

基于生成对抗网络与声发射特征的超高性能混凝土填充钢管 短柱轴压损伤阶段智能识别

陈 正^{1,2}, 陈展鹏^{1,2}, 陈 犇^{3,4}, 杨正曦^{1,2}, 陆彦菴^{1,2}, 朱浩杰^{1,2}

(1. 广西大学土木建筑工程学院, 南宁 530004; 2. 广西大学广西防灾减灾与工程安全重点实验室, 南宁 530004;
3. 中国电建集团华东勘测设计研究院有限公司, 杭州 311100; 4. 浙江大学高性能结构研究所, 杭州 310058)

摘 要: 近年来, 深远海区域的工程建设日益增多, 极端荷载环境使得高耸塔架与海洋平台中钢管混凝土构件的损伤风险剧增。为实现对上述关键结构内部损伤程度的智能识别, 本工作提出了一种融合带梯度惩罚的 Wasserstein 生成对抗网络(WGAN-GP)与一维残差网络(1D-ResNet)的超高性能混凝土填充钢管(UHP-CFST)短柱损伤阶段智能识别方法, 以解决声发射(AE)数据类别不平衡导致的识别精度下降问题。通过对 27 根 UHP-CFST 短柱开展轴压试验, 同步采集 AE 信号, 并依据归一化累计撞击数(NCH)的演化规律, 将损伤过程划分为轻微损伤阶段 I、中度损伤阶段 II 和完全损伤阶段 III。选取上升时间、能量、持续时间、幅值、峰值频率、信号强度及约束系数等特征参数构建数据集, 采用 WGAN-GP 对少数类样本进行增强, 并结合统计特征分析、t-SNE 降维可视化及最大均值差异(MMD)检验对生成数据质量进行评估。结果表明, WGAN-GP 生成数据与原始数据在统计特征及高维特征空间分布上具有较高一致性, 能够较好保持 AE 数据的整体分布趋势与主要特征结构。在此基础上, 构建基于 ResNet 的三阶段损伤识别模型, 并与支持向量机(SVM)、多层感知机(MLP)和卷积神经网络(CNN)模型进行对比。结果表明: ResNet 在阶段 I、阶段 II 和阶段 III 的 F1 分数分别达到 91.6%、93.8% 和 94.7%, 整体识别性能优于 SVM、MLP 和 CNN 模型。研究表明: 所提出的 WGAN-GP 与 ResNet 相结合的方法能够有效提升 UHP-CFST 短柱轴压损伤阶段的智能识别性能, 为基于 AE 信号的结构损伤识别提供了新的思路。

关键词: 超高性能混凝土填充钢管; 声发射; 带梯度惩罚的 Wasserstein 生成对抗网络; 一维残差网络; 损伤识别

中图分类号: TP18; TU398 文献标志码: A 文章编号: 0454-5648(2026)10-3345-16
网络出版时间: 2026-07-29



由于钢管与混凝土之间卓越的协同效应, 钢管混凝土(CFST)构件兼具高承载力与优异的延性, 同时在抗震及防火性能方面表现出色, 因而被广泛应用于高层建筑及大跨度空间结构^[1, 2]。自 20 世纪 60 年代以来, 中国内外学者对 CFST 构件在不同服役工况下的力学行为进行了系统研究, 涵盖了静力荷载^[3, 4]、动力冲击^[5, 6]以及火灾极端环境^[7, 8]。其中, 轴压作用下构件的力学响应与损伤演化机制始终是该研究领域的核心焦点。此外, 为突破传统 CFST 构件在现代超高、大跨及严苛服役环境下的性能瓶颈, 超高性能混凝土(UHPC)逐渐取代普通混凝土^[9, 10]。UHPC 兼具超高抗压强度与高耐久性, 在同等承载需求下, 采用 UHPC 填充不仅能大幅缩减截面尺寸

与结构自重, 更在全生命周期成本与低碳环保方面展现出显著优势^[11-13]。

尽管超高性能混凝土填充钢管(UHP-CFST)构件展现出卓越的综合性能, 但外部不透明的钢管完全阻碍了对内部核心 UHPC 损伤演化过程的直接观测。随着深远海区域的发展, 工程结构所面临的极端条件工况愈发频繁, 给 CFST 结构核心混凝土造成不可逆的损伤。因此, 引入结构健康监测(SHM)技术来实现对结构损伤程度的精准预测显得尤为关键。SHM 技术高度依赖于可永久附着于结构表面进行持续监测的主、被动传感器。为避免对原结构的自重及建造成本造成负面影响, 理想的传感设备必须具备轻质、经济且非侵入性等特征。声发射(AE)

收稿日期: 2026-05-15。 修订日期: 2026-05-29。

基金项目: 国家自然科学基金面上项目(52478242); 广西科技重大专项(桂科 AA23073017)。

第一作者: 陈 正(1982—), 男, 博士, 教授。

通信作者: 陈 犇(1997—), 男, 博士。

Received date: 2026-05-15. Revised date: 2026-05-29.

First author: CHEN Zheng (1982—), male, Ph. D., Professor.

E-mail: chen Zheng@gxu.edu.cn

Correspondent author: CHEN Ben (1997—), male, Ph.D.

E-mail: chen_b13@hdec.com

技术凭借其原位被动监测与微观缺陷捕捉能力,完美契合上述苛刻条件,已成为此类构件的理想无损评估手段^[14, 15]。

AE 技术作为一种先进的无损检测(NDT)技术,能够在不破坏构件原有性能与力学完整性的前提下,原位探测结构内部缺陷并实时监测裂纹的萌生与扩展^[16, 17]。其物理本质是材料在发生局部变形或微观断裂时,内部积累的应变能以瞬态弹性波形式快速释放的动态现象^[18]。通过捕获并解析这些丰富特征的 AE 信号,可实现对材料内部断裂演化过程的精准追踪,进而深刻揭示结构的宏、微观失效机制并定量评估其损伤程度。目前,AE 技术已成功应用于监控 CFST 结构的失效过程^[19, 20]。Gao 等^[21]采用 AE 技术监测 CFST 柱在轴向压缩下的损伤演变,全面分析了包括累积能量、振幅和命中次数等特征参数,成功识别了损伤发展的不同阶段,从而提升了结构健康监测的有效性和及时性。Shen 等^[22]通过多频传感器优选、特征参数阶段划分、RA-AF 裂纹分类及表征声发射事件整体幅值分布特征的统计参数 b 值损伤评估,全面揭示了混凝土包裹式 CFST 柱界面黏结失效的损伤演化规律与微观机制。

AE 技术虽然能够实现动态监测,但传统参数分析方法(如表征声发射事件整体幅值分布特征的改进统计参数 I_b 值、撞击数等)较多依赖人工经验,且对 AE 信号中复杂非线性特征关系的表达能力有限,难以充分挖掘高维 AE 数据中的潜在损伤信息。近年来,深度学习(DL)技术在模式识别、图像分类和回归问题等领域被广泛应用^[23, 24]。相比传统方法,深度学习能够自动提取高维特征,并建立复杂数据之间的非线性映射关系,因此在结构健康监测领域逐渐受到关注。部分学者已将卷积神经网络(CNN)、循环神经网络(RNN)以及残差神经网络(ResNet)等模型应用于 AE 信号分析^[25, 26],并取得了较好的识别效果。Xu 等^[27]提出了一种损伤诊断框架,用于预测复合材料的载荷行为和剩余承载强度。结果显示,AE 信号可用于描述结构强度、退化和

