

# 基于注意力机制和多标签 CNN 的桥梁损伤识别\*

秦世强, 苏 晟, 杨 睿

(武汉理工大学土木工程与建筑学院 武汉, 430070)

**摘要** 为解决结构多位置损伤识别中准确率低、抗噪性弱的问题,提出一种基于注意力机制(attention mechanism, 简称 AM)和多标签卷积神经网络(convolutional neural network, 简称 CNN)的结构多位置损伤识别方法。首先,以不同损伤工况之间公共损伤位置的相关性,引入注意力机制针对性地筛选数据,降低噪声对损伤识别准确率的影响,提升损伤识别准确率;其次,开展简支钢桁梁桥模型试验,设置单位置损伤、多位置损伤和混合位置损伤工况;最后,对比所提方法与传统多类别分类方法的损伤识别效果。结果表明:在多类别分类方法中,注意力机制对于损伤识别准确率最大提升 2.08%;在融合注意力机制的基础上,相较于多类别分类,多标签分类方法对于两损伤、三损伤以及多位置混合损伤的识别准确率分别提升 3.16%、4.58% 和 12.09%。所提方法具备较好的抗噪性,能有效提升多位置损伤识别的准确率。

**关键词** 桥梁工程;结构损伤识别;卷积神经网络;注意力机制;多标签分类

**中图分类号** TH7;TU317

## 引 言

作为重要的交通枢纽,桥梁结构的运营关系着人民群众的生命财产安全,及时识别桥梁结构损伤并进行提前干预,是保障桥梁安全运营的重要举措<sup>[1]</sup>。目前,桥梁结构损伤识别可分为模型驱动和数据驱动两类方法。数据驱动方法<sup>[2]</sup>可避免建立复杂的有限元模型,通过深入挖掘数据中隐含的结构损伤信息,感知结构损伤。随着机器学习和深度学习技术的快速发展,数据驱动方法的优势愈发显著,已成为结构健康监测和损伤识别的重要方向<sup>[3]</sup>。卷积神经网络等深度学习算法能够针对海量数据进行持续不断地学习,构建输出状态的估计概率模型,利用若干损伤特征信息,构建结构损伤特征与损伤状态之间的映射关系,实现结构损伤识别<sup>[4-5]</sup>。

实际工程结构的损伤具有随机性,可能在结构多个位置同时发生损伤,传统结构损伤识别方法难以识别结构多位置损伤。目前,多位置结构损伤识别主要采用多类别分类(multi-class classification, 简称 MCC)方法,该方法将每种损伤工况作为一个单独的类别。文献[6]以模态应变差作为特征输入 CNN,通过多类别分类方法实现结构单位置和两位置的损伤定位。文献[7]针对多位置损伤识别工况

数急剧增加的问题,将每一个损伤位置和特定损伤程度的组合标记为一个单独的类别,搭建多个并行的 CNN 模型进行训练并识别多位置损伤。Zhang 等<sup>[8]</sup>指出,多类别分类方法忽略了不同损伤类别之间公共损伤位置的内在相关性,导致多位置损伤识别的准确率较低。例如,2 种损伤类别存在公共位置损伤时,其公共位置损伤可能具有共同特征,合理地利用共同特征有助于提高损伤识别准确率。多位置损伤识别本质上是多标签分类(multi-label classification, 简称 MLC)问题,其中每个损伤样本包含反映结构多个损伤位置状态的各种信息。多标签分类方法已广泛应用于计算机视觉和自然语言处理等领域<sup>[9]</sup>,能够解决包含多种属性的样本分类问题,其中单个样本对应多个标签。

除了多位置损伤之间的共同特征外,影响多位置结构损伤识别准确率的另一个因素是噪声。目前,针对噪声的处理方法有 2 类:①对原始数据进行降噪<sup>[10]</sup>;②聚焦于 CNN 等深度学习框架自身抗噪能力,在提取损伤特征时降低噪声影响<sup>[11]</sup>。然而,前者在处理原始数据时可能会导致损伤特征丢失;后者降噪效果有限,特别是对于多源异构数据,其噪声来源较多,从算法本身角度难以剔除噪声影响。注意力机制在自然语言处理、语音识别及图像识别等方

\* 国家自然科学基金资助项目(51608408)

