

DOI: 10.3969/j.issn.1671-0673. 2026. 03. 016

# 面向建筑爆炸毁伤的 GraphSAGE-LSTM 实时仿真模型

陈卓<sup>1</sup>, 陈刚<sup>1</sup>, 徐铮<sup>1</sup>, 程远航<sup>1</sup>, 施金宏<sup>1</sup>, 雷添程<sup>2</sup>

(1. 信息工程大学, 河南 郑州 450001; 2. 32021 部队, 北京 100080)

**摘要:** 针对老旧建筑物爆炸毁伤多方案评估中传统有限元法耗时过长问题, 提出一种结合图采样聚合(GraphSAGE)和长短期记忆网络(LSTM)的爆炸毁伤实时仿真模型。首先, 利用空间立体网格对建筑物数据进行剖分, 并将剖分后的建筑物网格导入 Abaqus 有限元仿真软件, 构建爆炸毁伤高精度数据集; 其次, 利用 GraphSAGE 和 LSTM 分别实现对建筑物空间特征的刻画, 以及爆炸毁伤时间特征的演化; 最后, 通过多任务解码器实现位移场与失效状态的联合时序预测。实验结果证明, 该模型的建筑物位移预测精度在 96% 以上, 毁伤识别 PR-AUC 在 95% 以上, 计算速度与有限元法相比加速近 40 倍。

**关键词:** 城市更新; 建筑爆炸毁伤; 图采样聚合; 长短期记忆网络; 时空建模; 实时仿真

中图分类号: TP391.9

文献标识码: A

文章编号: 1671-0673(2026)03-0362-09

## A GraphSAGE-LSTM Real-Time Simulation Model for Building Blast Damage

CHEN Zhuo<sup>1</sup>, CHEN Gang<sup>1</sup>, XU Zheng<sup>1</sup>, CHENG Yuanhang<sup>1</sup>, SHI Jinhong<sup>1</sup>, LEI Tiancheng<sup>2</sup>

(1. Information Engineering University, Zhengzhou 450001, China; 2. Unit 32021, Beijing 100080, China)

**Abstract:** To address the high computational cost of the traditional finite element method in the multi-scenario assessment of aging building blast damage, a real-time simulation model of blast damage based on graph sample and aggregate (GraphSAGE) and long short-term memory (LSTM) is proposed. Firstly, the spatial three-dimensional grid is used to segment the building data, and the decomposed building grid is imported into Abaqus finite element simulation software to construct a high-precision dataset of blast damage. Secondly, GraphSAGE is employed to capture building spatial features, while LSTM is used to model the temporal features evolution of blast damage. Finally, a multi-task decoder is introduced to achieve joint temporal prediction of displacement fields and failure states. Experimental results demonstrate that the proposed model maintains building displacement prediction accuracy above 96% and damage identification PR-AUC above 95%, while achieving a computational speed nearly 40 times higher than that of the finite element method.

**Key words:** urban renewal; building blast damage; GraphSAGE; LSTM; spatiotemporal modeling; real-time simulation

随着城市更新进程的不断推进, 大量老旧房屋亟需进行安全高效的拆除与重建, 定向爆破作为房屋拆除中的重要工程手段, 其实施过程对周边环境安全以及施工风险管控提出了更高要求。

因此, 准确、可靠地获取建筑物在爆炸过程中的位移响应与毁伤分布信息, 是城市更新老旧房屋爆炸拆除中的关键技术问题; 在此基础上, 进一步提升多工况分析与方案比选的计算效率, 能够为爆

收稿日期: 2026-02-15; 修回日期: 2026-04-30

作者简介: 陈卓(2001—), 男, 硕士生, 主要研究方向为战场环境仿真。E-mail: 591933105@qq.com

破方案快速评估与优化提供高效技术支撑。当前,工程实践中爆炸仿真主要依赖以有限元法为代表的数值模拟方法<sup>[1-2]</sup>。该类方法能够较好地刻画爆炸作用下结构的动力学行为,但通常面临模型构建复杂、计算资源消耗大、迭代求解耗时长等问题<sup>[3]</sup>,难以满足城市更新过程中对快速评估、方案比选与实时决策支持的实际需求。

近年来,深度学习已经成为模拟复杂物理过程的有效工具。图神经网络(Graph Neural Networks, GNN)<sup>[4-5]</sup>因能有效捕捉空间拓扑关系与相互作用,在结构力学代理建模中表现出色。其中,图卷积网络(Graph Convolutional Network, GCN)<sup>[6]</sup>通过谱域或空间域的卷积操作实现了高效的消息传递与特征聚合;然而,其全邻域聚合机制对图结构变化的泛化能力较弱。图注意力网络(Graph Attention Network, GAT)<sup>[7]</sup>引入注意力机制动态分配邻域权重,提升了模型对异质图和关键交互的敏感性;但其计算开销较大,且在噪声或稀疏图上注意力权重可能不稳定。图采样聚合(Graph Sample and Aggregate, GraphSAGE)<sup>[8]</sup>凭借邻域采样与归纳学习机制,在大规模、不规则结构图上具备更高的计算效率与泛化能力。

