准确率保持在 92% 以上。所提出方法实现了敲击声特征的多尺度建模与自适应融合,可提高航空电连接器连接状态检测的精度、鲁棒性与泛化能力。

关键词 航空电连接器;连接状态检测;双通道特征;特征动态融合机制;深度学习;声纹识别

中图分类号 TH17;TP183

0 引言

航空电连接器作为连接与分离电气终端的重要元件,在飞机机载系统中承担着电能输送、信号传递等关键作用。然而,在复杂的飞行任务与恶劣的服役环境中,电连接器易发生连接松动甚至脱落等隐患,进而影响机载系统的安全运行^[1]。因此,对航空电连接器开展连接状态检测具有重要的工程意义。目前,机载系统中的电连接器多采用人工定期巡检方法,但由于电连接器具有数量多、分布广以及工作环境复杂等特点,人工巡检存在效率低、劳动强度大等问题,且对电连接器松动情况缺乏精确、量化的检测手段,因此导致隐患难以及时发现,存在较大的安全风险。

航空电连接器与螺栓连接同属螺纹连接形式,尽管两者结构存在差异,但其松动演化过程与机理具有很强的相似性。因此,螺栓松动检测的研究成果可为航空电连接器连接状态检测提供重要参考。现有的螺栓连接状态监测方法主要包括阻抗法、机

器视觉方法、基于振动的方法以及超声波法^[2]。Wang 等^[3]使用 2 种压电陶瓷并结合多频电磁干扰技术检测螺栓的松动状态,在配备 12 个铅钛酸铅的四螺栓法兰结构中,有效识别了螺栓的松动状态。Tong 等^[4]建立了螺栓连接的 Lamb 波传播模型,实现了双螺栓连接密封性的成像与识别。Zhang 等^[5]利用剪切水平波检测多螺栓接头的松动程度。然而,超声波法和阻抗法需要波形发生器和功率放大器等大型激励设备,且安装过程复杂,极大限制了其应用场景。Ramana 等^[6]提出了一种基于 Viola-Jones 算法和支持向量机(support vector machine, 简称 SVM)的全自动螺栓松动检测方法。文献^[7]提出一种基于 Canny 边缘检测技术的螺栓连接松动检测算法,通过比较螺栓松动前后的边线角度来识别松动状态。然而,目视方法仅适用于快速判断螺栓的明显松动,无法量化松动程度,尤其是早期松动^[8]。Kong 等^[9]提取功率谱作为敲击声信号特征,并使用基于决策树(decision tree, 简称 DT)的机器学习模型来识别螺栓松动程度。Yuan 等^[10]提出

* 国家自然科学基金资助项目(52375103);宁波大学“力学+”交叉学科领军人才创新基金资助项目(LJ2024005);宁波市青年科技创新领军人才资助项目(2025QL064)

收稿日期:2025-11-07;修回日期:2026-01-07

一种基于内在多尺度熵的螺栓松动监测方法。Zhang等^[11]提出一种基于梅尔频率倒谱系数(Mel frequency cepstral coefficient, 简称MFCC)与SVM的音频分类方法,用于螺栓松动检测。Yuan等^[12]将敲击声信号的MFCC特征输入卷积神经网络(convolution neural network, 简称CNN),实现了螺栓松动的实时监测。总体而言,声学检测方法与本研究对象具有较好的适配性,但现有研究多依赖单一特征表征连接状态信息、且多特征融合以静态融合为主,在复杂工况下存在信息表征不足的问题,从而导致识别精度下降。因此,有必要构建面向复杂工况的多特征融合表征与识别方法。

笔者提出一种基于敲击声信号的航空电连接器连接状态检测方法——双通道动态特征融合深度网络。首先,将不同连接状态下敲击航空电连接器产生的敲击声信号,转换为连续小波变换时频图与语谱图,并以此作为模型的输入;其次,通过特征提取模块中的2个Res2Net^[13]集成块,对输入图谱进行多尺度声纹特征提取;最后,结合双通道动态特征融合(dual-channel dynamic feature fusion, 简称DCDFF)机制,完成特征的自适应融合,从而实现对航空电连接器连接状态的识别。

