

DOI: 10.19650/j.cnki.cjsi.J2412340

基于 CBAM-CNN 和压电悬臂梁的温度 解耦质量感知方法*

闫宇楠^{1,2}, 刘智康^{1,2}, 徐佳文^{1,2}, 严如强³

(1. 东南大学仪器科学与工程学院 南京 210096; 2. 机器人感知与控制技术重点实验室 南京 210096;
3. 西安交通大学高端装备研究院 西安 710049)

摘要:悬臂梁结构广泛用于微小质量测量,而温度变化会引起测量结果漂移。传统测量方法需要在温度稳定的环境中进行,但实际应用中通常难以满足此要求,且温度漂移对测量的影响难以直接解耦。本文提出了一种基于数据驱动, CBAM-CNN 和压电悬臂梁的自适应温度解耦质量感知方法。首先,搭建谐振式压电悬臂梁温控测量平台采集不同质量负载下的阻抗响应信号,设计自适应加权预处理方法以增强结构特征并突出有限样本中的关键信息;其次,设计基于混合领域注意力机制的 CBAM-CNN 网络来评估信号中多个谐振峰的相对关系,实现温度解耦和质量感知。实验结果表明,该方法在 25°C 至 55°C 的温度范围内的对 0.1~1 g 的质量感知准确率高达 99.70%,无需进行温度补偿即可实现大跨度温度下的精确质量感知。

关键词: 压电悬臂梁;深度学习;CNN;CBAM;质量感知;温度解耦

中图分类号: TH703 **文献标识码:** A **国家标准学科分类代码:** 560.35

Temperature decoupled mass sensing based on CBAM-CNN and piezoelectric cantilever beam

Yan Yunan^{1,2}, Liu Zhikang^{1,2}, Xu Jiawen^{1,2}, Yan Ruqiang³

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China; 2. Jiangsu Key Lab of Robot sensing and control, Nanjing 210096, China; 3. iHarbour Academy of Frontier Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: The cantilever beam structure serves as a prevalent platform for micro-mass measurements. Conventional measurement methodologies necessitate a stable temperature environment, posing practical challenges. Temperature fluctuations profoundly impact measurement outcomes and pose difficulties in direct decoupling from the cantilever beam's characteristic equation. This paper introduces a temperature decoupled mass sensing method, leveraging CBAM-CNN and a piezoelectric cantilever beam. Initially, a temperature-controlled measurement platform employing a resonant piezoelectric cantilever beam is established to capture impedance response signals across varied mass loads. An adaptive weighted preprocessing method is tailored to augment structural features and accentuate critical information within confined samples. Subsequently, a CBAM-CNN network, incorporating a hybrid domain attention mechanism, is devised to evaluate the relative relationships of multiple resonance peaks in the signals, achieving concurrent temperature decoupled mass sensing. Experimental findings underscore the method's prowess, attaining an impressive 99.70% accuracy in mass measurements ranging from 0.1 g to 1 g within a temperature range spanning 25°C to 55°C. Moreover, the method exhibits precise mass sensing across a broad temperature spectrum, obviating the need for temperature compensation.

Keywords: piezoelectric cantilever beam; deep learning; CNN; CBAM; Mass sensor; temperature decoupling

0 引言

微悬臂梁传感技术是继原子力显微镜 (atomic force microscope, AFM)^[1] 和微机电系统 (micro electro mechanical systems, MEMS)^[2] 后发展迅猛的一种新型超微质量传感方法。随着 MEMS 技术的发展, 该技术凭借灵敏度高、结构轻便、性能稳定^[3] 等显著优势在医疗^[4-5]、军事、生化检测^[6-7]、环境监测^[8-9] 等领域被广泛用于测量微小物体的质量和位置信息^[10-12]。

微悬臂梁通常采用动态检测模式^[13-14] 进行测量, 利用压电材料、静电或其他功能材料作为激励或敏感元件。这种方法通过测量结构动态特性 (频率或相位) 的变化来识别或称重被测物, 谐振式压电悬臂梁质量传感器就是代表之一。Xiao 等^[15] 基于悬臂梁结构提出了一种可以同时感测多个分子质量和位置的同步感测方法。Elseddawy 等^[16] 在外加交流电场作用下, 利用单壁碳纳米管纳米机电系统 (nanoelectromechanical systems, NEMS) 谐振器实现对检测生物分子质量的检测。Li 等^[17] 通过研究 L 型压电悬臂梁的模式耦合行为和非线性动力学实现了微小质量检测。Sone 等^[18] 利用压电悬臂梁、正反馈控制器、压电驱动器和锁相环 (phase-locked loop, PLL) 解调器等实现了对悬臂梁上水分子的质量测量。然而, 传统方法通常依赖于压电传感器的双向电机机械耦合效应^[19-21], 需借助阻抗分析仪或复杂的频率捕捉电路才能实现检测。

当前, 悬臂梁传感器在低温、真空的实验室环境中的最小可探测质量已经达到原子级^[22]。然而, 由于材料的杨氏模量、悬臂梁尺寸和品质因数等都与温度相关^[23-24], 微小的温度变化会导致测量结构发生挠曲^[25-26]、谐振频率改变^[27-28] 以及测量精度降低, 这导致传统的悬臂梁传感系统对环境温度要求极为严格。但在实际测量场景中, 超稳定的温度控制通常难以实现。同时, 仅有少数研究提出通过调整机械结构、引入温度补偿等方式减小温度变化对测量的干扰。Shen^[29] 等人提出可采用双层悬臂梁结构、优化材料、减小涂层厚度消除部分热漂移。Lang 等人^[30] 提出可结合双微型悬臂结构和差分方法减小温漂, 但双悬臂梁结构存在不一致性, 易引入额外噪声, 无法完全实现温度解耦。Ikehara 等人^[31] 在压电质量传感器中引入 P-N 结二极管以补偿温度波动引起的频率漂移。Melamud 等人^[32] 提出利用硅悬臂结构表面氧化膜进行温度补偿。然而上述方法均不能完全消除温度影响, 且存在工艺复杂、加工困难、成本高昂等缺点。

综上, 当前亟需解决微悬臂梁传感系统中的温度依赖问题。深度学习是一种通过多层处理对数据进行深度采样来解决回归或分类问题的方法, 广泛应用于机械故

障诊断^[33-35]、文本分类^[36-37] 和心脑血管疾病诊断^[38-40] 等领域。深度学习模型具有强大的特征提取和学习能力, 能够在质量测量场景中实现对温度变化的自适应补偿, 相比传统方法具有低成本、高效率、强鲁棒性等优点, 但是目前未有学者采用该方法解决悬臂梁质量测量中的温度干扰问题, 因此, 本文创新性得提出采用深度学习模型进行质量感知和温度解耦。

然而, 一方面, 压电悬臂梁系统的特征方程为超越方程^[41], 理论上环境变化不会改变多个谐振峰之间的相对关系, 可以不考虑温度相关项 (如杨氏模量), 使用多个共振频率的数值直接解算质量值。但是该方法计算复杂, 难以准确得出质量与共振频率之间的解析关系, 且共振频率的测量误差可能引起求解误差。另一方面, 虽然卷积神经网络 (convolutional neural network, CNN) 作为典型的前馈神经网络, 相比其他网络模型具有权重共享和局部区域连接特征以及优越的特征提取和学习能力^[42]。但是 CNN 通常依赖大量训练数据, 而在压电悬臂梁测量场景中仅能采集到有限样本, 且阻抗信号特征有限, 极易导致结果准确性下降。

因此, 本文提出基于 CBAM-CNN 和压电阻抗的自适应温度解耦质量感知方法。首先对阻抗信号进行自适应加权平均预处理, 实现数据增强并突出重要的结构特征; 其次, 在具有首层宽卷积核的 CNN 中引入混合域注意力机制 (convolutional block attention module, CBAM), 对阻抗信号中多个谐振峰的相对关系和关键特征进行分析和提取, 通过充分利用有限的样本数据, 实现在大跨度温度中的准确质量感知。实验结果证明, 该方法相较于 SVM、DNN 等网络具有出色的温度解耦和质量感知能力, 有效提高了测量的鲁棒性和准确性, 有望推动悬臂梁传感技术在复杂温度环境中的应用, 为未来解决超微质量测量中的温度干扰问题提供了一种新的可能。

1 理论背景

1.1 压电悬臂梁的谐振行为及温度依赖性

如前文所述, 谐振式压电悬臂梁质量传感器的主要弹性元件为悬臂梁, 本文所采用的测量结构如图 1 所示。在矩形悬臂梁两侧同一位置粘贴两个大小相同的压电片 (PZT1, PZT2), 悬臂梁自由端附加待测质量块。其中, PZT1 作为致动器用于加载扫频激励电压信号, PZT2 作为传感器用于采集结构响应电压信号。将交流激励电压施加于 PZT1, 由于逆压电效应, 悬臂梁将在弯曲振动模式下产生形变, 同时在正压电效应作用下 PZT1 和 PZT2 上均会产生响应电压。