爆炸作用下结构响应具有显著的时间演化特性,然而传统GNN模型主要针对静态图数据设计,难以直接建模节点特征随时间变化的动态过程。循环神经网络(Recurrent Neural Network, RNN)<sup>[9]</sup>擅长捕捉序列长期依赖,其中门控循环单元(Gated Recurrent Unit, GRU)显著降低参数数量和训练时间,但其门控机制相对简单,在长序列依赖捕捉上仍可能出现性能衰减。扩张时序卷积网络(Dilated Temporal Convolutional Network, Dilated TCN)<sup>[10]</sup>利用扩张卷积扩大感受野,实现并行计算和长距离依赖建模,具有训练稳定、速度快的优势;然而,其卷积设计在非平稳序列上泛化能力有限。长短期记忆网络(Long Short-Term Memory, LSTM)<sup>[11]</sup>因其门控机制能有效缓解梯度消失问题,在计算资源有限和中短期动力学预测中仍为主流选择。最新研究耦合GNN的空间建模能力与RNN的时序建模能力<sup>[12-13]</sup>,构建时空图神经网络,实现了冲击波空间传播与毁伤过程时间演化的联合学习。尽管如此,现有研究尚未形成由高精度测绘数据直接驱动的端到端爆炸损伤预测框架,限制了模型在实际测绘工程中的应用;除此以外,现有方法中物理约束引入不足,在极端爆炸工况下的泛化能力

较弱。

综上所述,传统有限元方法虽能提供较高精度的爆炸仿真结果,但在多工况方案比选、施工过程动态调整和爆后效果快速评估等环节中存在计算效率不足的问题。

为解决上述问题,本文提出一种结合GraphSAGE和LSTM的爆炸毁伤实时预测模型。首先,利用GeoSOT-3D全球立体网格<sup>[14]</sup>对建筑信息模型(Building Information Modeling, BIM)进行剖分,将剖分后的建筑网格导入Abaqus软件中进行仿真计算,得到高保真建筑爆炸数据集;其次,结合GraphSAGE的空间拓扑建模能力与LSTM的时序建模能力,实现了对建筑物局部与整体响应特征的刻画以及位移场与失效状态的动态演化预测;最后,建立多任务解码器,实现位移场与失效状态的联合时序预测。通过对比有限元仿真算法和当前主流GNN与RNN网络,验证本文模型在位移场精度、失效场精度、训练速度以及推理速度上的优势。本文研究可为老旧房屋爆破拆除过程中的安全评估、多方案比选、方案优化与快速决策提供可靠且高效的技术支撑。

## 1 数据集构建

为支撑城市更新场景下老旧建筑拆除过程中的爆炸毁伤分析,构建面向建筑爆炸响应预测的数据集。

老旧住房的结构类型具有多样性,主要包括砖木结构、砖混结构及钢筋混凝土结构。对于砖木、砖混等结构,由于其受力体系相对简单,通常采用人工或机械方式进行拆除;相比之下,钢筋混凝土建筑具有整体性强、承重构件复杂等特点,更适合作为爆破拆除研究的典型对象。基于此,在数据集构建中将研究对象限定为城市更新场景下具有拆除需求的老旧钢筋混凝土建筑。

为实现对复杂建筑结构的统一空间表达与高效离散建模,采用基于GeoSOT的全球立体网格对BIM进行空间剖分。GeoSOT立体网格属于全球统一空间剖分框架,最小网格尺度可达1.5 cm,能够满足建筑物的空间剖分需求。不同于传统有限元面向对象的局部网格离散方式,GeoSOT提供了统一空间参考下的全局网格表达,可支撑BIM模型、倾斜摄影三维模型、城市三维实景模型等建筑测绘数据的统一表达与爆炸毁伤结果的空间关联。GeoSOT立体网格剖分示意图如图1所示。




图1 基于全球立体网格的BIM结构剖分

将完成剖分的建筑模型导入Abaqus平台作为计算网格,采用CONWEP爆炸载荷模型<sup>[15-16]</sup>生成建筑物在爆炸作用下的多场响应数据集。混凝土材料、钢材料分别采用JH-2模型、各向同性塑性模型进行模拟,两种材料参数如表1和表2所示。

