

融合时域信息与SE-TCN-LSTM的火灾后锈蚀梁损伤识别*

王大龙¹, 刘才玮¹, 王鹏霏², 张鑫迪¹

(1. 青岛理工大学土木工程学院 青岛, 266520)

(2. 中国矿业大学力学与建筑工程学院 徐州, 221116)

摘要 针对于损伤识别的安全性和精确度问题,提出一种利用一维加速度时域信号对锈蚀混凝土梁进行损伤识别的方法,将时间卷积网络(temporal convolutional network,简称TCN)与长短期记忆(long short term memory,简称LSTM)神经网络相结合,并引入通道注意力机制(squeeze-and-excitation,简称SE),提出一种深度卷积时序网络长短期记忆模型,即SE-TCN-LSTM。首先,依据火灾后的锈蚀混凝土梁构件建立初始有限元模型(finite element model,简称FEM),收集火灾后的加速度时域信号及静力折减系数,构建用于模型修正及损伤识别网络训练的数据集;其次,采用深度学习方法,利用两种修正方式对有限元模型的待修正物理参数进行修正,结果表明,采用依次修正物理参数的方法误差较低、精度较高;最后,利用更新后的FEM模型获取火灾后锈蚀梁的刚度折减系数及承载力折减系数。结果发现,基于一维加速度信号的数据集训练时间较短,且具有较高的识别精度,在模型更新及损伤识别工作中的误差均控制在10%以内。

关键词 时域信号;有限元模型修正;神经网络;锈蚀混凝土梁;损伤识别

中图分类号 TU375.1;TH825

0 引言

火灾是导致建筑结构失效的主要灾害之一^[1],混凝土结构在火灾作用下通常会出现显著的静力性能退化,导致其力学性能和稳定性大幅降低。对于沿海建筑而言,钢筋锈蚀因素会进一步加剧这种性能退化,使得结构损伤评估更为复杂。近年来,随着振动测试的健康诊断技术的发展,与固有频率、模态振型及其导数、阻尼值和刚度变化相关的损伤成为主要研究内容^[2-3]。LSTM网络因其较强的时间依赖性建模能力,被广泛应用于结构振动信号分析与损伤识别的研究中。然而,LSTM在处理长序列信号时仍存在计算复杂度高、训练时间长以及对远程依赖捕捉不足等问题^[4]。理论上,时域信号特征提取能够直接反映结构在外界荷载作用下的动态响应规律,通过对加速度、速度及位移信号的时程分析,可揭示结构刚度退化与损伤演化过程。然而,网络对噪声的敏感性导致其难以有效捕捉非线性特征。随着数值模拟与神经网络技术的发展,二者在结构响应分析与特征识别中的融合优势逐渐凸显。数值

模拟可提供高质量响应数据,TCN凭借并行计算和高效特征提取能力,可实现模拟与实测信号的深度融合^[5]。

数值模型的更新任务是近年来的研究热点,在结构的模态分析、损伤识别等方面已有报道。有限元模型的准确性对结构监测和识别结果具有决定性影响^[6]。在模型精度提升方面,刘才玮等^[7]通过分步修正算法精简神经网络结构,利用精简后的神经网络对螺栓球节点网络结构进行有限元模型修正。张皓等^[8]证明细化单元网格能有效减小有限元模型的阶次误差。

目前,基于时域信号的损伤识别与数值模拟更新方法在复杂工况下仍存在精度与稳定性不足等问题。同时,在数值模拟更新与损伤识别过程中往往依赖线性假设与理想边界条件,难以准确表征火灾后锈蚀梁等非线性结构在多因素耦合作用下的真实响应特征。此外,传统数值模型更新过程存在计算量大、参数耦合性强及收敛稳定性差等问题,对初始模型依赖性较高。针对上述问题,笔者通过特征权重自适应分配与时序多尺度建模,实现了损伤识别

* 国家自然科学基金资助项目(52178487);山东省自然科学基金资助项目(ZR2021ME228)