根据 Euler-Bernoulli 梁理论, 压电悬臂梁特征方程如下^[41]:

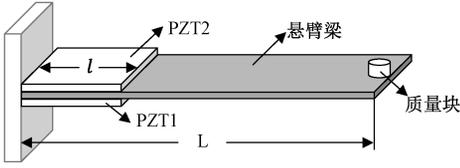


图1 压电悬臂梁测量结构

Fig.1 Measurement structure of resonant piezoelectric cantilever

$$1 + \cos\lambda_i \cosh\lambda_i + \lambda_i \frac{M_i}{mL} (\cos\lambda_i \sinh\lambda_i - \sin\lambda_i \cosh\lambda_i) - \frac{\lambda_i^3 I_i}{mL^3} (\cosh\lambda_i \sin\lambda_i + \sinh\lambda_i \cos\lambda_i) + \frac{\lambda_i^4 M_i I_i}{m^2 L^4} (1 - \cos\lambda_i \cosh\lambda_i) = 0 \quad (1)$$

式中: λ_i 为结构的第 i 个特征值, m 为悬臂梁的单位长度质量, M_i 为待测质量块的质量, I_i 为悬臂梁的等效截面惯性矩, L 为悬臂梁长度。同时, 结构的第 i 个固有频率与特征值之间关系如下:

$$\omega_i = \lambda_i^2 \sqrt{EI/\rho A} \quad (2)$$

式中: E 为杨氏模量, ρ 为悬臂梁材料的密度, A 为梁的横截面积。由上式可知, 谐振频率 ω_i 可以通过分析测量结构的阻抗信号得到。需要注意的是, 以往的研究主要关注单一的谐振频率, 而由于杨氏模量和悬臂梁尺寸具有温度依赖性, 单一的谐振频率值由与上述公式中的 m 、 I_i 、 L 、 M_i 、 E 、 ρ 等参数深度耦合, 当环境温度变化时悬臂梁的物理尺寸、刚度、杨氏模量、谐振频率等均会随之改变, 进一步使得待测质量计算值出现偏差。

如前文所述, 理论上环境温度变化并不会影响多个谐振频率之间的相对关系, 如果能够获取足够多的特征值, 即可消除上述公式中的温度相关项。因此, 本文提出可以利用测量多个谐振频率求解待测质量 M_i 。然而, 由于待测质量 M_i 与特征值间为隐性的非线性关系, 无法直接通过传统的解析方法求解。注意到神经网络具有强大的非线性建模和特征提取能力, 为解决这上述问题, 我们在后续的分析中引入了神经网络和自适应加权平均预处理方法来实现温度解耦和质量感知。

1.2 卷积神经网络

LeCun^[43] 于 1989 年结合反向传播算法与权值共享的卷积神经层发明了 CNN, 并在美国邮局的手写字符识别系统中首次成功应用。CNN 具有强大的特征提取能力, 能够自动从输入信号中提取深层特征信息, 常用于解决分类或回归问题, 在图像处理、故障诊断等领域应用广泛。典型的 CNN 模型一般由输入层、卷积层、池化层、全连接层 (FC 层) 和输出层 5 部分组成。信号通过输入层

进入网络后, 由卷积层和池化层交替形成的若干卷积模块对信号进行特征提取和降维操作。最后, 全连接层对提取的特征进行处理, 然后由输出层输出。

卷积层中通常包含多个卷积核, 可以提取输入信号的多种特征。卷积核与输入的特征矢量进行卷积操作, 随后通过激活函数进行非线性变换以提取信号的非线性特征。其中, 卷积运算为:

$$\mathbf{x}_i^{l+1} = f\left(\sum_j \mathbf{x}_i^l * \mathbf{k}_{ij}^{l+1} + \mathbf{b}_i^{l+1}\right) \quad (3)$$

式中: \mathbf{x}_i^{l+1} 为第 $l+1$ 个卷积层的第 i 个特征图, \mathbf{x}_i^l 为上一层的第 j 个特征图, \mathbf{k}_{ij}^{l+1} 为第 $l+1$ 层第 i 个卷积核, \mathbf{b}_i^{l+1} 为第 $l+1$ 层偏置值, $*$ 代表卷积计算, $f(\cdot)$ 在本文中代表 ReLU 激活函数。该函数可表示为:

$$\mathbf{v}_i^{l+1}(j) = f(\mathbf{z}_i^{l+1}(j)) = \max\{0, \mathbf{z}_i^{l+1}(j)\} \quad (4)$$

式中: $\mathbf{z}_i^{l+1}(j)$ 为卷积计算的输出, $\mathbf{v}_i^{l+1}(j)$ 为 $\mathbf{z}_i^{l+1}(j)$ 激活值。通常连续的卷积层之间会周期性地插入池化层, 目的是通过下采样操作保留有效的特征信息并压缩特征向量的维度, 以减少网络参数的数量, 避免模型过拟合。其中, 最大池化操作最为常见:

$$\mathbf{P}_i^{l+1}(j) = \max_{(j-1)W+1 \leq m \leq jW} \{\mathbf{q}_i^l(m)\} \quad (5)$$

式中: $\mathbf{q}_i^l(m)$ 为第 l 层中第 i 个特征向量的第 m 个神经元, W 表示池化区域宽度, $\mathbf{P}_i^{l+1}(j)$ 为第 $l+1$ 层第 i 个特征矢量的第 j 个值。

经过若干卷积模块处理后的输出特征经过“展平”操作变为一维特征向量, 随后将被馈送到全连接层进行更深层的特征提取。最终, 提取的深层特征输入 softmax 分类器进行分类, 并通过输出层输出各个类别的概率, 输出结果可表示为:

$$\mathbf{O} = f(\mathbf{f}_o \mathbf{w}_o + \mathbf{b}_o) \quad (6)$$

式中: \mathbf{O} 为分类问题中各个类别概率, \mathbf{f}_o 为最后一个 FC 层的特征向量, \mathbf{w}_o 为权值矩阵, \mathbf{b}_o 为偏置矩阵。

1.3 混合域注意力机制

CBAM 是由 Woo^[44] 等于 2018 年首次提出一种混合域注意力机制, 结合了通道注意力 (channel attention mechanism, CAM) 和空间注意力 (spatial attention mechanism, SAM) 两个子模块, 强调空间和通道两个维度上的关键特征, 可以有效增强有用特征, 抑制无用信息。CBAM 的结构如图 2 所示, 首先通过 CAM 对输入特征图 \mathbf{F} 进行处理得到通道注意力 \mathbf{M}_c , \mathbf{F} 和 \mathbf{M}_c 逐元素相乘得到通道增强特征 \mathbf{F}_c 。然后 SAM 对 \mathbf{F}_c 处理得到空间注意力 \mathbf{M}_s , \mathbf{M}_s 和 \mathbf{F}_c 逐元素相乘生成优化特征 \mathbf{F}' 。

值得注意的是, 由于多层感知机 (Multilayer Perceptron, MLP) 引入大量参数导致模型复杂度和计算量增加, 而双卷积层采用局部连接和权重共享, 能够减少参数数量、降低模型复杂度, 并更好地保留通道间的空间信息^[45-47], 因此为提高通道注意力的表达能力和泛化能

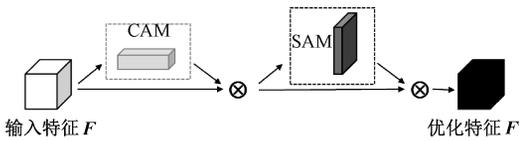


图2 CBAM模块结构

Fig. 2 Structure of CBAM

力,本文将CAM中传统的MLP替换为双卷积层,修改后的结构如图3。

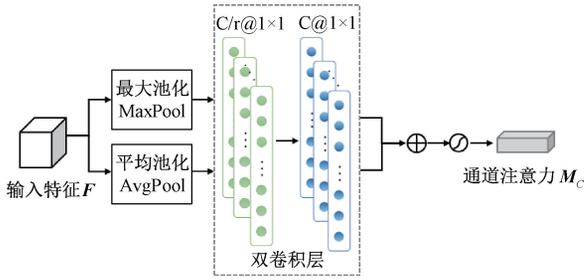


图3 CAM子模块结构

Fig. 3 Structure of CAM

CAM首先对 F 同时进行全局最大池化和全局平均池化操作,两个池化特征分别输入双卷积层,随后卷积层输出特征逐元素相加,最后经sigmoid激活函数生成通道注意力 M_c 。其中,双卷积层的激活函数均为ReLU,首层包含 C/r 个卷积核(C 为通道数, r 为衰减系数),用于压缩通道数量;第二层包含 C 个卷积核,用于还原通道数。