损伤状态。Barile 等^[28]利用碳纤维复合材料(CFRP)复合材料不同损伤模式的声发射波形训练循环抗噪声网络(CNTN)进行损伤在线监测,得到基体开裂、分层、脱黏和纤维断裂 4 种不同损伤模式的声发射波形的 Mel 尺度谱图,作为 CIN 的训练数据和测试数据,结果发现 CIN 的整体预测准确率为 97.9%,其中纤维断裂和分层事件的预测准确率为 100%,从而验证了 CNTN 的损伤分类准确性。Sikdar 等^[29]通过连续小波变换处理以提取时频分量图,提出了一种基于卷积神经网络的深度学习架构,能够自动从扫描图图像中提取离散的损伤特征,并用来分类复合面板中的损伤源区域。

然而,在实际 AE 监测过程中,不同损伤阶段通常存在明显类别不平衡问题,目前相关研究对此关注较少。对于 UHP-CFST 短柱轴压过程而言,初始损伤阶段仅伴随少量微裂纹萌生,因此 AE 事件数量较少。

随着损伤不断发展,裂纹逐渐扩展并相互连接,AE 活动明显增强,后期阶段数据量快速增加。若直接利用不平衡数据训练深度学习模型,模型容易偏向多数类样本,从而降低少数类阶段的识别能力,尤其会影响早期损伤识别效果。此外,AE 数据本质上属于按事件触发顺序排列的离散事件序列,而非固定时间间隔采样的连续波形信号,因此需要结合 AE 事件时序特征建立适用于损伤识别的深度学习模型。

基于上述研究背景,本工作开展了 27 根 UHP-CFST 短柱轴压试验,并同步采集 AE 信号数据。首先,根据归一化累计撞击数(NCH)与荷载百分比变化规律将损伤过程划分为 3 个阶段;随后,提取 AE 特征参数并采用带梯度惩罚的 Wasserstein 生成对抗网络(Wasserstein generative adversarial network with gradient penalty, WGAN-GP)对少数类数据进行增强,以改善数据类别不平衡问题。为适应 AE 离散事件序列的时序特征,本工作进一步构建基于一维残差网络(1D-ResNet)的损伤阶段识别模型,实现不同损伤阶段的智能分类识别,整体技术路线如图 1 所示。




图 1 基于 WGAN-GP 的 AE 损伤阶段智能识别流程图

Fig. 1 Deep learning-based AE damage identification flowchart

1 实验

1.1 样本制备

开展了 27 根外径为 152 mm、高度为 456 mm 的 UHP-CFST 短柱轴心受压试验,以研究约束效应的参数影响。试验包含 3 种钢管屈服强度(Q235、Q355、Q420)与 3 种壁厚(4、6、8 mm),核心均填充 UHPC,每组设置 3 个平行试件,UHPC 配合比以及强度参数如表 1 所示。参考 GB/T 51446—2021

《钢管混凝土混合结构技术标准》及相关研究规范,各试件约束系数(ζ)分别为 Q235-4($\zeta=0.167$)、Q235-6($\zeta=0.290$)、Q235-8($\zeta=0.424$)、Q355-4($\zeta=0.252$)、Q355-6($\zeta=0.438$)、Q235-8($\zeta=0.640$)、Q420-4($\zeta=0.298$)、Q355-6($\zeta=0.518$)和 Q235-8($\zeta=0.758$)。为保障声发射监测的精准度,加载前对钢管外表面进行了专门的打磨清理。此举有效避免了受载膨胀时因表面缺陷或杂物断裂产生的虚假声学信号,确保了高信噪比及损伤演化分析的可靠性。

表 1 UHPC 配合比
Table 1 Mixture proportions of UHPC

W/B	Mixture proportion/(kg·L ⁻¹)							Steel fiber/kg	f_{cu} /MPa	E_c /GPa
	Cement P·O52.5	Water	SF	Silica sand (16–26 mesh)	Silica sand (26–40 mesh)	Silica sand (40–70 mesh)	SP			
0.18	0.96	0.21	0.20	0.63	0.21	0.21	0.04	0.16	140.04	46.32

f_{cu} is compressive strength; E_c is elastic modulus.

1.2 测试步骤

所有短柱试件的单调轴向压缩试验均在一台量程为 12 000 kN 的电液伺服万能试验机(WAW-J12000J)上完成,试验装置测试示意图如图 2 所示。




图 2 UHP-CFST 测试示意图

Fig. 2 Schematic illustration of the UHP-CFST test

为消除端部应力集中并保障载荷的均匀传递,试件上、下两端均装配了刚性端部夹具。试验全过程严格采用位移控制模式,加载初期速率设定为 1.0 mm/min;过峰值荷载后,速率提升至 2.0 mm/min。试件承受的荷载与轴向位移,分别由试验机内置的数据采集模块和外部高精度线性可变差动变压器(LVDT)同步记录。上述所有的荷载、位移电信号,均统一接入静态数据采集仪进行自动保存。试验同步搭载了美国物理声学公司(PAC)研发的 16 通道 MISTRAS 声发射监测系统,选用 R6 α 及 R15 α 型宽频带传感器,门槛设置为 40 dB,AE 信号的振幅范围为 40~100 dB。此外,试件表

面涂抹凡士林,来改善 AE 传感器与试样之间的声学耦合。

1.3 撞击结果与 AE 信号

图 3 为被测样品的归一化荷载百分比与归一化累计撞击数(NCH)的相关关系。在轴压过程中,随着荷载的增加,试样的损伤进程主要包括微裂纹的形成、扩展与相互连接,这个过程与 AE 撞击数有着明显的相关性^[19,21]。由归一化累计撞击数曲线的演化特征可知,核心 UHPC 的损伤演化过程可划分为 3 个阶段,即轻微损伤阶段 I、中度损伤阶段 II 和完全损伤阶段 III。第 I 阶段,AE 撞击率极低,NCH 曲线几乎保持水平,主要对应于核心 UHPC 内部初始孔隙、原生缺陷及微裂纹在压应力作用下的压密闭合过程,同时伴随少量局部微裂纹萌生。随着轴向荷载不断增加,试样进入第 II 阶段,NCH 呈现显著的加速上升趋势,表明核心 UHPC 内部微裂纹逐渐突破基体阻力,开始稳定扩展并逐步相互连通。临近峰值荷载时,试样进入第 III 阶段,AE 活动剧烈爆发,NCH 曲线近乎垂直上升,表明裂纹扩展由稳定状态转入不稳定状态,纤维桥接失效,最终导致结构完整性严重受损。

2 理论方法

2.1 WGAN-GP 数据增强理论

在 UHP-CFST 短柱轴压试验过程中,不同损伤阶段对应的 AE 数据量存在显著差异。由于初始损伤阶段内部仅伴随少量微裂纹萌生,其 AE 活动较弱,因此第 I 阶段采集到的有效 AE 信号数量明显