收稿日期:2025-04-17;修回日期:2025-10-20

与数值模拟结果的深度融合,有效提高了损伤识别的灵敏度与模型修正的精度。

笔者分析了火灾后锈蚀梁的损伤机理及力学响应特征,提出一种融合动静力信息的SE-TCN-LSTM混合神经网络识别方法。首先,建立精细化有限元模型,通过动态灵敏度分析确定关键参数;其次,构建多工况参数-响应数据集,实现动静力信息融合;最后,将数据输入SE-TCN-LSTM,通过特征加权、时间卷积与时序建模完成模型修正与损伤识别。试验结果表明,该方法的识别误差控制在10%以内,较修正前降低了0~40%,为火灾后锈蚀结构的快速评估与智能诊断提供了有效路径。

1 理论背景

1.1 时间卷积网络

TCN是一种利用卷积机制处理时间序列数据的深度学习模型。该网络通过因果卷积、扩张卷积以及残差连接等设计,克服了传统循环神经网络(recurrent neural network,简称RNN)在长序列建模中易出现的梯度消失和计算效率低的问题。为了提取不同时间尺度的特征,TCN在卷积层中引入膨胀因子,在不增加网络深度的情况下扩大卷积核的感受野,从而增强模型对长时间依赖的捕获能力。TCN网络架构如图1所示。当TCN包含两层隐藏层且膨胀因子设置为1、2和4时,其感受野 R 可表示为

$$R = 1 + (k - 1) \sum_{l=0}^{L-1} d_l \quad (1)$$

其中: k 为卷积核的大小; d_l 为第 l 层的膨胀率。




图1 TCN网络架构

Fig.1 TCN network architecture

1.2 长短期记忆神经网络

LSTM作为RNN的改进形式,能够缓解训练阶段的梯度消失与梯度爆炸问题。其门控结构可动态

调节信息的记忆与更新,使模型具备较强的长期依赖建模能力。LSTM的基本单元由遗忘门、输入门和输出门组成,分别负责动态调节单元状态的更新与隐藏状态的输出。LSTM网络架构如图2所示。




图2 LSTM网络架构

Fig.2 LSTM neural network architecture

1.3 注意力机制

SE模块包含压缩和激励两个操作,通过这两个操作增强特征表达能力,以更好地提取特征信息。在压缩阶段,对输入的特征图进行全局池化操作,最终将其压缩成通道描述符。在激励阶段,通过全连接层和激活函数生成各个通道的权重。该机制利用自适应权重分配来区分通道的重要性,从而提高对核心特征的捕获效果,增强特征表示的有效性。

1.4 SE-TCN-LSTM

笔者提出一种SE-TCN-LSTM新型网络架构,用于处理时序数据。TCN通过多个卷积层并利用扩张卷积(扩张因子 d 分别为4、2和1)捕捉时序序列的特征,通过逐层缩小扩张因子,在扩展感受野的同时捕获长时序依赖关系,并结合SE注意力机制以强化特征信息。利用压缩和激励两种方式对各个通道进行注意力加权:通过全局池化生成各个通道的信息,再通过全连接层计算加权系数。利用生成的加权系数对TCN的输出进行重新标定,放大有利的特征信息,抑制干扰信息,从而提升特征的提取能力,进一步捕捉序列中的长期依赖,使网络能够学习重要的上下文信息。SE-TCN-LSTM网络架构如图3所示。

1.5 网络训练与评价

笔者采用有监督学习训练SE-TCN-LSTM网络,通过最小化预测输出与实际标签之间的误差来优化模型参数。为增强泛化能力,引入迁移学习策略,以提升火灾后锈蚀混凝土梁损伤识别的学习效果。在训练过程中采用Adam优化算法,其自适应学习率调整机制有助于提高收敛速度并稳定训练。




图 3 SE-TCN-LSTM 网络架构
Fig.3 SE-TCN-LSTM network architecture

数据采用小批量输入(批次大小为 8),训练轮次设为 100,初始学习率为 0.001。考虑到模型复杂性和计算资源限制,采用分批训练策略,并结合数据增强技术提升泛化能力。为防止过拟合,引入正则化、退出机制及早停策略。

为了从多个角度准确衡量深度学习网络模型在回归与预测任务中的表现,笔者采用了一系列典型的性能评价指标,包括均方误差(mean squared error, 简称 MSE)、平均绝对误差(mean absolute error, 简称 MAE),其表达式分别为