M_c 和 F 进行逐元素乘法后生成的通道增强特征 F_c, F_c 输入如图4所示的SAM后,先后通过最大池化和平均池化操作得到两个基于通道的池化特征图,随后这两个特征图经过基于通道的串联和卷积操作,最终经sigmoid激活函数生成空间注意力 M_s 。

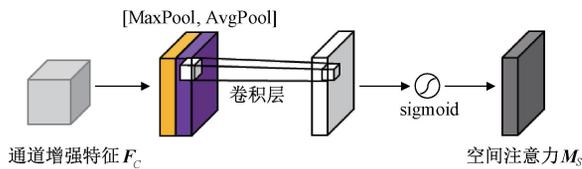


图4 SAM子模块结构

Fig. 4 Structure of SAM

2 基于自适应加权预处理和CBAM-CNN的质量测量及温度解耦方法

基于上述理论背景,为实现大跨度温度下的准确质量感知,本文所提的质量测量及温度解耦系统框架如图5所示,由谐振式压电悬臂梁温控测量平台、自适应加

权平均预处理、CBAM-CNN网络三部分构成。

2.1 自适应加权平均预处理

如1.1节所述,本文引入神经网络分析待测质量与谐振频率之间的非线性关系。然而,由于原始阻抗数据量庞大,直接将其输入神经网络将导致训练速度大幅降低甚至引起网络崩溃。此外,谐振峰的位置和幅值中包含丰富的结构关键特征,而悬臂梁自由端加载质量的变化会导致结构多阶谐振频峰偏移。因此,本文提出一种自适应加权平均预处理方法对数据进行降采样和特征增强处理,将包含2000000个数据点的原始信号 S 处理为只包含5000个数据点的新信号 S' ,在保留原始信息的同时突出关键信息。

首先设置5000个长度为400的数据分割窗口对 S 进行无重叠平均分割得到窗口 $window_i$, ($i=1,2,3,\dots,5000$),再计算各个窗口内数据的平均值 m_i ,组成平均值序列 $M\{m_i\}$;其次,取 $window_i$ 的最大值 \max_i 和最小值 \min_i ,计算两者差值 Δ_i 并构建差值序列 $\delta\{\Delta_i\}$,其中 Δ_i 为:

$$\Delta_i = \max_i - \min_i \quad (7)$$

实验数据表明,相较于其他窗口,包含谐振峰的窗口对应的 Δ_i 更大,为放大波峰特征,本文基于 Δ_i 构建权重序列。然而,由于 S 内某些片段变化幅度较小使得 $\delta\{\Delta_i\}$ 中部分点的值近似为0,若直接以 $\delta\{\Delta_i\}$ 作为权重序列与 $M\{m_i\}$ 逐元素相乘,将导致部分数据丢失引起信号失真。为避免信号失真和有效放大谐振峰,对 Δ_i 进行如下处理后得到 $M\{m_i\}$ 的权重序列 $W\{w_i\}$, w_i 的值为:

$$w_i = 5 \times \Delta_i + 1 = 5 \times (\max_i - \min_i) + 1 \quad (8)$$

最后,将 $W\{w_i\}$ 与 $M\{m_i\}$ 逐元素相乘生成包含5000个数据点的结构阻抗信号 $S'\{s_i\}$, s_i 的值为:

$$s_i = w_i \times m_i \quad (9)$$

由图6可知,原始信号 S 经上述方法处理后,其波峰区域被有效放大,其余变化幅度较小的非波峰片段均未失真。在测量过程中,波峰区域往往蕴含着丰富的物理信息,如结构的响应特性、材料的动态行为等,该方法不仅保留了信号的整体特征,而且通过增强波峰数据,显著放大了局部的关键特征,数据的利用率和信噪比得到了大幅提升。此外,该方法能够最大程度捕捉和识别结构的关键物理信息,增强了样本的物理意义,便于我们更准确的结构动态响应,为后续的数据分析和网络处理提供更多信息。

2.2 CBAM-CNN网络设计

传统的CNN模型具有出色的非线性建模和特征提取能力,但在处理复杂问题时容易受无关信息的影响而导致性能下降。为提升网络鲁棒性,本文在CNN中引

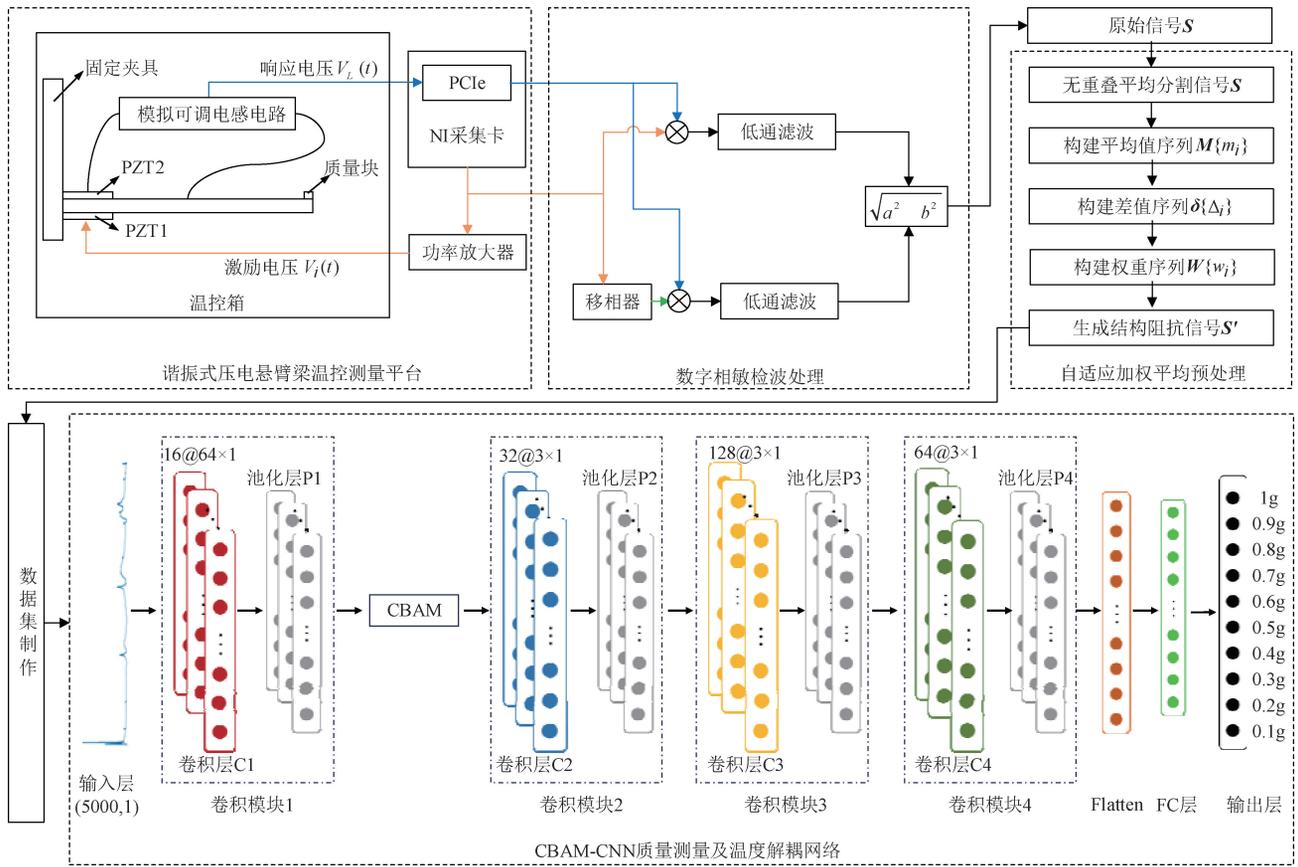


图 5 质量测量及温度解耦系统框架

Fig. 5 Framework of mass measurement and temperature decoupling system

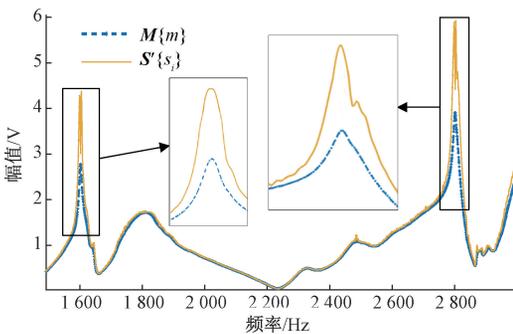


图 6 预处理前后对比

Fig. 6 Comparison before and after preprocessing

入 CBAM 模块,使网络能进一步抑制无用信息和增强关键特征。CBAM-CNN 结构如图 7 所示,由一个输入层,4 个卷积模块,CBAM 模块、全连接层和输出层组成,其中每个卷积模块由卷积层、修正线性单元(ReLU)、BN 层和池化层构成。