收稿日期:2023-07-13;修回日期:2023-09-25

面得到了广泛应用<sup>[12]</sup>,其核心原理是筛选对当前任务目标更具影响力的信息,并对这些信息针对性地进行加权学习。Zhang等<sup>[13]</sup>采用一种融合多级注意力机制的卷积神经网络,对利用无人机构建的道路损伤数据库进行损伤识别,能够高精度地识别出各种道路损伤状况。Wang等<sup>[14]</sup>提出一种融合注意力机制的细化网络模型,对铁路高架桥图像数据集进行损伤识别,可精确地识别铁路高架桥的损伤构件。因此,通过将注意力机制引入到结构损伤识别中,对结构振动响应信号中不同部分的重要性进行自适应调整,重点关注与损伤相关的信息,能够进一步提升结构损伤识别方法的鲁棒性和准确性。

为解决结构多位置损伤识别准确率和抗噪性问题,本研究考虑了多个位置损伤的共同特征,引入注意力机制,降低噪声对损伤识别精度的影响,提升多位置结构损伤识别准确率。在介绍CNN和注意力机制基本理论的基础上,提出融合注意力机制的多标签CNN结构损伤识别方法,开展简支钢桁架桥模型试验,并验证所提方法的有效性。

## 1 理论基础

### 1.1 卷积神经网络

CNN通过权值共享和局部连接可减少模型参数,提高计算效率,并能有效地提取数据中的特征<sup>[15]</sup>。一维卷积运算表示为

$$y_t = \sum_{k=0}^{K-1} x_{t-k} w_k + b \quad (1)$$

其中: $x$ 为输入序列; $w$ 为卷积核; $b$ 为偏置项; $K$ 为卷积核的长度; $y_t$ 为卷积后得到的特征图中的第 $t$ 个元素。

激活层能够增强神经网络表达和处理复杂非线性数据的能力,常用的激活函数有Sigmoid函数和ReLU函数,分别表示为

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$\text{ReLU}(x) = \max(0, x) \quad (3)$$

池化层能减小数据和参数数量,降低计算量和过拟合风险。批归一化层对神经网络每一层的输入进行归一化处理,可提升网络训练速度,缩短收敛过程,防止过拟合,降低参数初始化的要求,并简化网络参数调整过程。针对一个小训练批次数据 $B = \{x_1, x_2, \dots, x_i, \dots, x_n\}$ ,批归一化层的计算公式为

$$\hat{x}_i = \frac{x_i - \mu_A}{\sqrt{\sigma_A^2 + \xi}} \quad (4)$$

$$\hat{y}_i = \gamma \hat{x}_i + \beta \quad (5)$$

其中: $\mu_A, \sigma_A^2$ 分别为 $B$ 的均值与方差; $\xi$ 为非零微小量,以避免方差为零的情况; $\hat{x}_i$ 为归一化后的数据; $\gamma, \beta$ 分别为通过学习获得的参数,以增强神经网络的表达能力。

全连接层通过将上一层的所有节点连接到当前层的所有节点,实现输入与输出特征的全连接,学习特征权重并转化为预测结果。使用Adam算法进行损失函数优化,该算法使用不同的学习率参数来改进网络的训练,并且能够自动适应正在优化的损失函数。上述计算过程可表示为

$$\theta_{n+1} = \theta_n - \frac{\alpha m_n}{\sqrt{v_n} + \epsilon} \quad (6)$$

$$m_n = \beta_1 m_{n-1} + (1 - \beta_1) \nabla J(\theta_n) \quad (7)$$

$$v_n = \beta_2 v_{n-1} + (1 - \beta_2) [\nabla J(\theta_n)]^2 \quad (8)$$

其中: $n$ 为迭代次数; $\alpha$ 为学习率; $\theta$ 为参数向量; $J(\theta_n)$ 为损失函数; $\epsilon$ 为防止分母为零的安全系数; $\beta_1, \beta_2$ 为移动平均线的衰减率。