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

其中: n 为样本数量; y_i 为第*i*个样本的真实值; $\hat{y}_i$ 为第*i*个样本的预测值。

2 锈蚀钢筋混凝土梁有限元模型修正

2.1 火灾与动、静力试验

2.1.1 锈蚀构件的设计

锈蚀钢筋混凝土梁构件如图 4 所示,具体的构件设计见文献[9]。根据美国材料与试验协会标准^[10]中提出的方法,先用盐酸溶液清洗钢筋,再用小锤进一步清洗,去除附着在钢筋上的残余腐蚀产物,最后称重,确定总的重量损失。

质量锈蚀率的计算公式为

$$\eta_s = \frac{m_0 - m}{m_0} \quad (4)$$

其中: m_0 为钢筋在锈蚀前的质量; m 为钢筋在锈蚀后的质量。




图 4 锈蚀钢筋混凝土梁构件(单位:mm)
Fig.4 Rusted reinforced concrete beam components(unit:mm)

表 1 为受拉钢筋锈蚀结果。可以看出,测得的钢筋锈蚀率与目标锈蚀率的偏差维持在较小范围内,满足试验精度要求。

表 1 受拉钢筋锈蚀结果 Tab.1 Corrosion results of tensile steel bars			
编号	保护层厚度/mm	纵筋锈蚀率	实际锈蚀率
B-D05C20T0	20	0.05	0.049
B-D05C20T60	20	0.05	0.056
B-D05C20T120	20	0.05	0.062
B-D10C20T0	20	0.10	0.069
B-D10C20T60	20	0.10	0.091
B-D15C20T0	20	0.15	0.110
B-D15C20T60	20	0.15	0.100
B-D15C20T120	20	0.15	0.135
B-D20C20T0	20	0.20	0.141
B-D20C20T60	20	0.20	0.144

2.1.2 火灾与动力试验

为了研究火灾损伤后锈蚀构件的静力和动力性能,进行了火灾试验和振动试验。火灾试验采用 ISO 834 标准升温曲线进行升温,利用惠普安捷伦 34980A 型温度采集仪以 60 s 为间隔监测构件温度。当试件达到设定的受火温度阈值后,燃烧控制系统

自动关闭喷火口。随后,对锈蚀混凝土梁进行火灾前后的动力测试,以获取动力信息。利用配备弹性装置的DFC-2中型力锤,对试验梁跨中两侧的加载点进行精准敲击,有效激发并记录构件产生的加速度信号。采用DHDAS动态信号采集系统获取火灾后锈蚀混凝土梁的动力信息。图5为火灾炉示意图。




图5 火灾炉示意图
Fig.5 Schematic diagram of a fire furnace

2.1.3 火灾后静力试验

静载试验加载设备采用500 kN电液伺服万能试验机,通过分配梁对试件实施加载。试验采用分级加载方式。在正式加载前,先进行3次预加载,预加载水平设定为理论弯曲开裂荷载的30%。静载试验初期采用力控制方式进行加载,每级荷载增量为极限荷载的5%,即6 kN。当钢筋进入屈服阶段后,加载方式切换为位移控制,每次加载的跨中挠度增加约3 mm,直至构件破坏为止。数据采集方法参见文献[9]。同时,在试件跨中、加载点及支座处分别布置千分表,用来监测挠度变化。

2.2 火灾后锈蚀梁的初始有限元模型

2.2.1 模型参数设置

锈蚀梁构件采用ABAQUS独立建模,混凝土和垫片使用C3D8R单元,钢筋采用T3D2单元。弹簧单元刚度如图6所示。为准确反映结构状态,选择表1中列出的参数。钢筋-混凝土黏结及支撑约束由弹簧单元模拟^[11],其中:SPRING1单元用于支




图6 弹簧单元刚度
Fig.6 Spring unit stiffness

座约束(刚度 K_2 、 K_3);SPRING2单元用于钢筋-混凝土黏结(291×3个弹簧,分配三向刚度)。钢筋锈蚀导致黏结强度降低,通过调整SPRING2刚度表示,水平方向刚度(K_x)依据林红威等^[12]提出的本构关系设定,考虑外部约束和锈蚀速率 K_y 、 K_z 取最大值以防止滑动。此外,锈蚀还会减小钢筋横截面积,最终建立锈蚀钢筋的有限元模型。