CBAM-CNN 的结构参数如表 1 所示。模型的输入层为 5 000×1 的结构频域响应数据,网络选用 Adam^[48] 优化器更新参数,学习率为 0.001,批大小为 128,设置 50 个

表 1 CBAM-CNN 结构参数

Table 1 Structural parameters of CBAM-CNN

层名称	结构参数	输出大小
输入层	/	5 000×1
卷积层 C1	CN=16; CS=64×1; C_stride=8	625×16
池化层 P1	PS=2; P_stride=2	312×16
卷积层 C2	CN=32; CS=3×1; C_stride=1	312×32
池化层 P2	PS=2; P_stride=2	156×32
卷积层 C3	CN=128; CS=3×1; C_stride=1	156×128
池化层 P3	PS=2; P_stride=2	78×128
卷积层 C4	CN=64; CS=3×1; C_stride=1	78×64
池化层 P4	PS=2; P_stride=2	39×64
CBAM	/	39×64
Flatten	/	2 496
FC 层	/	10
输出层	/	10

* CS、CN 分别代表卷积核尺寸和卷积核数量,C_stride 表示卷积核步幅,PS 代表池化大小,P_stride 代表池化步幅。

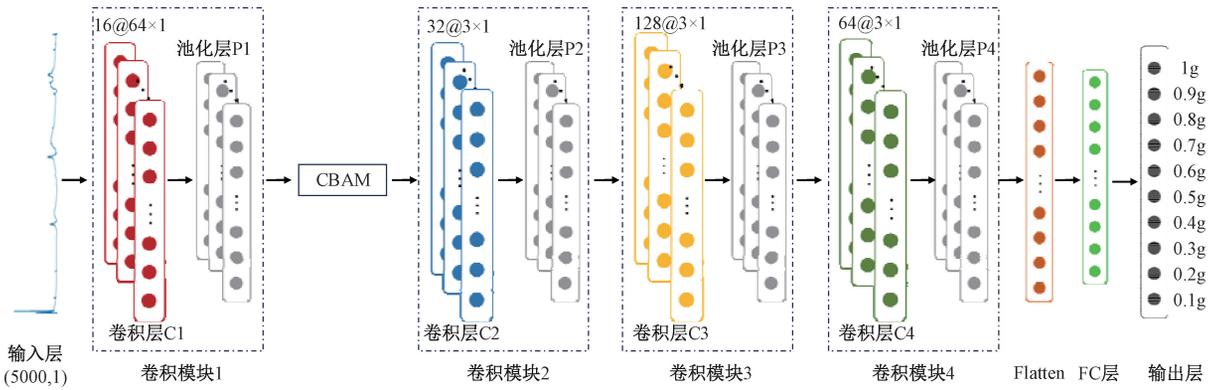


图7 CBAM-CNN 网络结构

Fig. 7 Structure of CBAM-CNN

训练情节。卷积层 C1、C2、C3、C4 表示一维卷积层,用于提取上层输入的不同特征。其中 C1 选用大小为 64×1 的宽卷积核,因为宽卷积核在高频处具有更强的去噪能力,可以拓宽感受野和优化网络性能。为提高模型训练速度,C1 的卷积步幅为 8。BN 表示批标准层,用于加快网络训练和收敛速度,防止网络训练过程中可能出现的梯度消失问题和梯度爆炸问题。ReLU 层增加网络稀疏性,缓解过拟合问题。MaxPooling1D 表示一维最大池化层,用于降低模型参数量,优化网络工作量。Dropout 层通过关闭部分神经元的方式来降低过拟合。Dense 表示全连接层。

CBAM 模块设置在卷积模块 1 和卷积模块 2 之间。池化层 P1 的输出作为 CBAM 模块的输入,先后经 CAM 和 SAM 处理,最后生成尺寸不变的增强特征图作为卷积层 C2 的输入。如前文所述,为更有效地挖掘信号中的深层关键特征,本文的 CAM 中采用两层卷积层,首层用于压缩通道,衰减系数 r 为 4,包含 16 个大小和步幅均为 1 的卷积核;第二层用于还原通道,包含 64 个大小和步幅均为 1 的卷积核。SAM 中的卷积层只包含 1 个大小和步幅均为 1 的卷积核。

3 实验及结果分析

3.1 实验平台

为验证所提方法的性能,本文在图 8 所示的测量平台上完成实验。

该平台由温控箱、功率放大器、稳压电源、NI 采集卡、模拟可调电感电路和上位机组成。温控箱用于模拟实际测量场景中的不同环境温度,其温度调节范围为 $0^\circ\text{C} \sim 65^\circ\text{C}$,谐振压电悬臂梁测量结构由工具钢夹具固定放置在恒温箱内,为验证该系统在大跨度温度下的性能,本文选择 4 个温度 (25°C , 35°C , 45°C , 55°C) 进行实验。



图8 谐振式压电悬臂梁温控质量测量装置

Fig. 8 Resonant piezoelectric cantilever beam temperature-controlled mass measurement device

测量结构如图 9 所示,采用弹性钢矩形悬臂梁,其厚度为 0.3 mm,杨氏模量为 210 Gpa,泊松比为 0.288,密度为 7810 kg/m^3 。在梁固定端的两侧粘贴两块大小相同、厚度均为 0.2 mm 的由高钛酸铅压电陶瓷 (lead zirconate titanate, PZT) 制成的压电片 (PZT1、PZT2)。其中, PZT1 作为致动器用于加载正弦扫频激励信号 $V_i(t)$,在正逆压电效应的作用下,作为传感器的 PZT2 端会产生响应电压。

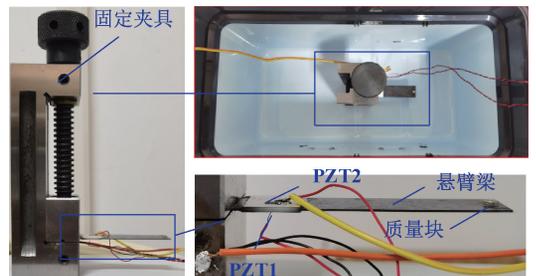


图9 压电悬臂梁测量结构

Fig. 9 Measurement structure based on piezoelectric cantilever beam

值得注意的是,由于阻抗信号特征有限,为满足后续网络的数据需求和提高系统性能,本文在 PZT2 两端引

入模拟可调电感电路,将电感两端电压 $V_L\{t\}$ 作为响应信号。该电路如图 10 所示,可以在不改变结构机械阻抗的同时,通过调整电感值丰富压电-结构耦合系统的动态响应特性,进而在相同实验条件下获得更丰富的特征信息,实现数据增强。

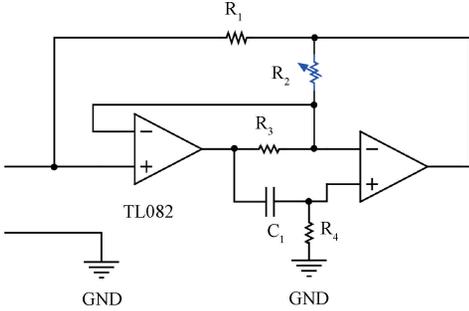


图 10 模拟可调电感电路

Fig. 10 Tunable inductance shunt circuit

该电路输出电感可表示为:

$$L = \frac{R_1 R_3 R_4 C_1}{R_2} \quad (10)$$

此处 R_1 、 R_4 、 R_3 、 C_1 均为固定值,可变电阻 R_2 选用可编程变阻器 AD5272,其电阻可调范围为 $0 \sim 100 \text{ k}\Omega$ 。本文通过改变 AD5272 的阻值调节来输出电感值。实验设置电阻值分为 50 个档次,初始电阻为 $1 \text{ k}\Omega$,终止电阻为 $5 \text{ k}\Omega$,阻值调节步长为 $1 \text{ k}\Omega$ 。

待测质量块粘贴在梁自由端的固定位置处。不同的待测质量会引起结构的谐振行为改变,响应阻抗信号谐振峰的幅值和位置也会随之改变,因此本文选择 0.1 g 、 0.2 g 、 0.3 g 、 0.4 g 、 0.5 g 、 0.6 g 、 0.7 g 、 0.8 g 、 0.9 g 、 1 g 十种质量进行测量,通过分析不同温度、不同质量下的响应信号实现质量测量。值得注意的是,此处我们着眼于分析所提方法的可行性,后续研究可以进一步增加质量分类及改进算法,以实现大量程高分辨率的质量感知。实验采用 NI PCIe-6361 DAQ 设备输出激励信号和完成数据采集。数据的采样频率 $f_s = 20 \text{ kHz}$,采样时长 $t_s = 100 \text{ s}$,正弦扫频激励信号 $V_i\{t\}$ 经功率放大器放大后加载于 PZT1 端,其线性扫频范围为 $0 \sim 5000 \text{ Hz}$ 。