### 1.2 注意力机制

结构健康监测系统在加速度响应信号采集过程中,由于易受到环境扰动、设备精度不足等因素的影响,实际采集的数据会存在噪声,这些噪声信号在一定程度上对结构振动信号的解释产生干扰,从而掩盖可能存在的结构损伤特征信息,会影响结构损伤识别的准确性。注意力机制<sup>[16]</sup>的核心原理是筛选对当前任务目标更具影响力的信息,并对这些信息针对性地进行加权学习。因此,将注意力机制引入到结构损伤识别中,对结构振动响应信号中不同部分的重要性进行自适应调整,重点关注与损伤相关的重要信息,以提升结构损伤识别方法的鲁棒性和准确性。注意力机制的实现流程如下:首先,对卷积层所提取的特征进行全局平均池化操作,将其压缩成一维数据;其次,通过全连接层对该数据进行映射和处理,得到每个通道的重要性权重;最后,将权重应用于原始特征中,通过加权每个通道的特征,提高深度学习模型的效果。注意力机制的计算如下

$$V_j = \frac{1}{N_j} \sum_i Z_j^i \quad (9)$$

$$d_j = \text{ReLU}(W_1, V_j) \quad (10)$$

$$Q_j = \text{Sigmoid}(W_2, d_j) \quad (11)$$

$$Z_j = Q_j \cdot Z_j \quad (12)$$

其中:  $V_j$  为第  $j$  个通道压缩产生的特征信息向量;  $Z_j^i$  为第  $j$  个通道映射对应的第  $i$  个初始数据向量;  $N_j$  为单个通道的初始数据尺寸;  $W_1$  为第 1 个全连接层的参数权重矩阵;  $d_j$  为第 1 个全连接层的输出信息向量;  $W_2$  为第 2 个全连接层的参数权重矩阵;  $Q_j$  为产生的特征通道权重向量;  $Z_j$  为初始输入特征矩阵;  $Z_j'$  为依据权重向量相应生成的新特征矩阵。

图 1 为注意力机制的特征通道权重调整示意图。其中:  $C$  为特征的通道数;  $L$  为相应特征通道的特征尺寸长度。




图1 注意力机制的特征通道权重调整示意图

Fig.1 Schematic diagram of feature channel weight adjustment of attention mechanism

### 1.3 多标签分类卷积神经网络

结构损伤识别问题可以转化为分类任务。首先,将待识别的结构离散成若干个部位,收集各部位的信息特征并将其标记为不同的结构损伤类型,以建立训练数据集;其次,通过使用经过训练的 CNN 模型针对待识别损伤案例的相关信息特征进行分类,以实现结构损伤识别;最后,通过多标签 CNN 模型将结构损伤特征与损伤状态进行解耦,采用深度学习中的卷积神经网络自动化生成多个子示例,并进行多标签分类。图 2 为基于卷积神经网络的多类别分类和多标签分类示意图。所对应的标签为

$$Y = \{Y_1, Y_2, \dots, Y_i\} \quad (i = 1, 2, \dots, K) \quad (13)$$

其中:  $K$  为结构损伤位置的数量。

针对多标签分类问题,采用 Sigmoid 交叉熵损失函数,即

$$\text{Loss}_i = -\frac{1}{K} \sum_{j=1}^K y_{ij} \log(\hat{y}_{ij}) + (1 - y_{ij}) \log(1 - \hat{y}_{ij}) \quad (14)$$

其中:  $y_{ij}$  为第  $i$  个样本的第  $j$  个标签的真实值;  $\hat{y}_{ij}$  为第  $i$  个样本的第  $j$  个标签的预测值。




图2 基于卷积神经网络的多类别分类和多标签分类示意图

Fig.2 Schematic diagram of multi-class classification and multi-label classification based on convolutional neural network

## 2 结构多位置损伤识别方法

### 2.1 基本思路

针对当前损伤识别方法抗噪性能较弱的问题,本研究提出一种基于注意力机制和多标签卷积神经网络的结构损伤识别方法。融合注意力机制的多标签卷积神经网络基本架构如图 3 所示。针对传统多类别分类方法对于多位置损伤识别准确率较低的问题,该方法将结构损伤识别视为多标签分类问题,利用不同损伤工况之间公共损伤位置的相关性,提升了结构损伤识别的准确率,是一种智能且准确的结构损伤识别方法。




图3 融合注意力机制的多标签卷积神经网络基本架构

Fig.3 Basic architecture of multi-label convolution neural network with attention mechanism