1 数据预处理

在航空电连接器连接状态监测中,受复杂背景噪声及其他设备运行声音的影响,被监测设备的故障信息易淹没于噪声之中,从而增加了后续特征提取的难度。为突出噪声中目标成分的特征信息,选择适当的信号处理方法至关重要。

在复杂工况下,单一时频特征难以充分表征敲击声音数据的特征,而过多的特征输入又会导致模型过于复杂。相比之下,双通道时频特征能够在全面表达声音信息的同时,保持模型的简洁性。因此,笔者选取能够强调信号局部特性的CWT时频图和突出整体动态变化的语谱图作为输入时频特征。

CWT是一种用于在时域和频域上同时分析信号的方法,通过使用不同尺度和位置的小波函数对信号进行变换,以获取信号的局部特性^[14]。对于原始信号 $f(t)$,需要先进行预处理,再进行CWT。预处理步骤包括音频截取、声道转换和预加重等。图1为数据预处理流程。CWT时频特征的提取流程对应图1中的数据预处理模块1,其核心步骤可表示为

$$H(f) = 1 - \mu f(t)^{-1} \quad (1)$$




图1 数据预处理流程

Fig.1 Data preprocessing process

$$\phi_{a,b}(t) = \frac{1}{\sqrt{a}} \phi\left(\frac{t-b}{a}\right) \quad (2)$$

$$\text{CWT}_f(a,b) = \int H(f) \phi_{a,b}(t) dt \quad (3)$$

其中: μ 为预加重系数,通常取0.9~1.0,此处取 $\mu=0.95$ ^[15],以增强高频信息并保证信号稳定性; $H(f)$ 为预加重后的信号; a 和 b 分别为比例因子和移位因子; $\Psi_{a,b}(t)$ 为小波基函数。

考虑敲击声具有明显的瞬态冲击与非平稳特征,笔者在CWT中选用Morlet小波基。该小波基的时频局部化能力较强,且幅值表征稳定,有利于在复杂噪声背景下突出目标瞬态成分。

语谱图是声纹识别和语音信号处理中常用的时频特征之一,其基于短时傅里叶变换(short time fourier transform, 简称STFT)对信号进行分帧分析,可同时表征信号的时间、频率及能量分布信息,为非平稳信号动态特性分析提供直观依据^[16]。语谱图的提取过程同样从预处理开始,包括音频截取、声道转换、预加重、分帧和加窗等步骤。首先,对每一帧加窗后的语音信号进行傅里叶变换;其次,将频谱幅值进行平方处理和对数运算,得到分贝形式的功率谱;最后,映射到给定的时间-频率范围内形成语谱图。整个语谱图提取流程对应图1中的数据预处理模块2,其核心步骤表示为

$$F(k) = \sum_{n=0}^{N-1} x(n) e^{-j2\pi \frac{kn}{N}} \quad (4)$$

$$P(k) = \log\left(|F(k)|^2 + \epsilon\right) \quad (5)$$

其中: $x(n)$ 为信号的短帧; N 为帧长; $F(k)$ 为快速傅里叶变换结果; $P(k)$ 为每帧分贝形式的功率谱; ϵ 为避免零值对数计算的小常数,用于增强动态范围的可视化效果。

为平衡时间与频率分辨率,本研究设置窗宽为

1 200 点、窗移为 480 点,并采用汉宁窗以降低谱泄漏;同时将快速傅里叶变换点数设为 2 048,在保证频率分辨率的同时兼顾计算效率,从而获得更稳定的时频表示。

2 双通道特征动态融合网络

双通道特征动态融合网络模型如图 2 所示,该网络主要由 2 个特征提取模块和双通道特征动态融合机制组成。DCFDFN 模型的结构参数如表 1 所示。其中:特征提取模块用于提取电连接器在不同连接状态下产生的 2 种声纹图谱特征;双通道特征