2.2.2 温度场模拟及动力数据采集

为模拟火灾真实环境,对初始有限元模型施加温度场,模型待修正物理参数及取值范围如表2所示。升温环境采用ISO834标准升温曲线,详见参考文献[9]。模型参数设定时,非受火面温度固定为-273℃,并采用斯蒂芬-玻尔兹曼常数 $5.67\times 10^8\text{ W}/(\text{m}^2\cdot\text{K}^4)$ 进行精确计算。

表2 模型待修正物理参数及取值范围

Tab.2 Physical parameters and range of values to be corrected

参数	初始值	取值范围
混凝土弹性模量 $E/(10^{10}\text{ N}\cdot\text{m}^{-2})$	3.2	(2.4,3.6)
混凝土密度 $D_s/(10^3\text{ kg}\cdot\text{m}^{-3})$	2.4	(2.0,3.0)
左侧支座偏移 D_1/m	0.1	(0.05,0.15)
右侧支座偏移 D_2/m	0.1	(0.05,0.15)
黏结弹簧刚度 $K_s/(10^6\text{ N}\cdot\text{m}^{-1})$	6.0	(5.0,7.0)
左侧支座竖向刚度 $K_2/(10^{10}\text{ N}\cdot\text{m}^{-1})$	1.5	(0.6,2.5)
右侧支座竖向刚度 $K_3/(10^{10}\text{ N}\cdot\text{m}^{-1})$	1.5	(0.6,2.5)
受火时间 T/min	60	(0,120)

在动力学分析阶段,模型的基础配置与弹簧单元分析保持一致。模型单元类型由热传导单元调整为传力单元。为了模拟实际环境振动,在数值模拟软件ABAQUS的荷载模块中施加白噪声激励,白噪声信号的采样频率为100 Hz,持续时间为5 s,作用方向垂直于梁顶面。最终,通过脚本从计算结果中提取加速度时域数据。

2.3 有限元模型修正

2.3.1 修正策略

笔者选用修正物理参数的方法修正初始有限元模型。首先,根据边界条件及损伤工况建立合理的初始有限元模型,在预设的特殊位置上提取时域信号;其次,将初始有限元模型高灵敏度的物理参数及提取的时域信号作为模型修正的数据集,修正有限元模型的关键物理参数;最后,利用验证集验证模型修正方法的可行性。

2.3.2 数据集构建

笔者采用正交试验设计方法,在待修正参数的取值范围内进行均匀插值,共建立 375 个损伤工况。通过数值模拟,提取得到加速度时域信号共计 $5 \times 5 \times 4 \times 5 \times 25 = 62\,500$ 条,各损伤工况参数取值如表 3 所示。将获取的时域信号输入已建立的深度学习模型中进行分析。时域分析结果表明,不同损伤工况下锈蚀混凝土梁的加速度响应差异明显。

表 3 各损伤工况参数取值

Tab.3 The value of each damage condition setting		
参数	取值范围	工况取值间隔
混凝土弹性模量 $E/(10^{10} \text{ N}\cdot\text{m}^{-2})$	(2.4,3.6)	0.275
混凝土密度 $D_s/(10^3 \text{ kg}\cdot\text{m}^{-3})$	(2.0,3.0)	0.25
黏结弹簧刚度 $K_s/(10^6 \text{ N}\cdot\text{m}^{-1})$	(5.0,7.0)	0.5
受火时间 T/min	(0.0,120.0)	60

图 7 为不同工况下的加速度时域图,具体数据集工况编号如表 4 所示。试验参数变化在加速度时域信号中均有显著反映,说明该信号可作为模型参数修正与损伤识别的有效特征。具体而言,如图 7(b)所示,随着受火时间的延长,梁的加速度响应幅值呈上升趋势;在常温工况下(受火时间为 0 min,如图 7(a)所示),梁的加速度幅值基本保持在




图 7 不同工况下的加速度时域图

Fig.7 Time domain graph of acceleration under different operating conditions

0.045 mm/s^2 以内,当受火时间增加到 120 min 时,幅值显著增大至约 0.10 mm/s^2 。图 7(c)的结果表明,混凝土密度增加会导致加速度幅值降低(小于 0.04 mm/s^2)。此外,分析还发现,提高混凝土弹性模量同样会引起加速度响应幅值的减小。为了进一步说明上述时域结果在频域上的表现,对 D1E1K1T1 工况进行了三阶频域分析,如图 8 所示。其中:振幅为量纲一的量。