此外,为提高信噪比和便于后续分析,本文利用 MATLAB R2022b 和 Simulink 开发了基于数字相敏检波的结构频域阻抗信号提取算法,将响应信号 $V_L\{t\}$ 转化为原始信号 S 。本实验在 4 种不同温度下分别设置不同电感和不同待测质量,共采集 1 992 个样本,样本分布如表 2 所示。

实验测量过程为:首先在悬臂梁的自由端加载待测质量;随后设置温控箱温度以及模拟可调电感电路中的

表 2 不同测量条件下的样本分布

Table 2 Sample distribution in different measurement conditions

质量类别	25℃	35℃	45℃	55℃
	样本数量	样本数量	样本数量	样本数量
0.1 g	50	50	50	50
0.2 g	50	50	50	50
0.3 g	50	49	50	50
0.4 g	50	50	50	50
0.5 g	50	50	50	50
0.6 g	50	50	50	50
0.7 g	50	50	50	50
0.8 g	45	49	50	49
0.9 g	50	50	50	50
1 g	50	50	50	50

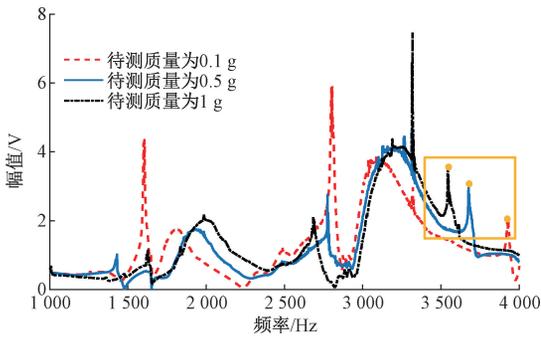
电感值;随后由 NI 采集卡产生的正弦扫频激励信号 $V_i\{t\}$ 经功率放大器放大后施加于 PZT1 上,同时通过 NI 采集卡采集电感两端的响应电压 $V_L\{t\}$ 并利用结构频域阻抗信号提取算法对 $V_L\{t\}$ 处理得到信号 S ;进一步对信号 S 进行自适应加权平均处理得到结构阻抗信号 S' ,将 1 992 条数据样本以 10 类质量为标签制作为数据集,并按照 7:2:1 的比例分割为训练集、验证集和测试集;最后将该数据集输入 CBAM-CNN 后得到质量分类结果。

实验过程中所有数据处理和网络训练均在 Windows 台式计算机上完成,其 CPU 和 GPU 配置为: Intel-8700 CPU 和 Nvidia GTX 10603 GB GPU。

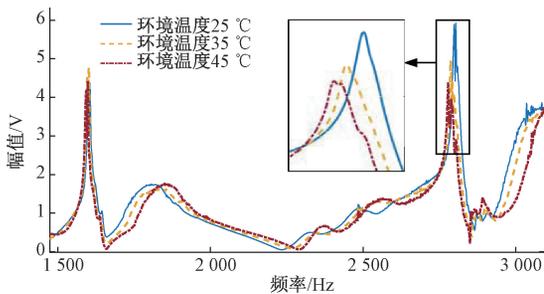
3.2 测量方法可行性分析

根据前文论述可知,悬臂梁末端加载不同质量会引起梁的多阶谐振频率发生改变,进而改变 PZT2 的响应电压。同时,由于 PZT2 端并联模拟可调电感电路,当 PZT2 的响应电压变化时,电感端的电压 $V_L\{t\}$ 和处理后得到的结构阻抗信号 S' 均会随之改变。基于此,本文提出通过分析并联电感两端的电压信号来揭示压电悬臂梁多个谐振峰之间的相对关系,实现梁自由端加载质量的测量和温度解耦。

以环境温度为 25°C ,等效电感电路中可调电阻为 $10 \text{ k}\Omega$ 为例,图 11 对比了待测质量分别为 0.1 g 、 0.5 g 、 1 g 的阻抗信号 S' ,其频率范围均为 1000 Hz 到 4000 Hz 。图 11 中标记的波峰均为谐振峰。显然,随着待测质量的变化,谐振峰也发生了变化,其位置随质量的增加而左移。当待测质量从 0.1 g 增加到 1 g 时,谐振峰的值从 3926 Hz 减少到 3543 Hz ,这表明通过评估阻抗信号中的峰值来测量待测质量是可行的。

图 11 不同质量对抗阻信号 S' 的影响Fig. 11 Impedance signal S' with different masses

此外,环境温度的变化也会引起谐振频率变化。以待测质量为 0.1 g, 等效电感电路中可调电阻为 20 k Ω 为例。图 12 对比了环境温度分别为 25 $^{\circ}\text{C}$ 、35 $^{\circ}\text{C}$ 、45 $^{\circ}\text{C}$ 时的阻抗信号 S' , 其频率范围均为 1 000~3 500 Hz。

图 12 不同环境温度对抗阻信号 S' 的影响Fig. 12 Impedance signal S' with different temperature

当环境温度从 25 $^{\circ}\text{C}$ 上升到 45 $^{\circ}\text{C}$ 时,在 2 800 Hz 附近的谐振峰的峰值从 2 804 Hz 减小到 2 779 Hz。可见,即使保持待测质量不变,不同的环境温度仍然会引起阻抗信号发生显著变化,谐振峰的位置会随温度升高向左偏移,对应的谐振频率也会随之减小。

事实上,在某些质量测量情况下,温度引起的谐振频率偏移比质量变化引起的偏移更大。例如,当环境温度为 25 $^{\circ}\text{C}$,待测质量从 0.1 g 增加到 0.2 g 时,位于 2 800 Hz 附近和 4 300 Hz 附近的谐振峰峰值分别减小了 36 Hz 和 24 Hz。此外,当待测质量为 0.1 g 时,当温度从 25 $^{\circ}\text{C}$ 上升到 55 $^{\circ}\text{C}$,这两个谐振峰的峰值分别减小了 23 Hz 和 53 Hz。显然,在这一测量场景中,相比于质量变化,温度变化会导致结构的谐振频率产生更显著的偏移。这表明如果关注单一谐振峰时,质量测量结果有极强的温度依赖性,一旦环境温度发生变化,测量结果将可能产生巨大的误差。由此可见,必须要进行温度解耦才可能实现准确的质量测量,且本文提出的通过评估多个谐振峰之间的相对关系来实现质量测量是可行的。

3.3 实验结果分析

1) 结果评价指标

为充分利用样本,实验中使用五折交叉验证策略来评价模型的性能。首先将每类质量下的总样本量 N 随机均匀分为 5 个子数据集,每个子数据集样本量为 $N/5$ 。随后依次将每一个子数据集作为测试集,其余 4 个子数据集作为训练集,进行模型性能评估。本文采用混淆矩阵 (confusion matrix)、平均精确率 (average precision, AP)、平均召回率 (average recall, AR)、F1 Score、总体准确率 (overall accuracy, OA)、平均 Kappa 系数 (average Kappa, AK) 这 6 个评估指标对实验结果进行分析。

其中,每次测量的总体准确率 (overall accuracy, OA) 可表示为:

$$OA = \frac{\sum_{i=1}^K x_{test,correct}^{(i)}}{N_{test}} \quad (11)$$

式中: $x_{test,correct}^{(i)}$ 表示测试样本中第 i 类正确分类的样本数, N_{test} 为测试样本量。最后将五次测试的平均 OA 作为模型的评价指标。

AP 用于衡量分类器在预测正例样本时的准确性, AR 用于评价分类器对正例样本的识别能力, F1 Score 为精确率和召回率的调和平均数,用于评估模型的综合性能。AK 用于评估分类器预测的准确性与随即预测的一致性之间的差异。

2) 不同网络测量结果对比

为验证所提 CBAM-CNN 模型的有效性,本文对比了 DNN 和 CNN 三种网络对本实验数据集的学习能力。

1) DNN: 包括 1 个输入层, 3 个 Dense 层, 3 个 Dropout 层和 1 个输出层。其中 Dense 层和 Dropout 层交替组成 3 个特征提取模块, 3 个 Dense 层 fenbie 设置 1 024、64、128 个神经元, 其激活函数均为 ReLU, l2 正则化操作系数均为 0.001。3 个 Dropout 层系数均为 0.1。输出层采用 softmax 分类器, 模型采用交叉熵损失函数和 Adam 优化器。

2) CNN: 由一个输入层, 4 个卷积模块, 一个全连接层和一个输出层组成, 网络参数与本文所提的 CBAM-CNN 中对应的 CNN 的参数相同。

DNN, CNN 和 CBAM-CNN 的输入均为经自适应加权平均处理后的一维结构频域响应信号, 信号长度为 5 000。各个模型训练批大小均为 128, 学习率均为 0.001, 训练情节均设置为 50。