动态融合机制用于自适应融合这 2 种特征。首先,将由数据预处理得到的时频图谱分别输入 2 个 Res2Net 模块进行多尺度特征提取;其次,利用所提出的双通道动态特征融合机制对 2 种特征进行自适应融合;最后,将融合后的特征作为分类器的输入,实现不同连接状态的识别。

表 1 DCFDFN 模型结构参数

Tab.1 Parameters of DCFDFN model structure		
层名	卷积核/步长,填充	特征层尺寸
输入层	—	224×224×3
卷积层 1	7×7/2,1	112×112×16
最大池化层	3×3/2,1	56×56×16
残差块 1	1×1/1,1→1×1/1,1	56×56×32
残差块 2	1×1/1,1→3×3/1,1→1×1/1,1	56×56×64
残差块 3	1×1/1,1→3×3/1,1→1×1/1,1	56×56×128
残差块 4	1×1/1,1→3×3/1,1→1×1/1,1	56×56×256
特征融合机制	—	56×56×256
全局平均池化层	—	1×1×256
全连接层	—	1×1×32
损失函数	—	1×1×6

残差块中组数为 1,尺度维度为 4。




图 2 双通道特征动态融合网络模型

Fig.2 Dual-channel feature dynamic fusion network model

2.1 多尺度特征提取模块

为增强网络的多尺度特征表达能力与跨尺度信息交互能力,本研究将残差网络(residual network, 简称 ResNet)中的传统残差块替换为 Res2Net 残差模块,并以此作为特征提取模块。Res2Net 残差模块结构如图 3 所示。该特征提取模块由 4 个 Res2Net 残差块串联组成,能够更全面地捕获不同层次细粒度的特征信息。




图 3 Res2Net 残差模块结构

Fig.3 The structure of Res2Net residual block

传统 ResNet 模块通过残差连接将输入特征与输出特征相加,从而缓解梯度消失并提升深层网络的训练效果。然而,其卷积操作仅限于单一尺度,易造成多尺度特征表达不足。Res2Net 残差块在残差结构内进一步引入组内层级连接,将通道特征划分为多个子特征组,并实现跨组信息交互,从而获得更丰富的多尺度表征。具体而言,输入特征图经 1×1 卷积核进行通道变换,被划分为 z 个子特征组 $x_i (i \in \{1, 2, \dots, z\}, \text{这里 } z \text{ 取 } 4)$ 。其中,第 1 个子特征组 x_1 直接作为第 1 个特征组 y_1 的输出,从第 2 个子特征组开始,将当前子特征组 x_i 与前 1 个子特征组输出 y_{i-1} 进行逐元素相加融合,再通过 3×3 的卷积核得到输出 y_i 。该过程可表示为

$$y_i = \begin{cases} x_i & (i=1) \\ C_i(x_i + y_{i-1}) & (1 < i \leq z) \end{cases} \quad (6)$$

其中: x_i 与 y_i 分别为第 i 个子特征组的输入和输出; C_i 表示卷积运算。

通过在模型中集成 Res2Net 集成块,网络能够在较低的额外复杂度下实现跨尺度特征交互与融合,从而提升多尺度声纹特征的表达能力。

2.2 双通道特征动态融合机制

单一时频声纹特征往往难以充分刻画复杂工况下航空电连接器的连接状态差异。将 CWT 时频图与语谱图两路特征进行融合,可在互补信息的基础上形成更全面的表征,从而降低模型对单一特征的依赖并提升泛化能力。为此,笔者基于多尺度通道注意力^[17]提出双通道特征动态融合机制。该机制通过在不同空间池化尺度上生成通道注意力,实现对多尺度特征的自适应加权,进而抑制冗余信息、增强有效特征。