表 4 数据集工况编号

Tab.4 Dataset operating condition IDs				
编号	混凝土密度 $D_s/(10^3 \text{ kg}\cdot\text{m}^{-3})$	混凝土弹性模量 $E/(10^{10} \text{ N}\cdot\text{m}^{-2})$	黏结弹簧刚度 $K_s/(10^6 \text{ N}\cdot\text{m}^{-1})$	受火时间 T/min
D1E1K1T1	2	2.4	2.4	0
D1E1K1T3	2	2.4	2.4	120
D2E1K1T1	2.25	2.4	2.4	0




图 8 D1E1K1T1 三阶频域分析

Fig.8 Three-stage frequency domain analysis of D1E1K1T1

为增强深度学习模型对数据内部结构特征的捕获能力,并减小训练过程中的不稳定性,对提取的数据进行归一化处理,处理公式为

$$x_{\text{nom}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (5)$$

其中: $x_{\max}$ 为数据最大值; $x_{\min}$ 为数据最小值。

针对获取的完整数据集,按训练集:验证集:测试集=7:2:1的比例进行划分,用于评估模型的泛化性能。采用五折交叉验证替代单一测试集划分,以减少随机划分带来的偏差,提高模型评估的稳定性。

2.4 结果与分析

灵敏度分析用于评估物理参数对模型结构响应的影响^[13],并通过此分析方法确定待修正参数。图 9 为灵敏度分析归一化结果。其中:横坐标灵敏度为量纲一的量。可以看出,混凝土密度、弹性模量和受火时间对静态和动态载荷响应影响显著。




图 9 灵敏度分析归一化结果
Fig.9 Normalized sensitivity analysis results

有限元模型修正采用工作站进行网络训练。工作站配置为:CPU 为 2*128GB RAM Intel Xeon (R) E5 2699 v3 @ 2.30G Hz;显卡为 1*24GB Nvidia GeForce RTX 3090;编译环境为 PyCharm IDE;深度学习框架为 TensorFlow2.0。训练时,以 ABAQUS 提取的锈蚀梁加速度时域信号作为输入,待修正参数为输出目标。笔者在修正过程中对比了 2 种修正流程。不同输入方式的输出结果如图 10 所示。从图 10(a)可以看出,一次性修正参数的误差较大,其中混凝土密度的预测误差超过 50%。因此,改用逐一输出参数的训练方式,精度显著提升,误差大幅减小。最终,在锈蚀混凝土梁火灾后的识别任务中,同样采用分步输出方法以确保预测的准确性和有效性。

为了检验所提出 SE-TCN-LSTM 网络的泛化能力和修正效果,从超过 50 组独立测试数据中选取 3 组代表性工况。验证集试件模型参数如表 5 所示。这些数据未在训练阶段出现,用于独立评估模型在真实工况下的预测精度与稳定性。




图 10 不同输入方式的输出结果
Fig.10 Output results from different input methods

表 5 验证集试件模型参数

Tab.5 Model parameters for the validation specimens					
工况	$E/(10^{10} \text{ N}\cdot\text{m}^{-2})$	$D_s(10^3 \text{ kg}\cdot\text{m}^{-3})$	$K_s(10^6 \text{ N}\cdot\text{m}^{-1})$	T/min	
1	2.34	2.01	5.43	61.5	
2	2.67	2.32	5.69	93.2	
3	3.13	2.31	6.25	110.2	

将试验梁的加速度信号输入网络模型,并以物理参数作为输出。为了验证模型的修正效果,利用训练完成的网络输出参数结果。SE-TCN-LSTM 输出部分参数值如图 11 所示。结果表明,修正后模