表 3 对比了 3 个网络的五折交叉验证的训练集综合准确率。DNN 在五折交叉验证中的准确率相对较低, 最高为 76.37%, 最低为 10.03%, 表明 DNN 在训练集上的性能不稳定, 更易出现过拟合。CNN 表现较好, 准确率一直保持在 99.00% 以上, 说明 CNN 在训练集上的泛化

能力较强,能够有效地识别不同质量类别的样本。相较于而言,CBAM-CNN 在训练集上的性能最优,在五折交叉验证中均表现出高于 99.80% 的极高准确率,显然具有更强的稳定性。

表 3 3 种网络五折交叉验证的训练集准确率

Table 3 Train accuracy comparisons of five-fold cross-validation for three networks %

交叉验证	DNN	CNN	CBAM-CNN
一折	76.37	99.25	99.93
二折	73.31	99.50	99.93
三折	61.93	99.00	100.00
四折	68.39	99.59	100.00
五折	10.03	100	99.87
总体 OA	57.28±24.09	99.45±0.33	99.70±0.10

表 4 列出了 3 个网络在 10 类质量测量中五折交叉验证的测试集平均准确率。在 10 类质量测量实验中,所提 CBAM-CNN 在大多数质量类别上都达到了 100%,且其总体 OA 最高,高达 99.7%,相较 DNN 和 CNN 分别提升了 42.42%,0.25%。CBAM-CNN 总体 OA 的标准差最小,表明该网络具有较强的测量稳定性。CNN 虽然在大多数质量类别中与 CBAM-CNN 表现相当,但在 0.5 g 和 0.6 g 这两种情况下波动较大且均低于 CBAM-CNN。相比之下,DNN 的表现较差,具有极高的不稳定性,其准确率在不同质量类别上波动较大,最高为 88.00%,最低仅为 22.50%。

表 4 3 种网络五折交叉验证的测试集 OA 比较

Table 4 Test OA comparisons of five-fold cross-validation for three networks %

质量类别	DNN	CNN	CBAM-CNN
0.1 g	80.00	100.00	100.00
0.2 g	79.00	100.00	100.00
0.3 g	88.00	100.00	100.00
0.4 g	45.00	100.00	100.00
0.5 g	44.00	98.50	99.00
0.6 g	22.50	97.00	99.00
0.7 g	56.00	100.00	100.00
0.8 g	59.97	100.00	100.00
0.9 g	51.50	99.00	99.00
1 g	47.50	100.00	100.00

表 5 列出了上述网络的平均训练及测试时间。其中,准确率低于 CNN 的 DNN 耗时比 CNN 更长,综合效

率较差。准确率最高的 CBAM-CNN 的训练耗时长于 DNN 和 CNN,这是由于 CBAM 在挖掘信号更深层的特征时会增加训练耗时,而当该网络学习到关键的特征后,其测试时间反而低于 CNN,且平均准确率相比 CNN 有所提升,综合而言,CBAM-CNN 在训练和测试时间上可能会产生额外的消耗,但它在处理效率和性能方面达到了更好的平衡,尤其适用于需要高准确率和快速推理的应用场景。

表 5 3 种网络的平均耗费时间

Table 5 Average elapsed time of each networks s

网络	DNN	CNN	CBAM-CNN
训练时间	52.20±0.96	50.92±5.54	62.34±4.78
测试时间	0.15±0.01	0.22±0.02	0.21±0.02

3 种网络的其他评估指标如表 6 所示。DNN 的性能相对较差,正确分类样本的能力较弱,而且 DNN 的平均精确率和召回率的标准差较大,表明其性能波动大,存在不稳定性。相比 DNN 和 CNN,CBAM-CNN 在各项关键指标上表现最佳,平均精确率高达 99.71%,具有最佳的正确分类样本的能力,CNN 则为 99.46%,DNN 表现最差仅为 58.98%。同时,CBAM-CNN 具有高达 99.7% 的高召回率,对正样本具有更强的捕获能力。此外,其 Kappa 系数也非常接近 1,各类指标的标准差均最小,这表明该网络与随机分类的一致性极高,性能非常稳定,并具有更强的泛化能力。

表 6 3 种网络的其他指标

Table 6 Other metrics of each network %

网络	DNN	CNN	CBAM-CNN
AP	58.98±29.35	99.46±0.32	99.71±0.10
AR	57.35±24.02	99.45±0.33	99.70±0.10
AK	52.58±26.68	99.39±0.37	99.66±0.11
F1 Score	54.08±26.60	99.45±0.33	99.70±0.10

为直观地展示所提模型在每个质量类别上的分类情况,对 CBAM-CNN 地整体性能进行全面评估,图 13 对比了三种网络的测试集的混淆矩阵。显然,DNN 的混淆矩阵显示在所有质量类别上都存在较高的混淆情况,例如,在 0.3 g 和 0.4 g 质量类别上,存在较高比例的样本被误分类为相邻的质量类别。这表明 DNN 在识别不同质量类别时存在困难,分类较为模糊。混淆矩阵中的非对角元素值较高,说明 DNN 在一些情况下难以正确分类样本。

CNN 的混淆矩阵显示在大多数质量类别上表现良好,对角线元素值接近或等于 100%,说明 CNN 在这些类

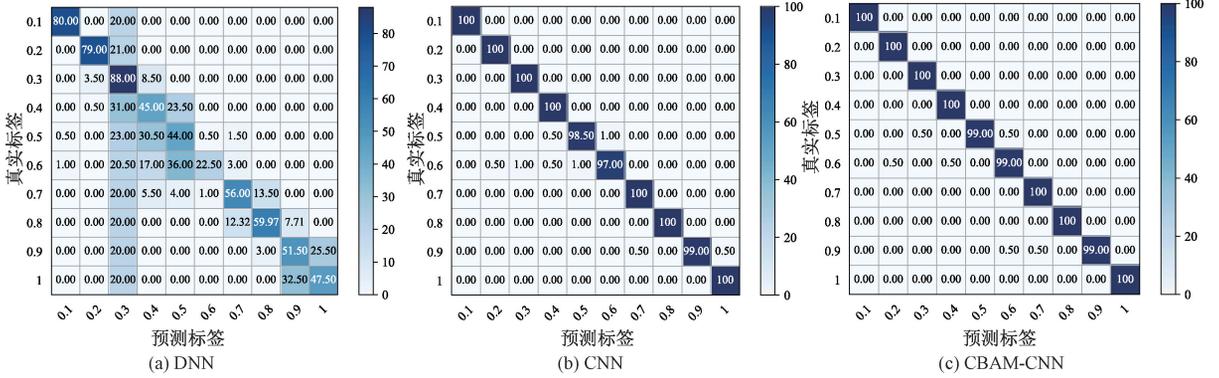


图 13 3 种网络的测试集的混淆矩阵对比

Fig. 13 Confusion matrix comparison of test sets for three networks

别上能够准确分类样本。然而, 仍然存在一些误分类情况, 例如在 0.4 g 和 0.5 g 质量类别上, 存在一些样本被误分类。这表明 CNN 相对于 DNN 具有更好的分类能力, 但仍然存在一定的改进空间。

CBAM-CNN 的混淆矩阵显示在所有质量类别上都表现出色, 几乎所有的对角线元素值都接近或等于 100%。这表明 CBAM-CNN 在对不同质量类别进行分类时几乎没有出现误分类的情况, 具有很高的分类准确性和稳定性。相比之下, CBAM-CNN 的综合性能优于 DNN 和 CNN, 具有更出色的分类准确性和稳定性, 特别是在模糊边界的情况下, CBAM-CNN 的表现更加可靠。

为直观地研究 CBAM-CNN 网络各层的特征学习能力, 本文利用 t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 将网络各层学习到的高维特

征进行降维, 得到如图 14 所示的二维空间的可视化图像。其中, 图 14(a) ~ 14(d) 为各个卷积模块的输出, 图 14(e) 为 FC 层的输出, 图 14(f) 为输出层的输出。

由图 14(a) 可见, 不同质量类别的特征存在一定的聚类性, 但在整个特征空间中, 各类别之间的分布杂乱且存在混叠现象, 导致类别间距较小。这种混乱的分布可能是由于特征表示的复杂性以及不同类别之间的相似性所致。

随着信号通过卷积模块 1 和卷积模块 2 并逐步传递至更深层的卷积模块, CBAM 模块引入的更深层次的关键信息得到了充分挖掘。这使得卷积模块 2 的输出特征如图 14(b) 所示, 不同类别间的分布间距显著增大, 出现了明显的可分现象, 为进一步的分类提供了更有利的条件, 这是由于 CBAM 增强了特征的区分度。值得注意的