双通道特征动态融合机制如图 4 所示。首先,对 2 个通道特征进行逐元素乘法,以实现初步的交互与信息融合;其次,将得到的特征输入 MS-CAM,通过逐点卷积操作对通道进行融合与调整,同时捕捉全局和局部信息;最后,经 Sigmoid 函数得到 2 个通道的自适应权重,并对原始特征进行加权融合,实现双通道特征的自适应融合。该机制能够在增强不同通道间互补信息利用的同时,有效抑制冗余特征的干扰,从而提升特征表达能力与模型判别性。其推导公式为

$$L(X) = B \left[\text{PWConv}_2 \left(\sigma \left\{ B \left[\text{PWConv}_1(X) \right] \right\} \right) \right] \quad (7)$$




图4 双通道特征动态融合机制

Fig.4 Dual-channel feature dynamic fusion mechanism

$$G(X) = B \left\{ \text{PWConv}_2 \left[\sigma \left(B \left\{ \text{PWConv}_1[g(X)] \right\} \right) \right] \right\} \quad (8)$$

$$M(X) = \sigma[L(X) \oplus G(X)] \quad (9)$$

$$O = M(X \odot Y) \otimes X + [1 - M(X \odot Y)] \otimes Y \quad (10)$$

其中: B 为批归一化处理; σ 为激活函数; g 为全局平均池化处理; PWConv 表示逐点卷积; $G(X)$ 与 $L(X)$ 分别为全局特征处理和局部特征处理; X 和 Y 为待融合特征; O 为融合后特征; $\odot$ 表示逐元素乘法; M 为 MS-CAM 生成的通道权重; $1 - M(X \odot Y)$ 为另一通道权重,用于待融合特征 Y 的加权。

2.3 损失函数

合适的损失函数能有效增强模型对声纹中微小差异的敏感性与区分能力。传统分类任务中常采用 Softmax 交叉熵损失,通过最大化样本对真实类别的预测概率完成训练。然而,该损失函数未对类别间的判别边界施加显式约束,在类别特征高度相似时难以获得足够的可分性,极大制约了声纹识别性能。为提升类间判别能力,笔者采用基于角度边距思想的附加角度边距损失函数^[18]。该损失函数在目标类别角度 θ_{rw} 中引入角度边距 m ,通过缩放因子 h 调整边距影响,从而强化决策边界约束,使相似类别之间获得更大的角度间隔,提高类间区分能力。

附加角度边距损失函数的计算式为

$$A = -\frac{1}{\lambda} \sum_{w=1}^{\lambda} \log \frac{e^{h(\cos(\theta_{rw}+m))}}{e^{h(\cos(\theta_{rw}+m))} + \sum_{q=1, q \neq r_w}^U e^{h \cos \theta_q}} \quad (11)$$

其中： λ 为批次中的样本数量； U 为类别总数； θ_{rw} 为样本 w 与其真实类别中心的夹角； r_w 为样本 w 的真实标签； h 为缩放因子； m 为角度边距。

3 实验

3.1 声纹信号采集系统搭建

笔者选取型号为 Y2-120ZJLM 的航空电连接器作为实验试件,开展敲击声信号采集,以验证所提出方法的有效性与可行性。需要说明的是,尽管不同型号的航空电连接器在敲击声响应机理上具有一定共性,但其结构差异仍可能导致声学特性存在差别。为了系统表征不同紧固程度下连接状态的变化特征,笔者以该型号电连接器的最大允许扭矩 10 N·m 为基准(选取 0~10 N·m 覆盖实际使用工况,并避免接近破坏扭矩造成损伤风险),综合考虑分辨率与可分性(步长过小易受施加误差影响、过大则降低趋势识别能力),采用 2 N·m 的扭矩步长设置 6 种扭矩工况,覆盖从过紧到明显松动的典型状态,以保证实验结果的有效性与可比性。