图3 归一化荷载与归一化累计撞击数相关性

Fig. 3 Correlation between normalized load and normalized cumulative hits

较少；随着荷载增加，裂纹逐渐扩展并贯通，AE事件迅速增加，使得第II、第III阶段的数据量远高于初始阶段。该现象导致构建的损伤数据集呈现明显的类别不平衡特征。通过深度学习对结构构件进行损伤识别，类别不平衡容易导致模型训练过程中对多数类样本产生偏置，从而降低少数类样本的识别能力，尤其会导致初始损伤阶段的漏判问题。因此，有效扩充少数类样本并平衡各阶段数据分布，是提高损伤识别模型泛化能力与稳定性的关键问题。

传统的数据平衡方法主要包括随机过采样、随机欠采样及SMOTE等插值类方法^[30–32]。然而，AE特征数据具有高维、非线性及强耦合等特点，传统插值方法难以准确描述复杂特征空间中的真实分布规律，容易造成生成样本缺乏多样性或偏离原始数据分布，GAN能够通过学习原始数据的潜在分布特

征，生成与真实数据高度相似的新样本^[33]，因此为解决AE少样本问题提供了一种新的思路。

2.1.1 GAN 基本原理 GAN主要由生成器(Generator)与判别器(Discriminator)两部分组成，其基本结构如图4所示。生成器以随机噪声作为输入，通过非线性映射生成伪样本；判别器则用于区分输入数据是真实样本还是生成样本。二者通过对抗训练不断优化，最终使生成器能够生成接近真实数据分布的样本。

GAN的目标函数可表示为：

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

其中： x 为来自真实数据分布 p_{data} 的样本； z 为来自先验噪声分布 p_z 的随机向量； $G(z)$ 表示生成器根据噪声 z 生成的样本； $D(\cdot)$ 表示判别器输出该样本为真实样本的概率。




图 4 GAN 结构图

Fig. 4 Architecture of the generative adversarial network (GAN)

尽管传统 GAN 在数据生成领域取得了较好效果,但其训练过程中仍存在梯度消失、训练不稳定以及模式崩塌(Mode collapse)等问题。当训练样本数量较少或数据分布复杂时,上述问题尤为明显,从而限制了 GAN 在 AE 少样本数据增强中的应用效果。

2.1.2 WGAN-GP 基本原理 为提高 GAN 训练稳定性,Arjovsky 等^[34]提出了 Wasserstein 生成对抗网络(WGAN),利用 Wasserstein 距离替代传统 GAN 中的 Jensen-Shannon 散度,以改善模型训练过程中的梯度消失问题。Wasserstein 距离能够更准确地度量真实分布与生成分布之间的差异,其表达式为:

$$W(P_r, P_g) = \sup_{\|f\|_L \leq K} [\mathbb{E}_{x \sim P_r} [f(x)] - \mathbb{E}_{z \sim p(z)} [f(G(z))]] \quad (2)$$

其中: $\sup$ 取遍所有 K-Lipschitz 函数 f ; P_r 为真实数据分布; P_g 为生成分布。当 $K=1$ 时,即为 1-Lipschitz 约束。

判别器损失函数分为 2 项,分别为 Wasserstein 距离估计项和梯度惩罚项,具体如公式为:

$$L_D = - \underbrace{\left[\mathbb{E}_{x \sim P_r} [D(x)] - \mathbb{E}_{z \sim p(z)} [D(G(z))]] \right]}_{\text{Wasserstein distance term}} + \underbrace{\lambda \cdot \mathbb{E}_{\hat{x} \sim P_{\hat{x}}} \left[(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2 \right]}_{\text{Gradient penalty term}} \quad (3)$$

其中: L_D 为判别器 D 的总损失函数; $D(\cdot)$ 为判别器输出一个分数,而非概率,其值越大表示样本越“真实”; λ 为梯度惩罚项的权重系数,是一个超参数,推荐值为 10; $\hat{x}$ 为用于计算梯度惩罚的采样点; $\nabla_{\hat{x}} D(\hat{x})$ 为判别器网络的输出相对于输入采样点 $\hat{x}$ 的梯度。

相比传统 GAN, WGAN-GP 的训练过程更加稳定,能有效缓解模式崩塌问题,更准确学习复杂高维数据分布,适用于少样本条件下的数据生成任务。因此,本工作采用 WGAN-GP 对少数类 AE 数据进行增强,以构建更加平衡的损伤阶段数据集,提高后续 ResNet 模型对不同损伤阶段的识别能力。

2.2 ResNet 损伤识别模型

AE 信号在结构损伤演化过程中具有显著的非线性与复杂时变特征,不同损伤阶段之间的 AE 参数分布存在较强耦合关系。传统 CNN 虽然能够通过局部感知与权值共享实现特征自动提取,但随着网络层数增加,容易出现梯度消失、网络退化以及深层特征提取能力不足等问题,从而影响模型对复杂损伤模式的识别性能。为提高模型对 AE 损伤特征的表达能力,本工作采用残差神经网络^[35](Residual Network)构建 UHP-CFST 短柱损伤阶段识别模型,其结果如图 5 所示。ResNet 通过引入残差学习机制,在网络中建立恒等映射(Identity mapping)快捷连接(Shortcut connection),使网络能够直接学习输入与输出之间的残差关系,从而有效缓解深层网络训练中的梯度消失与性能退化问题。




图 5 ResNet 结构图

Fig. 5 Architecture of the residual network

ResNet 的基本残差结构公式为

$$H(x) = F(x) + x \quad (4)$$

其中： x 为输入特征； $F(x)$ 为卷积层学习得到的残差映射； $H(x)$ 为残差模块输出。

ResNet 通过残差学习可显著降低网络训练难度，使深层网络能够更加充分地提取 AE 特征中的隐含损伤信息。在试件轴压损伤过程中，AE 参数随裂纹萌生、扩展及失稳演化呈现明显阶段性变化，但不同阶段之间仍存在一定特征重叠。ResNet 能够利用其深层特征提取能力，进一步挖掘 AE 参数之间的高维非线性关联特征，从而提高对不同损伤阶段的分类能力与泛化性能。以 AE 特征参数序列作为网络输入，选取与试件损伤阶段高度相关的关键 AE 参数，包括上升时间、能量、持续时间、幅值、峰值频率、信号强度；此外，不同约束系数 ζ 对声发射信号接收存在强关联性，因此也把约束系数作为考虑范围。首先通过卷积层提取局部损伤特征，随后利用残差模块实现深层特征学习，最后经全连接层与 Softmax 分类器输出损伤阶段识别结果。模型输出共对应 3 个损伤阶段，分别为轻微损伤阶段 I、中度损伤阶段 II 以及完全损伤阶段 III。

为验证 WGAN-GP 数据增强对模型性能的提升效果，分别采用原始不平衡数据集与增强后的平衡数据集进行训练，并通过精确率(Precision)、召回率(Recall)、F1-score 及混淆矩阵等指标对模型识别性能进行综合评价，其公式为：

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = \frac{2TP}{2TP + FP + FN} \quad (7)$$

其中：TP 为正确预测的正类样本数；TN 为正确预测的负类样本数；FP 为负类误判为正类的样本数；FN 为正类误判为负类的样本数。

3 基于 WGAN-GP 的 AE 数据增强

在试件轴压损伤过程中，不同损伤阶段对应的 AE 事件数量存在显著差异，AE 数据本质上属于非平稳离散事件序列，不同阶段的 AE 活动频率与特征分布差异较大。初始损伤阶段仅伴随少量微裂纹萌生，因此 AE 事件数量较少；随着损伤不断发展，