图 11 SE-TCN-LSTM 输出部分参数值
Fig.11 SE-TCN-LSTM output parameter values

型的参数误差明显减小,工况 1 梁的弹性模量由 36.75% 降至 1.28%,误差降低了约 35.47%。

3 火灾后锈蚀梁损伤识别

3.1 静力折减系数

为验证本识别方法的实用性,笔者对火灾后锈蚀梁的静力性能折减进行预测与分析。采用抗弯承载力折减系数 γ_c 和抗弯刚度折减系数 γ_B ,来表征火灾后锈蚀混凝土梁在受火和锈蚀双重作用下的整体承载能力及刚度退化程度,即

$$\gamma_c = M_c/M_0 \tag{6}$$

其中: M_c 为锈蚀与火灾后的简支梁抗弯承载力; M_0 为未锈蚀简支梁的抗弯承载力。

$$B = s \frac{Ml_0^2}{f} \tag{7}$$

其中: B 为简支梁的刚度; M 为试验梁的残余承载力; s 为挠度系数; f 为跨中挠度; l_0 为计算跨度。

$$\gamma_B = B_c/B_0 \tag{8}$$

其中: B_c 为锈蚀和受火共同作用下简支梁的抗弯刚度; B_0 为未锈蚀、未受火简支梁的抗弯刚度。

3.2 构建损伤识别数据集

为确保静载信息模型与动态数值模型的参数一致性,将载荷施加到更新后的有限元模型。在梁跨 1/3 处施加位移载荷,并在加载点放置 2 个钢垫块以避免应力集中。参考点 RP-1 和 RP-2 与钢垫块耦合,载荷方式为位移和转动,加载方向垂直向下。

有限元模型提取的静态信息用于训练数据集。采用预定义温度场方法,导入 ISO-834 标准升温曲线下的温度数据至静力分析模型。同时,以 100 Hz 的采样频率、5 秒的持续时间施加白噪声信号,计算相同参数下的残余承载力。为确保数据集充足,划分了 480 组不同损伤工况。损伤工况设定如表 6 所示。从各损伤场景中提取加速度信号作为识别网络的输入,相应的残余刚度折减系数作为输出。表 7 为损伤工况编号的说明。

表 6 损伤工况设定

Tab.6 Damage condition setting		
损伤参数	取值范围	取值间隔
钢筋锈蚀率/%	(0.0,20.0)	1
受火时间/min	(0.0,120.0)	5

表 7 损伤工况编号的说明

Tab.7 Description of damage condition numbers			
编号	锈蚀率/%	保护层厚度/mm	受火时间/min
B-D00C20T60	0	20	60
B-D00C20T120	0	20	120
B-D05C20T60	5	20	60
B-D05C20T120	5	20	120

3.3 消融试验

3.3.1 不同主干网络试验分析

为体现所提出模型在损伤诊断任务中的效果,笔者将 LSTM、MobileNetV2、VGG16、ResNet50、Transformer 等神经网络模型用于静力折减系数的损伤识别任务中。其中:VGG16 为标准卷积神经网络结构;MobileNetV3、ResNet50 为轻量化模型;LSTM 为时序特征提取模型,具有较强的时间依赖建模能力。

不同骨干网络的消融试验结果如表 8 所示,其中损伤工况编号说明见表 7。可以看出,LSTM 模型在各项指标上表现良好,其相对误差和 MSE 均取得了较好的效果。与 ResNet50 相比,LSTM 的平均相对误差降低约 0.22%,MSE 减小 0.000 1;与 VGG16 相比,LSTM 的平均相对误差降低约 2.3%,MSE 减小 0.002 1。同时,由识别结果可知,锈蚀率大于 10% 且受火时间大于 60 min 的工况识别误差相对较大。这可能是由于复杂工况干扰了构件动力信息采集的稳定性,使修正后的 FEM 与真实构件产生差异,从而导致后续折减系数识别工作的误差较高。

表 9 为参数量与训练时间的对比结果。相比

表 8 不同骨干网络的消融试验结果

Tab.8 The ablation test results of different backbone networks					
模型	相对误差/%				MSE
	B-D00 C20T60	B-D00 C20T120	B-D05 C20T60	B-D05 C20T120	
LSTM	−2.51	3.00	−3.52	2.10	2.7×10^{-3}
Mobile- NetV2	−3.42	4.10	−4.25	3.27	3.4×10^{-3}
VGG16	−4.85	5.32	−6.10	4.76	4.8×10^{-3}
ResNet50	−2.73	3.65	−3.55	2.88	2.8×10^{-3}
Trans- former	−2.15	2.96	−2.72	2.04	2.3×10^{-3}

表 9 各模型参数数量与训练时间对比
Tab.9 Comparison of parameter quantity and training time

模型	参数数量	训练时间/s
LSTM	2.5×10^6	190
MobileNetV2	3.4×10^6	180
VGG16	1.384×10^8	890
ResNet50	2.56×10^7	210
Transformer	1.15×10^7	230