信号采集系统如图 5 所示。系统主要包括麦克风(Superlux E302)、数字扭矩扳手(BSC09-030BN)、Speedgoat 实时目标机、JZK-10 激振器及 YE5872A 功率放大器等。首先,使用数字扭矩扳手将试件预紧扭矩依次设置为 0、2、4、6、8 和 10 N·m,形成对应的连接状态;其次,PC 端输出驱动电压,经 Speedgoat 实时目标机生成模拟电压,并由功率放大器放大后驱动激振器,对试件施加敲击激励;最后,敲击产生的声响应由麦克风以 48 kHz 采样率进行采集,经数据采集模块转换后传输至 PC 端,实现信号的存储与后续处理。




图 5 信号采集系统

Fig.5 The equipment of the detection system

3.2 数据分析

实验数据在 3 种敲击激励条件下采集。由于敲击过程属于瞬态冲击行为,敲击力难以直接准确测量,故笔者采用激振器驱动电压幅值作为敲击强度的等效表征量。在相同实验装置条件下,该电压幅值可稳定反映敲击强度的相对变化。表 2 为不同连接状态的数据采集方案。其中,敲击强度等级 1、2、3 分别对应驱动电压为 5、6 和 7 V 的敲击激励。对于每一固定敲击强度,在各连接状态下均采集 100 次敲击音频信号。为了保证样本长度一致且完整覆盖声响应,所有音频信号均截取为 0.35 s 的时间序列,并以每段信号的峰值点作为样本起始点。

表 2 不同连接状态的数据采集方案

Tab.2 Data acquisition schemes of different connection statuses

扭矩/(N·m)	敲击强度 1	敲击强度 2	敲击强度 3	总数据
0	100	100	100	300
2	100	100	100	300
4	100	100	100	300
6	100	100	100	300
8	100	100	100	300
10	100	100	100	300

图 6 为各连接状态下的信号时域图。全文中纵坐标幅值为量纲一的量。在敲击强度 2 条件下,各连接状态的时域波形(从左到右、从上到下依次为 0、2、4、6、8 和 10 N·m)表明,敲击声信号均呈现典型的衰减振荡特征。随着预紧扭矩增大,时域信号的峰值幅度整体呈减小趋势。这一现象与已有研究类似^[19],其解释为敲击产生的能量更多地从冲击源传递至麦克风,而不是通过螺纹连接处的摩擦耗散。

如图 7 所示,敲击声信号的功率谱密度(power spectrum density,简称 PSD)主要能量分布在 0~8 kHz 范围内。预紧扭矩为 0 N·m 时的频谱特征与其他 5 种工况相比存在明显差异,表现为主频响应向高频区域偏移。该现象可能是由于在 0 N·m 连接状态下,螺纹连接处的约束不足,使得振动响应更倾向于被敲击的螺纹结构局部主导,因此导致系统参与振动的等效质量相对减小。根据固有频率与等效质量/刚度的关系,等效质量降低将促使固有频率上移,从而导致 0 N·m 工况下的主频分量出现在更高频段。此外,当预紧扭矩大于 0 N·m 时,主要频率响应集中在 460 Hz 附近,不同预紧扭矩下的 PSD 峰值幅值存在一定差异。




图6 各连接状态下的信号时域图

Fig.6 Time-domain diagrams of signals in each connection state




图7 各连接状态下信号功率谱密度

Fig.7 Signal power spectral density in each connection state

不同连接状态的时频图谱如表3所示。可以看出,不同预紧扭矩下敲击声的时频图谱存在明显差别。对于CWT时频图,各工况在敲击瞬间均出现能量突增;随着预紧扭矩增大,能量分布由“短时突发、快速衰减”逐渐转变为“特征频带更清晰、持续时间更长”,部分频带条纹特征更加明显。对于语谱

图,敲击后低频能量占优,但在较小预紧扭矩下,纹理更离散且衰减更快;在较大预紧扭矩下,能量分布更连续、稳定。上述结果表明,预紧扭矩变化会引起敲击声信号的时频结构差异,具有一定可分性,可为连接状态的识别提供依据。