AE 活动逐渐增强，后期阶段数据量明显增加。为解决由此导致的数据类别不平衡问题，采用 WGAN-GP 对少数类 AE 数据进行增强。

3.1 WGAN-GP 模型构建

实验所提取的 AE 特征以及约束效应共包含 7 个参数，因此生成器输出维度与判别器输入维度均设置为 7。生成器输入随机噪声维度设置为 32，通过两层全连接隐藏层逐步实现特征映射，最终输出生成 AE 特征数据，生成器网络结构参数如表 2 所示。

表 2 生成器参数

Table 2 Generator parameters

Network layer	Input dimension	Output dimension	Activation function
Linear1	32	64	LeakyReLU(0.2)
Linear2	64	128	LeakyReLU(0.2)
Linear3	128	7	Tanh

其中，LeakyReLU 激活函数能够有效提高网络非线性表达能力，并缓解传统 ReLU 在训练过程中可能出现的神经元死亡问题，其负斜率参数设置为 0.2。输出层采用 Tanh 函数，将生成数据约束至归一化区间内，从而提高模型训练稳定性。判别器采用与生成器相对应的多层全连接结构，其输入为 7 维 AE 特征数据，通过逐层特征压缩输出样本评分值，用于衡量输入样本与真实数据分布之间的差异。判别器输出层未采用 Sigmoid 激活函数，而是直接输出实数评分，以满足 Wasserstein 距离优化要求。判别器网络结构参数如表 3 所示。模型训练参数设置：批次大小(Batch Size)设置为 512，随机噪声维度(Latent Dimension)设置为 32，训练轮次(Epoch)设置为 5000，判别器每训练 5 次后更新一次生成器，即 Discriminator 迭代次数设置为 5，梯度惩罚系数设置为 10。上述参数设置能够在保证训练稳定性的同时，提高生成样本对真实 AE 数据分布的拟合能力。

表 3 判别器参数

Table 3 Discriminator parameters

Network layer	Input dimension	Output dimension	Activation function
Linear1	7	128	LeakyReLU(0.2)
Linear2	128	64	LeakyReLU(0.2)
Linear3	64	1	Linear

3.2 WGAN-GP 模型训练与数据生成

模型训练数据包括上升时间、能量、持续时间、幅值、峰值频率、信号强度和约束系数，共 7 个特征参数。采用滑动事件窗口方式构建样本，

并将连续 150 个 AE 事件作为一个输入样本, 因此单个样本的数据维度为 150×7 。这里的“150 个时间步”并非固定时间间隔采样信号, 而是由连续 150 个 AE 事件构成的事件序列窗口。该窗口长度能够在保留损伤演化特征的同时, 兼顾模型训练稳定性与样本数量需求。根据损伤演化过程, 数据集被划分为 3 个损伤阶段, 随后分别采用 3 个阶段的数据对所建立的 WGAN-GP 模型进行训练, 共构建 3 个独立的 WGAN-GP 模型, 模型训练轮数均设置为 5000 轮。

训练过程中, 生成器与判别器通过对抗方式不断更新参数, 图 6 为 3 个阶段 WGAN-GP 模型的损失函数变化过程。由图 6 可见, 训练初期判别器损失波动较大, 随着训练轮数增加, 损失值逐渐减小并趋于稳定。生成器损失在训练过程中呈现周期性波动, 并在后期保持稳定变化, 该结果表明模型训练过程较为稳定, 生成器与判别器逐渐达到动态平衡状态, 表明训练已经完成。训练完成后, 使用 WGAN-GP 模型生成与真实样本高度相似的数据来扩充样本, 3 个阶段样本均扩充到 200 个。




图 6 损失函数变化

Fig. 6 Loss function fluctuation

3.3 增强数据有效性验证

为验证 WGAN-GP 生成数据的有效性,从统计特征一致性、特征空间分布一致性以及高维分布一致性 3 个方面对生成数据进行分析。首先,对原始样本与生成样本的统计特征进行了对比分析。选取上升时间、能量、持续时间、幅值、峰值频率和信号强度 6 个 AE 特征参数,分别计算 3 个损伤阶段中各特征的均值和标准差,结果如图 7~图 9 所示。结果表明,在 3 个损伤阶段内,生成样本与原始样本在各特征维度上的均值变化趋势总体一致,各特征参数的相对大小规律与原始数据基本保持一致,未出现明显偏离。其中,能量、幅值和信号强度等主要 AE 特征参数的均值差异较小,表明生成数据能够较好地保持原始 AE 数据的整体特征水平。此外,生成样本与原始样本在标准差方面也表现出较高的一致性。各损伤阶段的数据波动范围基本相近,未出现明显偏大或偏小的现象。这说明 WGAN-GP 生成的数据不仅能够较好地保持原始数据的平均特征,同时也能够有效保留数据内部的离散程度及波动特性。考虑到 AE 数据各特征之间具有较强的非

线性和随机性,生成样本仍能保持与原始数据相近的统计特征,说明模型能够较好保持 AE 数据的整体分布趋势与主要特征结构。

在统计特征分析基础上,进一步采用 *t*-SNE (*t*-distributed stochastic neighbor embedding)方法对原始数据与生成数据进行降维可视化分析。*t*-SNE 能够将原始数据与生成数据从七维特征映射到二维空间,从而更加直观地反映数据在特征空间中的分布情况。图 10 为 3 个损伤阶段以及全部样本数据的 *t*-SNE 分布结果,结果表明,在 3 个损伤阶段中,生成样本与原始样本在特征空间中的分布较为接近。两类样本在二维空间内均呈现较为均匀的分布状态,未出现明显聚类分离现象。大部分生成样本与原始样本相互交叉并重叠,说明生成数据能够较好地拟合原始数据的潜在分布特征。

对于第 I 阶段数据,由于原始样本数量较少,其数据分布相对离散。生成样本仍能够较好覆盖原始样本分布区域,没有出现明显偏移现象。对于第 II 阶段与第 III 阶段数据,生成样本与原始样本之间同样具有较高重叠度,整体分布边界基本一致。在




图 7 阶段 I 的原始数据和 GAN 数据的均值和标准差

Fig. 7 Mean and standard deviation of the original data and GAN data in stage I




图 8 阶段 II 的原始数据和 GAN 数据的均值和标准差

Fig. 8 Mean and standard deviation of the original data and GAN data in stage II




图 9 阶段 III 的原始数据和 GAN 数据的均值和标准差

Fig. 9 Mean and standard deviation of the original data and GAN data in stage III




图 10 原始和 GAN 数据的 t -SNE 可视化图
Fig. 10 t -SNE visualization of original and GAN data

全部样本的 t -SNE 结果中, 生成数据与原始数据整体混合分布, 说明 WGAN-GP 生成的数据能够较好保持不同损伤阶段之间的特征关系, 没有破坏原始数据的整体结构特征。