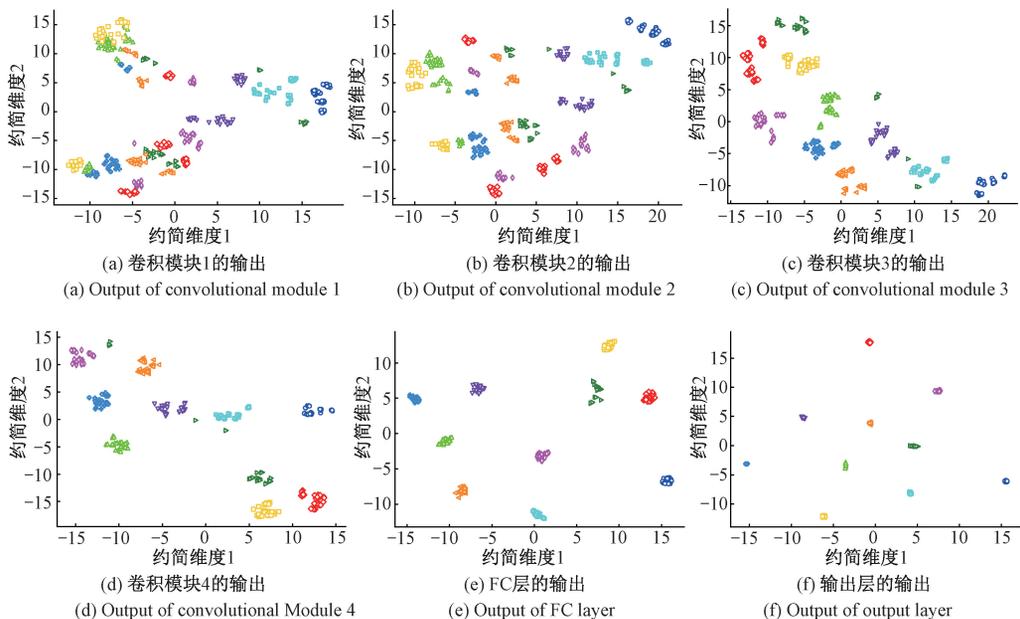


图 14 0.1 g 质量类别下第五折测试样本输入 CBAM-CNN 后的 T-SNE 可视化结果

Fig. 14 The t-SNE visualization results for the 0.1 g mass category in the fifth fold test samples input into CBAM-CNN

是,尽管各类特征间距增大,但同类特征分布仍具有一定的分散性,这表明网络在特征提取过程中保留了一定的差异性,有助于提高模型的泛化能力。

随着特征信号的进一步传递,经过卷积模块4操作,各类特征基本实现了完全可分,不同类别特征的间距再次增大,更容易区分明显,而相同类别特征的分布则呈现较强的聚合性,这表明网络在特征学习过程中进一步加强了对不同类别的区分能力,并提高了同类特征的一致性。这种特征空间的明显分离和聚合性表明网络在特征学习过程中进一步加强了对数据内在结构的理解,从而能够更好地区分不同类别的样本。

由图14(e)可见,经FC层处理后,不同类别特征分布的间距明显增大,而相同类别的聚合性则大幅提升。这表明FC层能够更好地对特征进行整合和映射,将高维特征空间中的信息转化为适合分类器处理的形式,各类特征的可分性和一致性得到进一步增强,提高了网络的分类性能和泛化能力,为最终分类输出提供了更为可靠的基础。

图15比较了CBAM-CNN和CNN的平均准确率和验证准确率。

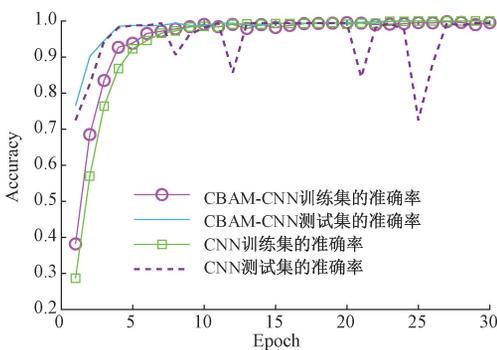


图15 CBAM-CNN和CNN准确率曲线对比

Fig. 15 Comparison of accuracy of CBAM-CNN and CNN

这两个模型的准确率都在10个epochs内迅速增加。此外,CBAM-CNN的验证准确率和训练准确率的起点和提升速率都高于CNN。而CNN的测试准确率在平台期后明显上下波动,而CBAM-CNN可以很好地稳定在高准确率水平,这表明所提出的网络在学习能力和稳定性方面优于CNN。

综上所述,相较于CNN和DNN,CBAM-CNN具有较强的自主特征挖掘和学习能力,在不同数据集上对不同类别的分类准确率均能够稳定在较高水平。此外,

CBAM-CNN在特征学习过程中能够更好地理解数据的内在结构,使得同类特征具有较强的聚合性。这表明CBAM-CNN具有更强的测量稳定性和对不同数据集的泛化能力,能够在温度不稳定的环境中更准确地捕捉到特征信息,更高效准确地完成不同质量的测量任务并实现温度解耦。

4 结 论

为解决悬臂梁结构在微小质量测量中面临的温度干扰问题,本文提出了一种基于CBAM-CNN和压电悬臂梁的自适应温度解耦质量感知方法。

1) 引入模拟可调电感电路,通过获取不同待测质量下丰富的阻抗响应信号,实现了有限样本下的数据增强,克服了深度学习对大数据集依赖的问题。

2) 自适应加权预处理方法具有出色的特征提取能力,在保留数据完整性的同时,通过放大谐振峰突出结构特征,增强了数据的物理意义。

3) 基于混合领域注意力机制的CBAM-CNN网络通过评估信号中多个谐振峰的相对关系,实现了温度解耦质量感知。实验结果表明,该方法在25℃至55℃的温度范围内对0.1g至1g的质量感知准确率高达99.70%。本方法相较于传统方法更为简单高效,无需进行温度补偿即可在大跨度温度下实现精确的质量感知,其准确性、温度解耦能力、稳定性和泛化性方面均取得了显著提升。

该创新性方法的提出填补了传统方法在实际应用中的缺陷,成功消除了温度变化对悬臂梁质量测量的严重干扰,为微小质量测量领域提供了一种高效可行的温度解耦方案。然而,本研究仍存在改进空间,例如测量结构的局限性、有限的训练数据及分辨率以及网络结构和参数的优化。后续研究可以进一步增加质量分类及改进算法,以实现大量程高分辨率的质量感知。并进一步研究该方法在其他测量结构、更大规模数据集和更复杂工况下的性能。

参考文献

- [1] BINNIG G, QUATE C F, GERBER C. Atomic force microscope [J]. American Physical Society, 1986, 56(9): 930-933.
- [2] GOTSZALK T, NIERADKA K, KOPIEC D, et al. Fabrication and metrology of electromagnetically actuated

- microcantilever arrays for biochemical sensing[C]//2012 12th IEEE International Conference on Nanotechnology (IEEE-NANO). IEEE, 2012; 1-4.
- [3] BA HASHWAN S S, KHIR M H M, NAWI I M, et al. A review of piezoelectric MEMS sensors and actuators for gas detection application [J]. Discover Nano, 2023, 18(1): 25.
- [4] KHAN U, ADNAN X, AHMED N, et al. γ -Nanofluid thermal transport between parallel plates suspended by micro-cantilever sensor by incorporating the effective Prandtl model: Applications to biological and medical sciences[J]. Molecules, 2020, 25(8): 1777.
- [5] KAUR M, LANE P M, MENON C. Scanning and actuation techniques for cantilever-based fiber optic endoscopic scanners—A review [J]. Sensors, 2021, 21(1): 251.
- [6] KURMENDRA, KUMAR R. MEMS based cantilever biosensors for cancer detection using potential bio-markers present in VOCs; A survey [J]. Microsystem Technologies, 2019, 25(9): 3253-3267.
- [7] MUNOZ-GALAN H, ALMAN C, PEREZ-MADRIGAL M M. Beyond biology: Alternative uses of cantilever-based technologies[J]. Lab on a Chip, 2023, 23(5): 1128-1150.
- [8] PHAN M T, TRINH X T, LE Q C, et al. Effect of environmental conditions on quality factors of MEMS cantilever beam resonator in gas rarefaction[J]. Sensing and Imaging, 2021, 22(1): 6.
- [9] LU S F, JIANG Y, ZHANG W, et al. Vibration suppression of cantilevered piezoelectric laminated composite rectangular plate subjected to aerodynamic force in hygrothermal environment[J]. European Journal of Mechanics-A/Solids, 2020, 83: 104002.
- [10] MOHAMED K, ELGAMAL H, KOURITEM S A. An experimental validation of a new shape optimization technique for piezoelectric harvesting cantilever beams[J]. Alexandria Engineering Journal, 2021, 60(1): 1751-1766.
- [11] YAO M, LIU P, MA L, et al. Experimental study on broadband bistable energy harvester with L-shaped piezoelectric cantilever beam [J]. Acta Mechanica Sinica, 2020, 36: 557-577.
- [12] SETIONO A, BERTKE M, NYANG'AU W O, et al. In-plane and out-of-plane MEMS piezoresistive cantilever sensors for nanoparticle mass detection [J]. Sensors, 2020, 20(3): 618.
- [13] MAHMOODI S N, JALILI N, DAQAQ M F. Modeling, nonlinear dynamics, and identification of a piezoelectrically actuated microcantilever sensor [J]. IEEE/ASME Transactions on Mechatronics, 2008, 13(1): 58-65.
- [14] JOHNSON B N, MUTHARASAN R. Biosensing using dynamic-mode cantilever sensors: A review [J]. Biosensors and bioelectronics, 2012, 32(1): 1-18.
- [15] XIAO M, XIA C, WANG D F. A mass-position sensing scheme using a geometrically adjustable resonator with low-order modals for detecting multiple analytes [J]. IEEE Transactions on Instrumentation and Measurement, 2023.
- [16] ELSEDDAWY A M, PHILLIPS A H, BAYOUMI A S. Carbon nanotube-based nanoelectromechanical resonator as mass biosensor [J]. Chinese Physics B, 2020, 29(7): 078501.
- [17] LI L, LIU H, LIU C, et al. Modal coupled vibration behavior of piezoelectric L-shaped resonator induced by added mass[J]. Nonlinear Dynamics, 2022, 109(4): 2297-2318.
- [18] SONE H, OKANO H, HOSAKA S. Picogram mass sensor using piezoresistive cantilever for biosensor[J]. Japanese Journal of Applied Physics, 2004, 43(7S): 4663.
- [19] MORTET V, PETERSEN R, HAENEN K, et al. Wide range pressure sensor based on a piezoelectric bimorph microcantilever [J]. Applied Physics Letters, 2006, 88(13): 133511.
- [20] SHIN S, SONG S, LEE Y, et al. Fabrication and sensing behavior of piezoelectric microcantilever for nanobalance[J]. Japanese Journal of Applied Physics, 2003, 42(9S): 6139.
- [21] XU T, WANG Z, MIAO J, et al. Micro-machined piezoelectric membrane-based immunosensor array [J]. Biosensors and Bioelectronics, 2008, 24(4): 638-643.
- [22] BOISEN A, DOHN S, KELLER S S, et al. Cantilever-like micromechanical sensors[J]. Reports on Progress in