基于 Pytorch 深度学习框架,分别建立 MCC 模型、AM-MCC 模型和 AM-MLC 模型。MCC 模型基本架构为:输入的原始数据依次经过 3 组不同的卷积层、池化层和批归一化层,然后展平成一维数组,再通过 2 个全连接层,最终输出结构损伤识别结果。AM-MCC 模型的主体架构与 MCC 模型一致,区别在于该模型会额外在每个批归一化层后加入注意力机制模块。2 种模型的卷积核大小均取为 3,池化层采用最大池化,在全连接层 2 中使用 Softmax 函数,其余层均使用 ReLU 函数。每个注意力机制模块中包含 2 个全连接层,第 1 个采用 ReLU 激活函数,第 2 个采用 Sigmoid 激活函数。AM-MLC 模型的基本架构与 AM-MCC 模型一致,区别在于全连接层 2 中

使用 Sigmoid 激活函数。上述 3 种卷积神经网络均采用 Adam 优化算法,学习率取为 0.001。

## 2.2 损伤识别评价指标

损伤识别方法的分类性能可以使用以下 4 个指标进行评估<sup>[17]</sup>:准确率( $F_{Acc}$ )、查准率( $F_{Pre}$ )、查全率( $F_{Rec}$ )与  $F_1$  分数( $F_{F_1}$ )。准确率表示模型正确预测的样本数量占样本总数的比例;查准率是指模型预测结果归类到某一类的样品中,实际类别是该类样品所占的比重;查全率是指全部实际类别属于某一类的样品中,正确归类到这一类样品所占的比重; $F_1$  分数为查准率与查全率之间的调和平均值,可对每个类别的分类性能进行全面的评估, $F_1$  分数越接近于 1,表明模型的分类质量越高。4 个指标的计算公式分别为

$$F_{Acc} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TP} + N_{FP} + N_{FN}} \quad (15)$$

$$F_{Pre} = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (16)$$

$$F_{Rec} = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (17)$$

$$F_{F_1} = 2 \frac{F_{Pre} F_{Rec}}{F_{Pre} + F_{Rec}} \quad (18)$$

其中: $N_{TP}$  为被分类器正确分类为该类别的样本数量; $N_{TN}$  为被分类器正确分类为非该类别的样本数量; $N_{FP}$  为被分类器错误分类为该类别的样本数量; $N_{FN}$  为被分类器错误分类为非该类别的样本数量。

## 2.3 结构损伤识别流程

基于注意力机制和多标签分类卷积神经网络进行结构损伤识别,主要步骤如下:

1) 通过结构健康监测系统、无损检测或人工检测获得结构不同损伤工况下的加速度响应数据;

2) 利用加速度响应构造多标签数据集,每个样本中包含加速度响应数据和对应的结构损伤状态,按照指定比例将数据集划分成训练集、验证集和测试集;

3) 基于 Pytorch 深度学习框架建立融合注意力机制的多标签分类卷积神经网络模型,通过训练集数据训练卷积神经网络,在训练过程中使用优化算法进行损失函数优化,不断缩小模型输出与标签之间的差距;


4) 利用验证集对模型进行评估和调整,根据验证集的准确率、损失值及收敛速度等因素,对 CNN 中的超参数进行调整,获得 CNN 的最优模型;

5) 将测试集中待识别的数据输入到最优模型中进行预测,从而获得结构损伤识别的结果。

## 3 模型试验


### 3.1 模型概况

图 4 为传感器布置示意图。图 5 为试验梁立面图。钢桁架桥模型采用 304 不锈钢制作。该模型的计算跨度为 2.4 m,将钢梁分成 8 个节间,每个节间长度为 0.3 m,主桁架高度为 0.4 m,主桁中心距为 0.4 m。上下弦杆采用等边角钢 30 mm×30 mm×2 mm,腹杆选用扁钢 20 mm×1 mm。各类杆件之间采用节点板和螺栓进行连接,所有螺栓孔直径均为 5 mm,螺栓直径为 4 mm。模型底部的一端采用铰支座,另一端采用滑动支座。



(a) 测点位置

(a) Measuring point positions



(b) 传感器布置方式

(b) Arrangement of sensors

图 4 传感器布置示意图

Fig.4 Schematic diagram of sensor layout




图 5 试验梁立面图(单位:mm)

Fig.5 Elevation of test beam (unit:mm)

试验设备包括加速度传感器和动态采集仪。加速度传感器型号为 1A202E,是一种低频压电式加速度传感器,其轴向灵敏度为 100 mV/(m·s<sup>2</sup>),量程为 ±5g,分辨率为 3×10<sup>-6</sup>g,频率响应为 0.2~1 500 Hz,采样频率为 200 Hz。在结构特定位置布加速度传感器,共计 8 个测点,采集结构在环境激励下每个指定位置处的水平加速度响应值。以上试验