为了进一步验证生成数据在高维特征空间中的分布一致性, 引入最大均值差异(Maximum mean discrepancy, MMD)指标对原始数据与生成数据进行定量分析, 如表 4 所示。相比传统 KS 检验仅针对单变量边缘分布进行比较, MMD 能够将高维数据映射至再生核希尔伯特空间(RKHS), 并直接度量两组样本联合分布之间的差异, 因此更加适用于多维 AE 特征数据的分布一致性分析。

分别对 3 个损伤阶段的原始数据与生成数据进行了 MMD 检验, 并结合置换检验进行显著性分析,

检验结果如表 4 所示。结果表明, 第 II 阶段与第 III 阶段数据的 MMD 值分别为 0.019 5 与 0.004 3, 对应 p 值分别为 0.14 与 0.36, 在 5%显著性水平下均未拒绝同分布假设。这说明随着样本数量增加, WGAN-GP 能够较好学习 AE 数据的整体分布规律, 并生成与原始数据具有较高一致性的增强样本。

对于第 I 阶段数据, 由于原始样本数量较少, 仅包含 10 组数据块, 其数据分布本身存在较强随机性, 因此 MMD 检验结果在 5%显著性水平下拒绝同分布假设。说明第 I 阶段生成数据与原始数据之间仍存在一定统计差异。该结果主要与 GAN 模型对训练样本规模具有一定依赖性有关。当训练样本数量不足时, 模型较难完全学习真实数据中的全部细节特征。综合统计特征分析、 t -SNE 可视化结果

表 4 各阶段 MMD 显著性检验结果
Table 4 MMD significance test results for each stage

Stage	Sample Size	Blocks(150×7)	MMD ²	p -value	Significant?	Interpretation
1	1500	10	0.120 8	1×10^{-12}	Yes	Significant distribution difference with a small sample size
2	10 000	66	0.019 5	0.14	No	No significant distribution difference detected
3	30 000	200	0.004 3	0.36	No	Distributions are highly consistent

以及 MMD 检验结果可以看出, WGAN-GP 生成数据与原始数据在整体分布趋势、主要特征结构以及高维特征空间分布方面具有较高一致性, 能够满足后续损伤阶段识别模型的数据增强需求。

4 基于 ResNet 的损伤阶段智能识别

为进一步提高模型对 AE 损伤特征的表达能力, 本节采用 ResNet 构建损伤阶段识别模型。ResNet 在传统 CNN 的基础上引入残差连接, 通过输入与输出之间的快捷通路学习残差映射, 可有效缓解深层网络训练中的梯度消失问题, 增强模型对复杂特征的提取能力。基于增强后的 AE 特征数据, 以损伤类别为输出, 建立三阶段损伤识别模型, 实现对轻微损伤阶段 I、中度损伤阶段 II 和完全损伤阶段 III 的分类识别。

4.1 ResNet 模型构建

模型采用连续 150 个时间步构建输入样本, 每个时间步包含 7 个 AE 特征参数, 输入数据维度为 150×7 。样本首先经过初始卷积层进行特征提取, 该层卷积核大小设置为 7, 步长设置为 2, 输出通道数为 64, 用于提取较大范围的局部时序特征。卷积层后加入 BN (Batch Normalization) 层与 ReLU 激活函数, 以提高网络训练稳定性和非线性表达能力。随后采用最大池化层(Max Pooling)对特征进行降维处理, 池化核大小为 3, 步长为 2, 从而降低计算量并保留主要特征信息。为进一步提高模型对复杂 AE 特征的学习能力, 模型在主干网络中引入残差模块

(Residual Block)。残差结构通过快捷连接(Shortcut Connection)实现输入与输出之间的直接映射, 从而有效缓解深层网络训练中的梯度消失与网络退化问题, 模型共构建 3 组残差层, 分别为 Layer1、Layer2 与 Layer3, 每组残差层均由 2 个 BasicBlock 组成。Layer1 输出通道数为 64, Layer2 输出通道数为 128, Layer3 输出通道数为 256, ResNet 具体网络参数如表 5 所示。ResNet 模型的 Batch Size 设置为 64, Epoch 设置为 300, 学习率设置为 1×10^{-3} , 并采用 Adam 优化器进行参数更新。

表 5 ResNet 参数
Table 5 ResNet Parameters

Network layer	Output channels	Kernel size	Stride
Conv1	64	7	2
MaxPool	64	3	2
Layer1	64	3	1
Layer2	128	3	2
Layer3	256	3	2
GAP	256		
FC	3		

4.2 ResNet 训练及损伤阶段识别结果与分析

为验证 4.1 节中构建 ResNet 模型的损伤阶段识别能力, 采用增强后的 AE 数据集对模型进行训练、验证与测试。模型训练过程中, 分别记录训练集与验证集的损失函数(Loss)和分类精度(Accuracy)变化情况, 结果如图 11 所示。




图 11 ResNet 训练过程

Fig. 11 Training workflow

由图 11 可见, 训练初期训练集与验证集的损失值均较高, 且存在一定波动。随着训练轮数的增加, 损失值逐步下降, 并在后期趋于稳定。训练集与验证集的损失变化趋势基本一致, 表明模型在训练过程中能够逐渐学习 AE 数据中的损伤特征。与此同

时, 训练集与验证集的分类精度均随 Epoch 增加而不断提升。训练前期精度提升较为明显, 随后增长幅度逐渐减小, 并最终稳定在较高水平。训练后期两者精度差异较小, 未出现明显过拟合现象, 说明所构建模型具有较好的泛化能力。

在模型训练完成后,采用测试集对模型分类性能进行验证,并绘制损伤阶段识别混淆矩阵,如图 12 所示。同时,采用 Precision、Recall 以及 F1-score 对模型分类性能进行评价,结果如表 6 所示。

True class	I	38	2	0	95%
	II	2	38	0	95%
	III	3	1	36	90%
		88.4%	92.7%	100%	93.3%
					93.7%
		I	II	III	
		Prediction class			

图 12 ResNet 识别混淆矩阵

Fig. 12 Confusion matrix for ResNet recognition

表 6 ResNet 识别结果精确率、召回率和 F1 分数

Table 6 Accuracy, Recall, and F1-score of ResNet recognition results

Damage stage	Precision/%	Recall/%	F1-score/%
I	88.4	95	91.6
II	92.7	95	93.8
III	100.0	90	94.7

对于第 I 阶段损伤识别,模型精确率为 88.4%,召回率为 95.0%,F1 分数为 91.6%。该结果表明模型能够识别大部分第 I 阶段样本,漏检数量较少。较高的召回率说明模型对于初始损伤阶段具有较强敏感性,能够有效识别早期损伤特征。但其精确率相对较低,说明部分第 II 阶段样本被误判为第 I 阶段,即存在一定假阳性现象。对于第 II 阶段损伤识别,模型精确率为 92.7%,召回率为 95.0%,F1 分数为 93.8%。第 II 阶段各项指标均保持较高水平,同时精确率与召回率较为均衡。该结果说明模型能够较好提取第 II 阶段 AE 特征,并准确区分其与其他阶段之间的差异,整体识别效果最好。对于第 III 阶段损伤识别,模型精确率达到 100%,召回率为 90.0%,F1 分数为 94.7%。该结果表明模型对于第 III 阶段具有极高识别准确性。当模型判断样本属于第 III 阶段时,未出现误判情况,即不存在假阳性样本。但部分真实第 III 阶段样本被分类至其他阶段,