MobileNetV2,所提出模型的参数量减少约 26.5%,训练时间仅略增 5.6%。

3.3.2 TCN 模块优越性

为解决 LSTM 网络在消融试验中表现不足和训练时间过长的缺陷,笔者引入了 TCN 网络模块。TCN 模块的消融试验结果如表 10 所示。相较于 LSTM 网络,TCN-LSTM 网络的相对误差与 MSE 分别降低了 1.02% 和 14.81%。

表 10 TCN 模块的消融试验结果
Tab.10 The ablation experiment results of the TCN module

模型	相对误差/%				MSE
	B-D00	B-D00	B-D05	B-D05	
	C20T60	C20T120	C20T60	C20T120	
LSTM	-2.51	3.00	-3.52	2.10	2.7×10^{-3}
TCN-LSTM	-2.30	2.80	-3.30	1.95	2.3×10^{-3}

3.3.3 SE 注意力机制模块

SE 注意力模块的消融试验结果如表 11 所示。加入 SE 注意力模块后,与 TCN-LSTM 相比,SE-TCN-LSTM 方法在 MSE 与相对误差方面均有明显降低。

表 11 SE 注意力模块的消融试验结果
Tab.11 The ablation experiment results of the SE attention module

模型	相对误差/%				MSE
	B-D00C	B-D00C	B-D05C	B-D05C	
	20T60	20T120	20T60	20T120	
TCN-LSTM	-2.30	2.80	-3.30	1.95	2.3×10^{-3}
SE-TCN-LSTM	-2.20	2.70	-3.10	1.85	2.1×10^{-3}

训练损失曲线如图 12 所示。可以看出,加速收敛效果较为明显,模型的预测精度逐步上升,这说明该模型表现较为理想。




图 12 训练损失曲线
Fig.12 Training loss curve

3.4 对比试验

表 12 为所提出模型与其他模型在锈蚀梁火灾静载试验数据集上的对比分析结果。对比模型包括 SE-TCN-LSTM、门控循环单元 (gated recurrent unit,简称 GRU)、卷积神经网络-长短期记忆网络 (convolutional neural network-long short term memory,简称 CNN-LSTM)及双向长短期记忆网络 (bidirectional long short term memory,简称 BiLSTM)。

表 12 模型对比分析结果
Tab.12 The results of the network comparison test

模型	相对误差/%				MSE
	B-D00C	B-D00C	B-D05C	B-D05C	
	20T60	20T120	20T60	20T120	
SE-TCN-LSTM	-1.86	2.71	-3.08	1.82	2.1×10^{-3}
GRU	-2.10	3.00	-3.20	2.05	2.3×10^{-3}
CNN-LSTM	-2.30	3.20	-3.40	2.10	2.5×10^{-3}
BiLSTM	-2.50	3.30	-3.50	2.20	2.7×10^{-3}

由表 12 可以看出,笔者提出的方法在自制数据集上的 MSE 为 2.1×10^{-3} ,表明模型具有优异的综合性能。

4 结 论

1) 提出的 SE-TCN-LSTM 神经网络模型能够有效融合火灾后锈蚀梁的动静力信息,通过一维加速度时域信号实现了高精度的损伤识别。试验结果表明,该方法在模型修正和损伤识别任务中的误差均控制在 10% 以内,显著提升了传统方法的识别精度。

2) 采用分步修正策略对有限元模型物理参数进行依次修正,相较于一次性修正参数,可将关键参数(如混凝土弹性模量)的预测误差降低 35% 以上,

验证了分步修正策略在提升模型精度方面的有效性。

3) 笔者提出的方法在自制数据集上的MSE为 2.1×10^{-3} ,模型的综合性能优异。此外,消融试验和对比试验的结果表明,所提出模型在不同骨干网络及模块的消融试验中均展现出明显优势,尤其在损伤识别任务的准确性和稳定性方面,优于其他传统及现代神经网络模型。