设备能够准确采集结构在外部激励下的振动响应数据,并为结构损伤识别方法提供充足的数据支持。

### 3.2 损伤设置

除上下弦杆外,钢桁架桥试验模型的其余杆件均采用A、B两种类型的杆件,A型杆件长为433 mm,宽为20 mm,厚度为1 mm,作为主桁节间的斜向连接;B型杆件长为350 mm,宽为20 mm,厚度为1 mm,作为主桁架间的横向连接与竖向连接。试验中,结构损伤杆件位置如图6所示。为模拟真实结构的损伤情况,采取截面削弱的方式降低杆件的刚度,设计C、D两种类型的杆件作为损伤杆件,以便于后续损伤工况模拟和替换。




图6 结构损伤杆件位置

Fig.6 The position of structural damage members

在试验中,采集的加速度信号是获取结构损伤状态信息的重要依据。每个损伤工况测量时间至少持续480 s,但由于试验过程中需要人工更换损伤杆件等因素,测量初始阶段结构可能会受到人为扰动的影响。因此,为了保证数据质量和可靠性,试验截去原始测量数据前180 s的数据,并选取后续300 s内的实测数据作为样本,每个通道共计60 000个数据点。采用数据增强技术获取不同损伤工况下的多个样本,通过滑动窗口技术将一段信号划分成若干样本,其中窗长 $H$ 为1 000,步长 $S$ 为500,划分得到的样本个数 $M$ 为119,即每个损伤工况最终能划分为119个样本。通过数据增强技术扩充结构损伤数据库,单个样本的数据尺寸为 $8 \times 1\,000$ 。

图7为加速度传感器信号。图中为测点1、2处在同一时间段所采集到的信号,由于通过这些无规律的数据信号较难人工识别结构的损伤,因此本研究将深度学习技术应用于结构损伤识别。数据集大小分布见表1。

### 3.3 结果讨论与分析

#### 3.3.1 单损伤识别

当结构单个位置发生损伤时,损伤类别数仅有6种,对应6根杆件位置。3种方法的单位置损伤识别结果 $F_1$ 分数如图8所示。由图可知:MCC方




图7 加速度传感器信号

Fig.7 Accelerometer signal

表1 数据集大小分布

Tab.1 Dataset size distribution

损伤状况	训练集数量	验证集数量	测试集数量
单损伤	426	144	144
两损伤	1 065	360	360
三损伤	1 420	480	480




图8 3种方法的单位置损伤识别结果 $F_1$ 分数

Fig.8  $F_1$ -score of single-position damage identification results of 3 methods

法共有4个测试样本出现误判,其整体 $F_1$ 分数为0.965 1,对应的损伤识别准确率为96.53%;AM-MCC方法整体平均 $F_1$ 分数提升至0.986 0,对应的损伤识别准确率为98.61%;AM-MLC方法的单损伤识别结果整体平均 $F_1$ 分数和准确率与AM-MCC方法持平。结果表明,AM-MCC方法的损伤识别准确率比MCC方法提升了2.08%,融合注意力机制的结构损伤识别方法能更加有效地提取出结构损伤相关特征,提高了损伤识别的准确率。

3.3.2 两损伤识别

两损伤工况种类见表 2。表中列出了两位置损伤时可能出现的 15 种情况,此时损伤类别数相比于单损伤明显增加。3 种方法的两位置损伤识别结果  $F_1$  分数如图 9 所示。由图可知:MCC 方法的整体  $F_1$  分数为 0.858 0,对应的损伤识别准确率为 86.11%;AM-MCC 方法在 11 种损伤类别上的识别  $F_1$  分数优于 MCC 方法,在 2 种损伤类别上的  $F_1$  分数与 MCC 方法持平,整体平均  $F_1$  分数提升至 0.876 4,对应的损伤识别准确率为 88.06%;AM-MLC 方法在 8 种损伤类别上的损伤识别  $F_1$  分数优于 AM-MCC 方法,在 5 种损伤类别上的  $F_1$  分数与 AM-MCC 方法持平,整体平均  $F_1$  分数为 0.912 2,对应的损伤识别准确率为 91.22%。针对  $d_{205}$ (1#和 6#损伤)、 $d_{214}$ (4#和 6#损伤)和  $d_{215}$ (5#和 6#损伤)损伤工况,采用 MCC 方法和 AM-MCC 方法的误判情况较为严重,而 AM-MLC 方法能有效改善相关误判。结果表明,对于两位置损伤识别,AM-MCC 方法的损伤识别准确率比 MCC 方法提升了 1.95%,融合注意力机制的方法能有效提升结构损伤识别的准确率。此外,多标签分类方法在结构两位置损伤识别方面具有明显优势,AM-MLC 方法的损伤识别准确率比 AM-MCC 方法提升了 3.16%,能有效利用不同损伤工况之间公共损伤位置的相关性,以提升结构损伤识别的准确率。