因此召回率略低。

从混淆矩阵结果可以看出,模型对 3 个损伤阶段均具有较高识别能力。其中,第 II 阶段与第 III 阶段分类效果较好。第 I 阶段与第 II 阶段之间存在少量误分类现象。这主要是由于损伤演化过程具有连续性,部分第 I 阶段后期样本与第 II 阶段初期样本在 AE 特征空间中存在一定重叠。整体结果表明,基于增强数据构建的 ResNet 模型能够有效学习 AE 特征中的损伤演化规律,并实现 UHP-CFST 短柱轴压下不同损伤阶段的精准识别。

4.3 其他模型识别结果对比

为进一步验证上述 ResNet 模型的识别性能,在相同数据集与训练条件下,分别采用支持向量机(SVM)、多层感知机(MLP)以及一维 CNN 对 3 个损伤阶段进行分类识别,并与 ResNet 模型结果进行对比分析。SVM 是一种常用的小样本分类模型,其通过构建最优分类超平面实现不同类别之间的区分;MLP 属于典型前馈神经网络,通过多层全连接结构实现非线性特征映射;CNN 则通过卷积操作提取局部时序特征,在时序信号识别中具有较好应用效果。

其中,MLP 模型由 3 层全连接隐藏层组成,隐藏层节点数分别为 512、256 和 128,并在前两层加入 Dropout 层以降低过拟合风险。输入维度为 $150 \times 7 = 1050$,输出类别数为 3。模型训练参数设置:Batch Size 为 64,Epoch 为 300,学习率为 1×10^{-3} 。CNN 模型采用两层一维卷积结构。第 1 层卷积通道数为 32,第 2 层卷积通道数为 64,每层卷积后均加入 ReLU 激活函数与最大池化层。卷积特征经 Flatten 展开后,通过全连接层输出三分类结果,CNN 模型训练参数与 ResNet 保持一致。综上所述,SVM、MLP 以及 CNN 识别的混淆矩阵如图 13 所示,3 种模型对应的识别的精确率、召回率和 F1 分数如表 7 所示。

SVM 模型对第 I 阶段识别效果较好,其精确率、召回率及 F1 分数分别为 81.6%、100%和 89.7%。但第 II 阶段与第 III 阶段识别性能下降较明显。其中,第 II 阶段 F1 分数仅为 58.0%,第 III 阶段 F1 分数为 68.3%。该结果说明 SVM 对于复杂非线性 AE 特征的表达能力有限,难以准确区分不同损伤阶段之间的高维特征差异。

MLP 模型 3 类损伤阶段的识别效果整体较低。第 I 阶段精确率为 76.3%,召回率为 72.5%,F1 分数为 74.3%;第 II 阶段 F1 分数仅为 46.7%;第 III 阶




图 13 其他模型识别混淆矩阵

Fig. 13 Confusion matrix for other models recognition

表 7 其他模型识别精确率、召回率和 F1 分数

Table 7 Accuracy, Recall, and F1-score of other models recognition results

Model	Damage stage	Precision/%	Recall/%	F1-score/%
SVM	I	81.6	100.0	89.7
	II	69.0	50.0	58.0
	III	66.7	70.0	68.3
MLP	I	76.3	72.5	74.3
	II	48.6	45.0	46.7
	III	51.1	57.5	54.1
CNN	I	41.2	100.0	58.4
	II	63.6	17.5	27.5
	III	66.7	20.0	30.8

段 F1 分数为 54.1%。由于 MLP 主要依赖全连接层进行特征学习，其对 AE 时序特征与局部关联信息的提取能力较弱，因此整体分类性能有限。

CNN 模型能够通过卷积操作提取局部时序特征，但整体识别结果仍不理想。第 I 阶段召回率达到 100%，但精确率仅为 41.2%，说明大量第 II 阶段与第 III 阶段样本被误判为第 I 阶段。第 II 阶段与第 III 阶段 F1 分数分别仅为 27.5% 和 30.8%。该结果表明传统 CNN 在处理复杂 AE 损伤特征时，容易出现特征提取不足与分类偏置问题。

相比之下，ResNet 模型在 3 个损伤阶段均取得了较高识别精度。其中，第 I 阶段、第 II 阶段与第 III 阶段 F1 分数分别达到 91.6%、93.8% 与 94.7%，整体性能明显优于 SVM、MLP 及 CNN 模型。ResNet 通过残差连接结构能够有效缓解深层网络训练中的梯度消失问题，同时增强模型对 AE 高维非线性特征的提取能力，因此能够更加准确地学习不同损伤

阶段之间的特征差异。

5 结论

应用于深远海平台与高耸塔架中的 CFST 构件，作为承受极端荷载的重要承载单元，其核心混凝土一旦发生损伤累积，将导致结构刚度、承载能力及稳定性下降。针对 AE 数据类别不平衡条件下 UHP-CFST 短柱损伤阶段识别精度受限的问题，提出了一种融合 WGAN-GP 与 1D-ResNet 的智能识别方法。依据归一化累计撞击数的演化规律，将损伤过程划分为轻微损伤阶段 I、中度损伤阶段 II 和完全损伤阶段 III，并提取 AE 特征参数构建训练数据集。针对不同损伤阶段样本数量不均的问题，采用 WGAN-GP 对少数类样本进行增强，以改善数据不平衡对模型识别性能的影响。主要结论如下：

1) WGAN-GP 生成的 AE 样本与原始样本在统计特征及特征空间分布上具有较高相似性。统计结果表明，生成样本在均值、标准差及整体变化趋势等方面与原始样本较为接近； t -SNE 与 MMD 分析结果进一步说明，生成数据能够较好保持原始 AE 数据的整体分布趋势与主要特征结构。该方法能够有效缓解原始数据集的类别不平衡问题。

2) 构建了基于 ResNet 的 3 阶段损伤识别模型，并与 SVM、MLP 和 CNN 模型进行了对比分析。结果表明，ResNet 在 3 个损伤阶段均表现出较好的识别效果，其在轻微损伤阶段 I、中度损伤阶段 II 和完全损伤阶段 III 的 F1 分数分别达到 91.6%、93.8% 和 94.7%。相比 SVM、MLP 和 CNN，ResNet 在分类精度和识别稳定性方面均具有更优表现，表明残差结构有助于增强模型对 AE 特征高维非线性关系

的表征能力, 提高不同损伤阶段的区分效果。

3) 综合分析表明, WGAN-GP 与 ResNet 相结合的方法能够有效提升 UHP-CFST 短柱轴压损伤阶段的智能识别性能, 验证了基于深度学习的 AE 信号分析方法在结构损伤识别中的可行性与应用价值。为深远海这类极端环境中的 CFST 塔架及平台安全性, 提供了基于智能损伤识别方法的有效保障。

(第二十八届中国科协年会学术论文)

参考文献:

- [1] 韩林海, 牟廷敏, 王法承, 等. 钢管混凝土混合结构设计原理及其在桥梁工程中的应用[J]. 土木工程学报, 2020, 53(5): 1–24.
HAN Linhai, MU Tingmin, WANG Facheng, et al. China Civ Eng J, 2020, 53(5): 1–24.
- [2] 钟善桐. 钢管混凝土结构在我国的应用和发展[J]. 建筑技术, 2001(2): 80–82.
ZHONG Shantong. Archit Technol, 2001(2): 80–82.
- [3] 刘威. 钢管混凝土局部受压时的工作机理研究[D]. 福建: 福州大学, 2005.
LIU Wei. Research on mechanism of concrete-filled steel tubes subjected to local compression[D]. Fujian: Fuzhou University, 2005.
- [4] JASINDA C, KONO S, MUKAI D, et al. Experimental investigation and development of design equation for circular hollow precast high-strength concrete-filled steel tube piles under uniaxial compressive loading[J]. Eng Struct, 2025, 343: 121276.
- [5] GAO W, LIAO C, ZHANG L C, et al. Behaviour of concrete-filled steel tube subjected to truck impact considering failure with cohesive zone model[J]. Thin Walled Struct, 2026, 225: 114745.
- [6] XU N, LIU Y H. Integrated algorithm for identifying failure modes and assessing reliability of concrete-filled steel tubes under lateral impact[J]. Autom Constr, 2025, 173: 106118.
- [7] 周侃. 钢管混凝土叠合柱-RC 梁节点耐火性能研究[D]. 北京: 清华大学, 2017.
ZHOU Kan. Fire performance of concrete-encased concrete filled steel tubular column-RC beam joints[D]. Beijing: Tsinghua University, 2017.
- [8] ZHANG W J, CHEN X M, YUAN X H, et al. Investigation on concrete-filled double skin steel tube columns to impact resistance post-fire[J]. J Constr Steel Res, 2026, 238: 110200.
- [9] 韦建刚, 罗霞, 陈宝春, 等. 圆高强钢管 UHPC 梁抗弯性能研究[J]. 工程力学, 2021, 38(1): 183–194.
WEI Jiangang, LUO Xia, CHEN Baochun, et al. Eng Mech, 2021, 38(1): 183–194.
- [10] ZAHRA H G, MAHMOUD N, BADR A, et al. Integrated experimental and numerical study with design code comparison for stiffened UHPC-filled steel tube columns under axial compression[J]. Structures, 2026, 88: 111917.
- [11] AMRAN M, HUANG S S, ONAIZI A M, et al. Recent trends in ultra-high performance concrete (UHPC): Current status, challenges, and future prospects[J]. Constr Build Mater, 2022, 352: 129029.
- [12] 欧阳雪, 史才军, 史金华, 等. 超高性能混凝土受压力学性能及其弹性模量预测[J]. 硅酸盐学报, 2021, 49(2): 296–304.
OUYANG Xue, SHI Caijun, SHI Jinhua, et al. J Chin Ceram Soc, 2021, 49(2): 296–304.
- [13] 史才军, 肖江帆, 曹张, 等. 材料组成对 UHPC 性能的影响[J]. 硅酸盐通报, 2013, 32(6): 1005–1011.
SHI Caijun, XIAO Jiangfan, CAO Zhang, et al. Bull Chin Ceram Soc, 2013, 32(6): 1005–1011.
- [14] 张力伟. 混凝土损伤检测声发射技术应用研究[D]. 大连: 大连海事大学, 2012.
ZHANG Liwei. Research on concrete damage detection by using acoustic emission technology[D]. Dalian: Dalian Maritime University, 2012.
- [15] BEHNIA A, CHAI H K, SHIOTANI T. Advanced structural health monitoring of concrete structures with the aid of acoustic emission[J]. Constr Build Mater, 2014, 65: 282–302.
- [16] SAEEDIFAR M, ZAROUCAS D. Damage characterization of laminated composites using acoustic emission: A review[J]. Compos Part B, 2020, 195: 108039.
- [17] XU Z W, SAMPATH S, WANG X J, et al. Review on structural health monitoring of pipeline: From perspective on acoustic based crack detection[J]. Measurement, 2026, 263: 120075.
- [18] 杨瑞峰, 马铁华. 声发射技术研究及应用进展[J]. 中北大学学报(自然科学版), 2006, 27(5): 456–461.
YANG Ruifeng, MA Tiehua. J N Univ China Nat Sci Ed, 2006, 27(5): 456–461.
- [19] XIE K Z, HUANG K, LIANG D, et al. Axial compressive damage and failure early warning method of concrete-filled steel tube with defects based on acoustic emission[J]. Structures, 2026, 86: 111411.
- [20] SHEN W, BAI H, WANG F, et al. Acoustic Emission characteristics and damage evolution of Concrete-Encased CFST columns under compressive load[J]. Eng Fract Mech, 2024, 311: 110578.
- [21] GAO P, LIU J P, WANG X D, et al. Damage evaluation and failure mechanism analysis of axially compressed square concrete-filled steel tubular columns by acoustic emission techniques[J]. Measurement, 2023, 217: 113132.
- [22] SHEN W, WANG F, LI C, et al. Revealing evolution law and failure mechanism of interface damage in concrete-encased CFST columns by acoustic emission technology[J]. J Build Eng, 2024, 93: 109792.
- [23] ZOU Z L, WANG M S, SONG B, et al. Deep learning and digital twin driven structural health monitoring of masonry structures: Progress and challenges[J]. Autom Constr, 2026, 188: 106993.
- [24] ZHENG B, YANG J, LI J Y, et al. Advances in deep learning for intelligent non-destructive spectral analysis: From preprocessing and data augmentation to interpretability, fusion, and transfer learning[J]. Trac Trends Anal Chem, 2026, 197: 118741.
- [25] DU J B, ZENG J, WANG H, et al. Using acoustic emission technique for structural health monitoring of laminate composite: A novel CNN-LSTM framework[J]. Eng Fract Mech, 2024, 309: 110447.
- [26] 郭福平. 基于深度学习的 CFRP 复合材料损伤声发射信号模式识别[D]. 黑龙江: 东北石油大学, 2023.
Guo Fuping. Pattern recognition of acoustic emissionsignals based on deep learning for CFRP composite damage[D]. Heilongjiang: Northeast Petroleum University, 2023.
- [27] XU D, LIU P F, CHEN Z P. A deep learning method for damage prognostics of fiber-reinforced composite laminates using acoustic emission[J]. Eng Fract Mech, 2022, 259: 108139.
- [28] BARILE C, CASAVOLA C, PAPPALETERA G, et al. Damage monitoring of carbon fibre reinforced polymer composites using acoustic emission technique and deep learning[J]. Compos Struct, 2022, 292: 115629.
- [29] SIKDAR S, LIU D Z, KUNDU A. Acoustic emission data based deep learning approach for classification and detection of damage-sources in a composite panel[J]. Compos Part B Eng, 2022, 228: 109450.