表3 不同连接状态的时频图谱

Tab.3 Time-frequency spectra of different connection states

预紧状态	0	6 N·m	10 N·m
CWT 时频图			
语谱图			

3.3 消融实验

为验证输入特征的有效性,及模型各模块的贡献,对采集的全部敲击声数据进行6组消融实验。具体设置如下:①将CWT时频图、语谱图以及梅尔频谱(Mel spectrogram,简称Mel)分别作为单通道输入,在Res2Net骨干网络上进行识别;②将任意2类图谱进行组合并输入DCFDFN进行对比;③在最佳图谱组合条件下,引入静态融合网络与笔者提出的动态融合机制进行对比。数据划分采用按扭矩工况分层抽样的方式:每种扭矩下50%的样本用于训练、50%用于测试;训练集按8:2的比例进行划分。

消融实验结果如表4所示。可见:单一特征输入时的最高识别准确率为93.67%;采用双通道特征后,准确率均达到96%以上,说明双特征融合能够提供更充分的状态表征。其原因在于,单一时频特征对敲击声的局部或整体信息刻画有限,而双通道输入可利用2类图谱的互补信息,从而提升分类性能。当将CWT时频图与语谱图进行动态融合时,识别准确率最高可达99.33%,表明2类特征具

表4 消融实验结果

Tab.4 Results of the ablation experiment

方法	CWT+ Res2Net	语谱图+ Res2Net	Mel+ Res2Net	Mel-CWT+ DCFDFN	Spectrogram+Mel+ DCFDFN	语谱图-CWT+ 静态特征融合	提出方法
准确率/%	72.33	88.33	93.67	96.33	96.67	98.33	99.33

有较强的互补性,动态融合后的特征能够更全面地反映航空电连接器的连接状态。相比之下,静态融合的准确率为 98.33%,进一步说明所提出的动态融合机制可在一定程度上抑制冗余信息并提升融合效果。

3.4 对比实验

为了验证本研究方法在关键特征提取方面的优越性,将其与其他 3 种典型声纹识别方法在敲击强度等级 1、2、3 下的敲击音频数据上进行对比实验。实验中数据集划分方式与消融实验一致。

不同方法在各敲击强度下的实验结果如图 8 所示。所提出方法在各固定敲击强度采集的声音数据上均接近 100% 的识别准确率,而其他方法在敲击强度 1 下的最高准确率为 95%,在敲击强度 2 下为 96%,在敲击强度 3 下为 96.67%。该结果表明,所提出方法在关键特征提取方面显著优于其他对比方法。因此,所提出的双通道特征动态融合网络能够有效提取与连接状态相关的深层声纹特征,具有更强的特征判别能力和更稳定的连接状态识别性能。




图 8 不同方法在各敲击强度下的实验结果
Fig.8 Experimental results of different methods under various knocking intensities

3.5 泛化性测试实验

为评估模型的泛化能力,训练阶段采用固定敲击强度下采集的全部声信号时频图对模型进行训练;测试阶段则通过随机幅值电压驱动激励,对试件施加随机敲击激励,并将采集到的声信号转换为时频图输入模型进行测试。随机敲击强度下的部分声音信号及对应驱动电压如图 9 所示。其中,图 9(a)~(c)分别为驱动电压在 6.3、8.2 和 3.8 V 下采集的声信号。由于测试阶段的随机敲击强度分布与训练阶段的固定敲击强度分布不同,该测试可用于评估模型在分布外敲击条件下的适应能力与泛化性能。




图 9 随机敲击强度下的部分声音信号及对应驱动电压
Fig.9 Part of the sound signal and the corresponding drive voltage under random knocking intensity

各方法的分类混淆矩阵如图 10 所示。结果表明:提出方法在测试集中的识别准确率达到 90.17%,而 PSD+DT、MFCC+SVM 及 Mel+CNN 等方法的识别准确率分别为 69.5%、75.67% 和 81.33%,其均低于 85%。本研究方法的识别准