表 2 两损伤工况种类

Tab.2 Types of two-position damage conditions

类别编号	损伤位置	杆件型号	类别编号	损伤位置	杆件型号	类别编号	损伤位置	杆件型号
$d_{201}$	1#,2#	C,C	$d_{206}$	2#,3#	C,D	$d_{211}$	3#,5#	D,C
$d_{202}$	1#,3#	C,D	$d_{207}$	2#,4#	C,C	$d_{212}$	3#,6#	D,D
$d_{203}$	1#,4#	C,C	$d_{208}$	2#,5#	C,C	$d_{213}$	4#,5#	C,C
$d_{204}$	1#,5#	C,C	$d_{209}$	2#,6#	C,D	$d_{214}$	4#,6#	C,D
$d_{205}$	1#,6#	C,D	$d_{210}$	3#,4#	D,C	$d_{215}$	5#,6#	C,D




图 9 3 种方法的两位置损伤识别结果  $F_1$  分数

Fig.9  $F_1$ -score of two-position damage identification results of 3 methods

3.3.3 三损伤识别

三损伤工况种类见表 3。表中列出了三位置损伤时可能出现的 20 种情形。3 种方法的三位置损伤识别结果  $F_1$  分数如图 10 所示。由图可知:MCC 方法的整体平均  $F_1$  分数为 0.815 0,对应的损伤识别准确率为 83.33%;AM-MCC 方法在 14 种损伤类别上的损伤识别  $F_1$  分数优于 MCC 方法,在 3 种损伤类别上的  $F_1$  分数与 MCC 方法持平,其整体平均  $F_1$  分数提升至 0.840 8,对应的损伤识别准确率为 85.21%;AM-MLC 方法在 16 种损伤类别上的损伤识别  $F_1$  分数优于 AM-MCC 方法,整体平均  $F_1$  分数为 0.897 2,对应的损伤识别准确率为 89.79%。可以看出,采用 MCC 方法和 AM-MCC 方法对于  $d_{301}$ (1#,2#,3#损伤)和  $d_{313}$ (2#,3#,6#损伤)损伤类别的误判情况较为严重,而 AM-MLC 方法能有效改善相关误判。

表 3 三损伤工况种类

Tab.3 Types of three-position damage conditions

类别编号	损伤位置	杆件型号	类别编号	损伤位置	杆件型号
$d_{301}$	1#,2#,3#	C,C,D	$d_{311}$	2#,3#,4#	C,D,C
$d_{302}$	1#,2#,4#	C,C,C	$d_{312}$	2#,3#,5#	C,D,C
$d_{303}$	1#,2#,5#	C,C,D	$d_{313}$	2#,3#,6#	C,D,D
$d_{304}$	1#,2#,6#	C,C,D	$d_{314}$	2#,4#,5#	C,C,C
$d_{305}$	1#,3#,4#	C,D,C	$d_{315}$	2#,4#,6#	C,C,D
$d_{306}$	1#,3#,5#	C,D,C	$d_{316}$	2#,5#,6#	C,C,D
$d_{307}$	1#,3#,6#	C,D,D	$d_{317}$	3#,4#,5#	D,C,C
$d_{308}$	1#,4#,5#	C,C,C	$d_{318}$	3#,4#,6#	D,C,D
$d_{309}$	1#,4#,6#	C,C,D	$d_{319}$	3#,5#,6#	D,C,D
$d_{310}$	1#,5#,6#	C,C,D	$d_{320}$	4#,5#,6#	C,C,C




图 10 3 种方法的三位置损伤识别结果  $F_1$  分数

Fig.10  $F_1$ -score of three-position damage identification results of 3 methods