- Physics, 2011, 74(3):036101.
- [23] MAROUFI M, ZIHACHEZADEH S, SHAMSHIRSAZ M, et al. Effect of thermal and mechanical properties variations on microcantilever mass sensor performance[J]. *Microsystem technologies*, 2011, 17: 575-583.
- [24] ARROYO E, JIA Y, DU S, et al. High temperature performance of a piezoelectric micro cantilever for vibration energy harvesting [C]. *Journal of Physics: Conference Series*. IOP Publishing, 2016, 773 (1): 012001.
- [25] THUNDAT T, WARMACK R J, CHEN G Y, et al. Thermal and ambient - induced deflections of scanning force microscope cantilevers [J]. *Applied Physics Letters*, 1994, 64(21) : 2894-2896.
- [26] LEE H L, FANG T H, CHANG W J. Effect of thermal vibrations on the resonant frequency of cantilever for scanning thermal microscopy nanomachining[J]. *Journal of Applied Physics*, 2009, 105(1) : 013520.
- [27] GIMZEWSKI J K, GERBER C, MEYER E, et al. Observation of a chemical reaction using a micromechanical sensor [J]. *Chemical Physics Letters*, 1994, 217(5-6) :589-594.
- [28] BUSER R A, DE ROOIJ N F. Resonant silicon structures[J]. *Sensors and Actuators*, 1989, 17(1-2) : 145-154.
- [29] SHEN F, LU P, O'SHEA S J, et al. Thermal effects on coated resonant microcantilevers [J]. *Sensors and Actuators A: Physical*, 2001, 95(1) : 17-23.
- [30] LANG H P, BERGER R, ANDREOLI C, et al. Sequential position readout from arrays of micromechanical cantilever sensors[J]. *Applied Physics Letters*, 1998, 72(3) : 383-385.
- [31] IKEHARA T, KONNO M, MURAKAMI S, et al. Integration of p-n junction diode to cantilever mass sensor for frequency drift compensation due to temperature fluctuation[J]. *Sensors and Materials*, 2011, 23(7) : 381-396.
- [32] MELAMUD R, CHANDORKAR S A, KIM B, et al. Temperature-insensitive composite micromechanical resonators [J]. *Journal of Microelectromechanical Systems*, 2009, 18(6) : 1409-1419.
- [33] SINITSIN V, IBRYAEVA O, SAKOVSKAYA V, et al. Intelligent bearing fault diagnosis method combining mixed input and hybrid CNN-MLP model [J]. *Mechanical Systems and Signal Processing*, 2022, 180: 109454.
- [34] ZHANG X, WANG H, HOU B, et al. 1D-CNN-based damage identification method based on piezoelectric impedance using adjustable inductive shunt circuitry for data enrichment [J]. *Structural Health Monitoring*, 2022, 21(5) : 1992-2009.
- [35] ZHANG X, XU J, YAN R. A structural impedance measurement method by using polyvinylidene fluoride as actuator and sensor [J]. *Review of Scientific Instruments*, 2020, 91(8).
- [36] LUAN Y, LIN S. Research on text classification based on CNN and LSTM [C]. 2019 IEEE international Conference on Artificial Intelligence and Computer Applications (ICAICA). IEEE, 2019: 352-355.
- [37] WANG H, HE J, ZHANG X, et al. A short text classification method based on N - gram and CNN[J]. *Chinese Journal of Electronics*, 2020, 29(2) : 248-254.
- [38] LELLA K K, PJA A. Automatic COVID-19 disease diagnosis using 1D convolutional neural network and augmentation with human respiratory sound based on parameters: Cough, breath, and voice[J]. *AIMS public Health*, 2021, 8(2) : 240.
- [39] OBEIDAT Y, ALQUDAH A M. A hybrid lightweight 1D CNN-LSTM architecture for automated ECG beat-wise classification[J]. *Traitement Du Signal*, 2021, 38(5).
- [40] LI Z, LIU F, YANG W, et al. A survey of convolutional neural networks: Analysis, applications, and prospects[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021.
- [41] ERTURK A, INMAN D J. An experimentally validated bimorph cantilever model for piezoelectric energy harvesting from base excitations[J]. *Smart Materials and Structures*, 2009, 18(2) : 025009.
- [42] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: A survey[J]. *Mechanical Systems and Signal Processing*, 2021, 151: 107398.
- [43] LECUN Y, BOSER B, DENKER J S, et al.

Backpropagation applied to handwritten zip code recognition[J]. *Neural Computation*, 1989, 1(4): 541-551.

- [44] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018: 3-19.
- [45] DRISS S B, SOUA M, KACHOURI R, et al. A comparison study between MLP and convolutional neural network models for character recognition[C]. *Real-Time Image and Video Processing 2017, SPIE*, 2017, 10223: 32-42.
- [46] BOTALB A, MOINUDDIN M, AL-SAGGAF U M, et al. Contrasting convolutional neural network (CNN) with multi-layer perceptron (MLP) for big data analysis[C]. *2018 International Conference on Intelligent and Advanced System (ICIAS)*, IEEE, 2018: 1-5.
- [47] ZHAO Y, WANG G, TANG C, et al. A battle of network structures: An empirical study of cnn, transformer, and mlp [J]. *Arxiv Preprint Arxiv*, 2021, 2108.13002.
- [48] WANG X, TANG J. Damage detection using piezoelectric admittance approach with inductive circuitry[J]. *Journal of Intelligent Material Systems and Structures*, 2010, 21(7): 667-676.

作者简介



闫宇楠, 2021 年于合肥工业大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为信号处理, 压电悬臂梁的质量感知及温度解耦。

E-mail: 220213644@seu.edu.cn

Yan Yunan received her B. Sc. degree from Hefei University of Technology in 2021. Now she is a M. Sc. candidate at Southeast University. Her main research interests include mechanical signal processing, mass perception and temperature decoupling of piezoelectric cantilever beams.



徐佳文(通信作者), 分别在 2009 年和 2012 年于中国科学技术大学获得学士学位和硕士学位, 2017 年于美国康涅狄格州立大学获得博士学位, 现为东南大学副研究员、博士生导师, 主要研究方向为压电振动能量采集, 压电结构故障诊断, 信号处理。

E-mail: jiawen.xu@seu.edu.cn

Xu Jiawen (Corresponding author) received his B. Sc. and M. Sc. degrees from University of Science and Technology of China in 2009 and 2012 respectively, and Ph. D. degree from University of Connecticut, USA in 2017. Now he is an associate researcher and doctoral supervisor at Southeast University. His main research interests include piezoelectric vibration energy harvesting, piezoelectric structure fault diagnosis, and signal processing.