图 10 各方法的分类混淆矩阵
Fig.10 Classification confusion matrices of each method

准确率优于其他方法,这主要得益于其能够自适应调整不同声纹特征的网络权值,实现2种特征的动态融合,从而更全面地描述数据,减少模型对特定特征的依赖,提高模型的泛化能力,使其在复杂环境下仍能达到较好的识别效果。

为进一步验证所提模型的泛化能力,选取前述对比实验中在敲击强度等级2条件下训练得到的模型,在其测试集上叠加不同强度的噪声以开展鲁棒性实验。参照相关研究^[20],采用加性高斯白噪声对测试音频进行加噪,分析不同噪声水平下的性能变化。

信噪比(signal-to-noise ratio,简称SNR)的计算公式为

$$\text{SNR} = 10 \log_{10} \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (12)$$

其中: P_{signal} 和 P_{noise} 分别为原始信号功率和噪声功率。

实验通过调整噪声幅值,使叠加后的音频满足目标SNR,并在SNR分别为-6、-3、0、3和6 dB这5种水平下进行测试。

图11为不同信噪比下的识别结果。可见:当 $\text{SNR} \geq 0$ dB时,模型识别准确率保持在92%以上,表现出较好的抗噪稳定性;当SNR降低至-6 dB时,识别性能明显下降。这说明该方法在中等及以上信噪比条件下具有较稳定的识别性能,其有效工作范围约为 $\text{SNR} \geq 0$ dB;在更强噪声干扰($\text{SNR} < 0$ dB)条件下,可结合降噪或数据增强等策略进一步提升其鲁棒性。




图11 不同信噪比下的识别结果

Fig.11 Recognition results under different signal-to-noise ratios

4 结 论

1) 构建了基于敲击声信号的航空电连接器连接状态双通道检测框架。首先,采用双通道并行时频表征,以增强对不同连接状态差异的表征能力;其次,设计由Res2Net残差模块堆叠构成的多尺度特

征提取结构,实现敲击声声纹特征的多尺度建模与细粒度表达;然后,提出基于MS-CAM的双通道特征动态融合机制,对2个声纹特征进行自适应加权融合,以降低工况变化与噪声干扰引起的特征失配影响;最后,引入附加角度边距损失函数以增强类间间隔约束,提高特征判别性并优化决策边界。

2) 通过消融实验、对比实验及泛化性测试对所提出方法进行验证。结果表明:所提出方法在诊断准确率和鲁棒性方面均优于传统方法,验证了其能够有效提取并融合多尺度声纹特征,从而提升复杂工况下连接状态的识别能力。

参 考 文 献

- [1] 陆国丽,王光庆.基于四层分类模型的网络流量分类技术研究综述[J].中国科技论文,2025,20(5):406-417.
LU Guoli, WANG Guangqing. Review on network traffic classification based on a four-layer classification model[J]. China Sciencepaper, 2025, 20(5): 406-417. (in Chinese)
- [2] 韩雷,季宏丽,吴义鹏,等.基于共面卷曲腔体的宽频带消声结构[J].振动、测试与诊断,2025,45(6):1105-1111.
HAN Lei, JI Hongli, WU Yipeng, et al. Wideband silencing structure based on coplanar coiled cavity[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(6): 1105-1111. (in Chinese)
- [3] ZHANG M, TANG Z, YUN C B, et al. Bolt looseness detection using SH guided wave and wave energy transmission[J]. Smart Materials and Structures, 2021, 30(10): 105015.
- [4] TONG T, HUA J D, GAO F, et al. Identification of bolt state in lap joint based on propagation model and imaging methods of Lamb waves[J]. Mechanical Systems and Signal Processing, 2023, 200: 110569.
- [5] WANG L T, YUAN B, XU Z B, et al. Synchronous detection of bolts looseness position and degree based on fusing electro-mechanical impedance[J]. Mechanical Systems and Signal Processing, 2022, 174: 109068.
- [6] RAMANA L, CHOI W, CHA Y J. Fully automated vision-based loosened bolt detection using the Viola-Jones algorithm[J]. Structural Health Monitoring, 2019, 18(2): 422-434.
- [7] CANNY J. A computational approach to edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, 8(6): 679-698.