- [30] 石洪波, 陈雨文, 陈鑫. SMOTE 过采样及其改进算法研究综述[J]. 智能系统学报, 2019, 14(6): 1073–1083.
SHI Hongbo, CHEN Yuwen, CHEN Xin. CAAI Trans Intell Syst, 2019, 14(6): 1073–1083.
- [31] 王磊, 刘雨, 刘志中, 等. 处理不平衡数据的聚类欠采样加权随机森林算法[J]. 计算机应用研究, 2021, 38(5): 1398–1402.
WANG Lei, LIU Yu, LIU Zhizhong, et al. Appl Res Comput, 2021, 38(5): 1398–1402.
- [32] 张家伟, 郭林明, 杨晓梅. 针对不平衡数据的过采样和随机森林改进算法[J]. 计算机工程与应用, 2020, 56(11): 39–45.
ZHANG Jiawei, GUO Linming, YANG Xiaomei. Comput Eng Appl, 2020, 56(11): 39–45.
- [33] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//Advances in neural information processing systems, 2014, 27.
- [34] Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks[C]//International conference on machine learning. Pmlr, 2017: 214–223.
- [35] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 770–778.

作者贡献声明:

陈正: 设计论文框架、数据分析、撰写论文
陈展鹏: 实验测试、绘制图表、参与数据分析和撰写论文
陈桦: 项目管理、提出研究方向、修订论文
杨正曦: 参与实验测试、绘制图表
陆彦蕊: 参与实验测试
朱浩杰: 参与实验测试

Intelligent Identification of Axial Compression Damage Stages in Ultra-High-Performance Concrete-Filled Steel Tube Short Columns Based on Generative Adversarial Networks And Acoustic Emission Features

CHEN Zheng^{1,2}, CHEN Zhanpeng^{1,2}, CHEN Ben^{3,4}, YANG Zhengxi^{1,2}, LU Yansong^{1,2}, ZHU Haojie^{1,2}

(1. School of Civil Engineering and Architecture, Guangxi University, Nanning 530004, China; 2. Guangxi Key Laboratory of Disaster Prevention and Structural Safety, Guangxi University, Nanning 530004, China; 3. Powerchina Huadong Engineering Corporation Limited, Hangzhou 311100, China; 4. College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China)

Extended Abstract

Introduction Ultra-high-performance concrete-filled steel tubular (UHP-CFST) members exhibit excellent overall performance; however, the opaque outer steel tube completely prevents direct observation of the damage evolution within the UHPC core. With the continuing development of deep and distant offshore regions, engineering structures are increasingly exposed to extreme loading conditions, which can cause irreversible damage to the core concrete of CFST members. Therefore, the introduction of structural health monitoring (SHM) techniques for accurate identification of structural damage severity is particularly important for these members. Acoustic emission (AE) technology, owing to its *in situ* passive monitoring capability and sensitivity to microscopic defects, is well suited to such harsh conditions and has become an ideal nondestructive evaluation tool for this type of member. However, although AE enables dynamic monitoring, conventional parameter-based analysis methods, such as the Ib-value and hit count, still rely heavily on manual experience and have limited capability in representing the complex nonlinear relationships embedded in AE signals, which makes it difficult to fully extract the latent damage information contained in high-dimensional AE data. In recent years, deep learning (DL) has been widely applied in pattern recognition, image classification, and regression tasks. Compared with conventional methods, DL methods can automatically extract high-dimensional features and establish nonlinear mappings among complex data, and have therefore attracted increasing attention in the field of structural health monitoring. Against this background, axial compression tests were conducted on 27 UHP-CFST short columns with synchronous AE data acquisition, and an intelligent classification framework was developed to identify damage stages in the specimens.

Methods A total of 27 UHP-CFST short columns with an outer diameter of 152 mm and a height of 456 mm were tested under concentric axial compression. The test matrix included three steel grades (Q235, Q355, and Q420) and three wall thicknesses (4, 6 mm, and 8 mm), and all specimens were filled with UHPC and three replicate specimens were prepared for each group. The tests were conducted under displacement control, with a loading rate of 1.0 mm/min in the initial stage and 2.0 mm/min after the peak load was reached. The applied load and axial displacement were recorded synchronously by the built-in data acquisition module of the testing machine and external high-precision linear variable differential transformers (LVDTs), respectively. Meanwhile, a 16-channel MISTRAS acoustic emission monitoring system developed by Physical Acoustics Corporation (PAC), USA, was used to monitor crack development in the UHPC core throughout the test.

Based on the evolution of normalized cumulative hits (NCH) as a function of load percentage, the damage process was divided into three stages. AE feature parameters were subsequently extracted, and minority-class data were augmented using a Wasserstein generative adversarial network with gradient penalty (WGAN-GP) to mitigate class imbalance. Based on the augmented data, a damage-stage identification model based on a one-dimensional residual network (1D-ResNet) was further established to classify

different damage stages intelligently.

Results and discussion The AE samples generated by WGAN-GP exhibited high similarity to the original samples in terms of both statistical characteristics and feature-space distribution. For Stage I damage identification, the developed ResNet model achieved a precision of 88.4%, a recall of 95.0%, and an F1-score of 91.6%. These results indicated that the model was able to identify most Stage I samples, with relatively few missed detections. The high recall suggested that the model was highly sensitive to the initial damage stage and could effectively capture early damage features. However, the relatively lower precision indicated that some Stage II samples were misclassified as Stage I, implying the presence of a limited number of false positives. For Stage II damage identification, the model achieved a precision of 92.7%, a recall of 95.0%, and an F1-score of 93.8%. All three metrics remained at a high level, and the precision and recall were relatively well balanced. These results indicated that the model was able to effectively extract the AE characteristics of Stage II and accurately distinguish them from those of the other stages, thereby yielding the best overall identification performance. For Stage III damage identification, the model achieved a precision of 100%, a recall of 90.0%, and an F1-score of 94.7%. These results indicated that the model exhibited extremely high identification accuracy for Stage III. When a sample was classified as belonging to Stage III, no misclassification occurred, indicating the absence of false positives. However, some true Stage III samples were assigned to other stages, which led to a slightly lower recall. The confusion matrix further showed that the model exhibited strong identification capability for all three damage stages. Among them, the classification performance for Stages II and III was particularly good. A small number of misclassifications were observed between Stages I and II, which could be attributed mainly to the continuity of the damage evolution process, as some late Stage I samples and early Stage II samples exhibited a certain degree of overlap in the AE feature space.

In addition, the comparison of identification results among different models showed that the ResNet model achieved high classification accuracy across all three damage stages, with overall performance markedly superior to that of the SVM, MLP, and CNN models. Overall, the results demonstrated that the ResNet model constructed on the basis of the augmented dataset could effectively learn the damage evolution patterns embedded in the AE features and achieve accurate identification of different damage stages in UHP-CFST short columns under axial compression.

Conclusions The data generated by WGAN-GP show high consistency with the original data in terms of both statistical characteristics and the distribution in high-dimensional feature space, indicating that the overall distribution trend and the main feature structure of the AE data are well preserved. On this basis, a three-stage damage identification model based on ResNet is established and further compared with support vector machine (SVM), multilayer perceptron (MLP), and convolutional neural network (CNN) models. The results show that the F1-scores of the ResNet model for Stages I, II, and III reach 91.6%, 93.8%, and 94.7%, respectively, demonstrating overall identification performance superior to that of the SVM, MLP, and CNN models. Therefore, the proposed method combining WGAN-GP and ResNet effectively improves the intelligent identification of axial compression damage stages in UHP-CFST short columns and provides a new perspective for AE-based structural damage identification.

Keywords ultra-high-performance concrete-filled steel tubular; acoustic emission; wasserstein generative adversarial network with gradient penalty; 1D-residual network ; damage identification