3 种方法的损伤识别效果对比见表 4。对于三位置损伤识别,AM-MCC 方法的损伤识别准确率比 MCC 方法提升了 1.88%,融合注意力机制的结构损伤识别方法能有效提升损伤识别的准确率。

表4 3种方法的损伤识别效果对比

Tab.4 Comparison of damage identification effects of 3 methods

方法	单损伤		两损伤		三损伤	
	$F_1$ 分数	准确率/%	$F_1$ 分数	准确率/%	$F_1$ 分数	准确率/%
MCC	0.965 1	96.53	0.858 0	86.11	0.815 0	83.33
AM-MCC	0.986 0	98.61	0.876 4	88.06	0.840 8	85.21
AM-MLC	0.986 0	98.61	0.912 2	91.22	0.897 2	89.79

多标签分类方法在结构三位置损伤识别方面的优势更为显著,AM-MLC方法的损伤识别准确率比AM-MCC方法提升了4.58%,能够有效利用结构多位置损伤样本之间的相互联系,助力解决分类过程的混淆问题,并且随着结构损伤位置的增加,其对于损伤识别准确性的提升越显著。

### 3.3.4 多位置混合损伤识别

为了更好地适应实际工程应用,本研究考虑到结构发生损伤的位置数量具有随机性,将结构损伤数据库中的单位置损伤、两位置损伤及三位置损伤样本混合,在此基础上构建多位置损伤工况数据集,结构损伤位置种类共计有41种损伤类别。

基于AM-MCC方法的多位置混合损伤识别效果如图11所示。由图可知:该方法在单损伤识别方面的平均 $F_1$ 分数达到0.897 4,对应的损伤识别准确率达到90.28%;当结构发生两位置损伤时,其损伤识别的 $F_1$ 分数平均值为0.785 6,对应的损伤识别准确率为79.17%;当结构发生三位置损伤时,其损伤识别的 $F_1$ 分数平均值降低至0.720 8,对应的损伤识别准确率为72.50%。3种损伤情形下的分类效果差异表明,不同损伤位置样本之间的相互联系混淆了分类器的训练过程,导致分类器的准确性下降。




图11 基于AM-MCC方法的多位置混合损伤识别效果

Fig.11 Effect of multi-position mixed damage identification based on AM-MCC method

基于AM-MLC方法的多位置混合损伤识别效果如图12所示。该方法对于单位置损伤、两位置损

伤和三位置损伤的识别准确率分别为96.53%、88.89%和88.13%。AM-MCC方法和AM-MLC方法对于多位置混合损伤的整体识别准确率分别为77.54%和89.63%。结果表明:AM-MLC方法通用性强,能够有效利用不同损伤工况之间公共损伤位置的相关性,提升结构损伤识别的准确率,识别出结构多种类型的损伤。




图12 基于AM-MLC方法的多位置混合损伤识别效果

Fig.12 Effect of multi-position mixed damage identification based on AM-MLC method

在钢桁架桥模型试验中,AM-MCC方法对于单损伤、两损伤和三损伤的损伤识别准确率相比MCC方法分别提升了2.08%、1.95%和1.88%;AM-MLC对于两损伤、三损伤和多位置混合损伤的损伤识别准确率相比AM-MCC方法分别提升了3.16%、4.58%和12.09%。结果表明,融合注意力机制的结构损伤识别方法能够有效提升损伤识别的准确率。在此基础上采用多标签分类方法,能够利用不同损伤工况之间公共损伤位置的相关性,解决分类过程中的混淆问题,进一步提升结构损伤识别的准确率,所提方法具备良好的鲁棒性和泛化性能。

## 4 结论

1) 融合注意力机制的结构损伤识别方法能够有针对性地筛选与结构损伤相关的特征,提升结构损伤识别的准确率。试验结果表明,引入注意力机制后,单损伤、两损伤和三损伤的损伤识别准确率分别提升了2.08%、1.95%和1.88%。

2) 在融合注意力机制的基础上采用多标签分类方法,能够利用不同损伤工况之间公共损伤位置的相关性,进一步提升损伤识别准确率。试验结果表明,多标签方法对于两损伤、三损伤和多位置混合损伤的损伤识别准确率相比多类别方法分别提升了3.16%、4.58%和12.09%。