4) 基于正交试验设计构建的损伤工况数据集为模型训练提供了充分的数据支撑,为火灾后简支锈蚀梁的损伤评估提供了可靠的技术手段。

5) 本研究的有限元模型及网络训练数据均基于简支边界条件,尚未对连续梁、悬臂梁及复杂约束体系进行验证,模型在不同支撑形式下的适用性仍有待进一步研究。

参 考 文 献

- [1] RADZI N A M, HAMID R, MUTALIB A A, et al. A review of the structural fire performance testing methods for beam-to-column connections[J]. *Advances in Civil Engineering*, 2021(1): 5432746.
- [2] CAO H X, LIU Z A, XU X, et al. Vibration-based methods for local damage identification of breathing cracks in truss-like structures[J]. *Journal of Sound and Vibration*, 2024, 592: 118646.
- [3] SHI T, LOU P, YANG T Y. Optimized machine learning methods for identifying the stiffness loss of CRTS-II slab track based on vehicle vibration signals[J]. *Advanced Engineering Informatics*, 2024, 62: 102886.
- [4] GUI T, ZHANG Q, ZHAO L J, et al. Long short term memory with dynamic skip connections[EB/OL]. (2018-11-09)[2025-02-13]. <https://arxiv.org/abs/1811.03873>.
- [5] XUE G X, MIAO J L, ZHANG D, et al. Seismic acceleration response prediction method of the PSCFST bridge based on TCN[J]. *Journal of Constructional Steel Research*, 2025, 224: 109147.
- [6] EREIZ S, DUVNJAK I, JIMÉNEZ-ALONSO J F, et al. REVIEW of finite element model updating methods for structural applications[J]. *Structures*, 2022, 41: 684-723.
- [7] 刘才玮, 张毅刚, 吴金志. 考虑螺栓球节点半刚性的网格结构有限元模型修正研究[J]. *振动与冲击*, 2014, 33(6): 35-39.
- LIU Caiwei, ZHANG Yigang, WU Jinzhi. Finite element model updating of lattice structures considering semi-rigid bolted spherical joints[J]. *Journal of Vibration and Shock*, 2014, 33(6): 35-39. (in Chinese)
- [8] 张皓, 李东升, 李宏男. 有限元模型修正研究进展: 从线性到非线性[J]. *力学进展*, 2019, 49(1): 542-575. ZHANG Hao, LI Dongsheng, LI Hongnan. Recent progress on finite element model updating: from linearity to nonlinearity[J]. *Advances in Mechanics*, 2019, 49(1): 542-575. (in Chinese)
- [9] BA G Z, WU W J, LIU C W, et al. Residual flexural capacity of corroded reinforced concrete beams after exposure to fire[J]. *Structures*, 2024, 61: 105991.
- [10] ASTM. ASTM G1-25 Standard practice for preparing, cleaning, and evaluating corrosion test specimens[S]. Pennsylvania, USA: American Society for Testing and Materials, 2003.
- [11] 何化南, 陈西嫻, 杨嫻嫻. 不同钢筋位置下锈蚀钢筋混凝土梁粘结性能分析[J]. *哈尔滨工程大学学报*, 2023, 44(10): 1720-1731. HE Huanan, CHEN Xixian, YANG Manman. Analysis of bond-slip performance between corroded steel bars and concrete at different positions of steel bars[J]. *Journal of Harbin Engineering University*, 2023, 44(10): 1720-1731. (in Chinese)
- [12] 林红威, 赵羽习. 变形钢筋与混凝土黏结性能研究综述[J]. *建筑结构学报*, 2019, 40(1): 11-27. LIN Hongwei, ZHAO Yuxi. Bond behavior between concrete and deformed steel bar: a review[J]. *Journal of Building Structures*, 2019, 40(1): 11-27. (in Chinese)
- [13] 刘才玮, 赵元元, 黄绪宏, 等. 基于动力测试的简支梁模型修正与参数分析[J]. *振动、测试与诊断*, 2022, 42(2): 394-401. LIU Caiwei, ZHAO Yuanyuan, HUANG Xuhong, et al. Model updating and parameter analysis of a simply supported beam based on dynamic testing[J]. *Journal of Vibration, Measurement & Diagnosis*, 2022, 42(2): 394-401. (in Chinese)



第一作者简介:王大龙,男,2001年4月生,硕士生。主要研究方向为结构抗火。
E-mail:15806877844@163.com

通信作者简介:刘才玮,男,1983年1月生,博士、教授。主要研究方向为结构抗火。
E-mail:03150053@163.com