- [8] 邱志成, 刘一鸿, 李旻. 柔性铰接板振动视觉测量与小波神经网络控制[J]. 光学精密工程, 2024, 32(7): 998-1010.
QIU Zhicheng, LIU Yihong, LI Min. Vibration vision measurement and wavelet neural network control of flexible hinged plate[J]. Optics and Precision Engineering, 2024, 32(7): 998-1010. (in Chinese)
- [9] KONG Q Z, ZHU J X, HO S C M, et al. Tapping and listening: a new approach to bolt looseness monitoring[J]. Smart Materials and Structures, 2018, 27(7): 07LT02.
- [10] YUAN R, LÜ Y, KONG Q Z, et al. Percussion-based bolt looseness monitoring using intrinsic multiscale entropy analysis and BP neural network[J]. Smart Materials and Structures, 2019, 28(12): 125001.
- [11] ZHANG Y, ZHAO X F, SUN X W, et al. Bolt loosening detection based on audio classification[J]. Advances in Structural Engineering, 2019, 22(13): 2882-2891.
- [12] YUAN C, WANG S Y, QI Y Z, et al. Automated structural bolt looseness detection using deep learning-based prediction model[J]. Structural Control and Health Monitoring, 2022, 29(3): e2899.
- [13] GAO S H, CHENG M M, ZHAO K, et al. Res2net: a new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43(2): 652-662.
- [14] 谢宗伟, 谭大鹏, 王彤, 等. 正交各向异性圆柱壳裂纹形态求解及其自由振动特性[J]. 高技术通讯, 2023, 33(10): 1100-1112.
XIE Zongwei, TAN Dapeng, WANG Tong, et al. Solution of crack morphology and free vibration characteristics of orthotropic cylindrical shell[J]. Chinese High Technology Letters, 2023, 33(10): 1100-1112. (in Chinese)
- [15] WANG X P, WANG D L, DAI W J, et al. A multi-scale temporal feature fusion framework for sheep voiceprint recognition[J]. Smart Agricultural Technology, 2025, 12: 101061.
- [16] 费相宜, 严博, 余宁, 等. 菱形磁悬浮电磁振动俘能器的建模与试验研究[J]. 振动工程学报, 2026, 39(1): 118-125.
FEI Xiangyi, YAN Bo, YU Ning, et al. Modeling and experiment of rhombus-type maglev electromagnetic vibration energy harvester[J]. Journal of Vibration Engineering, 2026, 39(1): 118-125. (in Chinese)
- [17] DAI Y M, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion[C]//2021 IEEE Winter Conference on Applications of Computer Vision (WACV). Waikoloa, HI, USA: IEEE, 2021: 3559-3568.
- [18] DENG J K, GUO J, YANG J, et al. ArcFace: additive angular margin loss for deep face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(10): 5962-5979.
- [19] ZHOU Y, WANG S Y, ZHOU M, et al. Percussion-based bolt looseness identification using vibration-guided sound reconstruction[J]. Structural Control and Health Monitoring, 2022, 29(2): e2876.
- [20] WANG F, SONG G B. 1D-TICapsNet: an audio signal processing algorithm for bolt early looseness detection[J]. Structural Health Monitoring, 2020, 20(5): 2828-2839.



第一作者简介: 李仔真, 男, 2002年3月生, 硕士生。主要研究方向为机械设备故障诊断。

E-mail: 2411090071@nbu.edu.cn

通信作者简介: 娄军强, 男, 1986年7月生, 博士、教授。主要研究方向为仿生机器人及流固耦合振动技术。

E-mail: loujunqiang@nbu.edu.cn