3) 针对结构多位置损伤特点,所提融合注意力机制和多标签CNN的损伤识别方法,能够建立公共

损伤位置的联系,降低噪声影响,提升结构损伤识别精度,具备良好的鲁棒性和泛化性能。

### 参 考 文 献

- [1] 《中国公路学报》编辑部. 中国桥梁工程学术研究综述·2021[J]. 中国公路学报, 2021, 34(2): 1-97.  
Editorial Department of China Journal of Highway and Transport. Review on China's bridge engineering research: 2021[J]. China Journal of Highway and Transport, 2021, 34(2): 1-97.(in Chinese)
- [2] 孙利民, 尚志强, 夏焯. 大数据背景下的桥梁结构健康监测研究现状与展望[J]. 中国公路学报, 2019, 32(11):1-20.  
SUN Limin, SHANG Zhiqiang, XIA Ye. Development and prospect of bridge structural health monitoring in the context of big data[J]. China Journal of Highway and Transport, 2019, 32(11):1-20. (in Chinese)
- [3] BURGOS D A T, VARGAS R C G, PEDRAZA C, et al. Damage identification in structural health monitoring: a brief review from its implementation to the use of data-driven applications[J]. Sensors, 2020, 20(3): 733.
- [4] 鲍跃全, 李惠. 人工智能时代的土木工程[J]. 土木工程学报, 2019(5):1-11.  
BAO Yuequan, LI Hui. Artificial intelligence for civil engineering[J]. China Civil Engineering Journal, 2019(5):1-11. (in Chinese)
- [5] 骆勇鹏, 王林堃, 郭旭, 等. 利用单传感器数据基于GAF-CNN的结构损伤识别[J]. 振动、测试与诊断, 2022,42(1):169-176.  
LUO Yongpeng, WANG Linkun, GUO Xu, et al. Structural damage identification using single sensor data based on GAF-CNN[J]. Journal of Vibration, Measurement & Diagnosis, 2022,42(1):169-176. (in Chinese)
- [6] LI M Y, WU Z Y, JIA D W, et al. Structural damage identification using strain mode differences by the iFEM based on the convolutional neural network (CNN)[J]. Mechanical Systems & Signal Processing, 2022, 165: 108289.
- [7] LI D, LIANG Z L, REN W X, et al. Structural damage identification under nonstationary excitations through recurrence plot and multi-label convolutional neural network[J]. Measurement, 2021, 186: 110101.
- [8] ZHANG Z M, SUN C. Multi-site structural damage identification using a multi-label classification scheme of machine learning[J]. Measurement, 2020, 154: 107473.
- [9] 武红鑫, 韩萌, 陈志强, 等. 监督和半监督学习下的多标签分类综述[J]. 计算机科学, 2022, 49(8): 12-25.  
WU Hongxin, HAN Meng, CHEN Zhiqiang, et al. Survey of multi-label classification based on supervised and semi-supervised learning [J]. Computer Science, 2022, 49(8): 12-25.(in Chinese)
- [10] CAO M S, DING Y J, REN W X, et al. Hierarchical wavelet-aided neural intelligent identification of structural damage in noisy conditions[J]. Applied Sciences, 2017, 7(4): 391.
- [11] ZHAN Y L, LU S J, XIANG T Y, et al. Application of convolutional neural network in random s-structural damage identification[J]. Structures, 2021,29:570-576.
- [12] NIU Z Y, ZHONG G Q, YU H. A review on the attention mechanism of deep learning[J]. Neurocomputing, 2021, 452:48-62.
- [13] ZHANG Y C, ZUO Z W, XU X B, et al. Road damage detection using UAV images based on multi-level attention mechanism[J]. Automation in Construction, 2022,144:104613.
- [14] WANG J J, LEI Y, YANG X J, et al. A refinement network embedded with attention mechanism for computer vision based post-earthquake inspections of railway viaduct[J]. Engineering Structures, 2023, 279: 115572.
- [15] 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.
- [16] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [17] POWERS D. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation[DB/OL]. (2020-10-11) [2021-04-20]. <https://arxiv.org/abs/2010.16061>.



**第一作者简介:**秦世强,男,1987年7月生,博士、副教授、硕士生导师。主要研究方向为结构健康监测。曾发表《A novel multi-objective function based finite element model updating of a long-span cable-stayed bridge using in-situ static and dynamic measurements》(《ASCE Journal of Bridge Engineering》2023, Vol.28, No.1)等论文。  
E-mail: shiqiangqin@whut.edu.cn