每组仿真持续时间为0.03 s,包含150个时间步,结果文件由以下数据要素组成。1)建筑结构信息,包括边索引、单元索引及构成单元的节点关系,用于建立静态图结构;2)节点时序特征,包括节点在各时间步的三维坐标、速度、应力与应变分量、失效状态以及失效的判据,钢和混凝土均采用Abaqus中的状态变量(status)作为是否失效的判据;3)节点的材料类型,包括混凝土与钢两种材料;4)爆炸工况信息,包括爆炸点三维坐标与TNT当量。

表1 混凝土JH-2本构模型材料参数

| 符号       | 参数说明                                      | 参数值   | 符号                 | 参数说明             | 参数值  | 符号                                    | 参数说明       | 参数值   |
|----------|-------------------------------------------|-------|--------------------|------------------|------|---------------------------------------|------------|-------|
| $\rho_0$ | 混凝土材料密度/( $\text{kg}\cdot\text{m}^{-3}$ ) | 2 400 | $\dot{\epsilon}_0$ | 参考应变率            | 1.0  | $D_1$                                 | 损伤演化参数     | 0.6   |
| $G$      | 剪切模量/GPa                                  | 125   | $T$                | 静水拉伸强度/MPa       | 3.4  | $D_2$                                 | 损伤演化参数     | 0.1   |
| $A$      | 完整材料归一化强度系数                               | 0.63  | $\sigma_i^{\max}$  | 完整材料最大归一化强度      | 8.56 | $\bar{\epsilon}_{f,\max}^{\text{pl}}$ | 塑性失效应变上限   | 1.0   |
| $N$      | 完整材料压力硬化指数                                | 0.84  | $\sigma_f^{\max}$  | 破坏材料最大归一化强度      | 1.1  | $\bar{\epsilon}_{f,\min}^{\text{pl}}$ | 塑性失效应变下限   | 0.001 |
| $B$      | 归一化强度系数                                   | 0.21  | $H_{\text{HEL}}$   | Hugoniot弹性极限/GPa | 1.48 | $K_1$                                 | 体积模量参数/GPa | 16.67 |
| $M$      | 压力硬化指数                                    | 0.84  | $P_{\text{HEL}}$   | 极限压力/GPa         | 0.81 | $K_2$                                 | 体积模量参数/GPa | 73.2  |
| $C$      | 应变率效应系数                                   | 0.006 | $\beta$            | 剪胀系数             | 1.0  | $K_3$                                 | 体积模量参数/GPa | -23.6 |

表2 钢各向同性塑性模型材料参数

| 符号           | 参数说明                                    | 参数值   |
|--------------|-----------------------------------------|-------|
| $\rho_1$     | 钢材料密度/( $\text{kg}\cdot\text{m}^{-3}$ ) | 7 850 |
| $\epsilon$   | 弹性模量/GPa                                | 265   |
| $\nu$        | 泊松比                                     | 0.3   |
| $\sigma_y$   | 屈服强度/MPa                                | 450   |
| $\sigma_u$   | 极限强度/GPa                                | 600   |
| $\epsilon_b$ | 断裂应变                                    | 0.5   |

本研究根据结构、材料、墙体厚度、TNT当量和爆炸距离的不同共构建256种爆炸仿真工况,具体的工况参数设计如表3所示。

数据集按照约9:1:1的比例大致分为210个训练集工况、23个验证集工况和23个测试集工况。需要说明的是,本文数据集每个工况包含大规模空间网格节点及时序响应信息。整个数据集平均每个工况约包含28 790个节点。每个节点包含150个时间步的时序信息。因此,数据集具有百万级空间节点规模和更大规模的时空节点样本,可以为GraphSAGE-LSTM网络训练、验证与测试提供较充分的数据支撑。

表3 爆炸仿真数据集工况参数设计

| 参数类别       | 参数信息                                                | 水平数量           | 备注                                    |
|------------|-----------------------------------------------------|----------------|---------------------------------------|
| 建筑<br>结构模型 | 平板结构、<br>中空正六面体、<br>中空正八面体、<br>框架结构                 | 4              | 覆盖板式构件、<br>规则空间结构和<br>框架结构等典型<br>几何形态 |
|            | 材料类型                                                | 混凝土、钢          | 覆盖钢筋混凝土<br>建筑爆炸仿真中<br>典型结构材料          |
| 墙体厚度/m     | 0.04、0.10、0.20、0.25                                 | 4              | 覆盖薄板构件<br>至常见楼板构件<br>厚度范围             |
| TNT当量/kg   | 混凝土材料:<br>10、30、50、100<br>钢材料:<br>100、300、500、1 000 | 4(针对同<br>一种材料) | 覆盖多种爆炸<br>强度工况                        |
| 爆炸距离/m     | 0.1、1                                               | 2              | 覆盖不同爆炸<br>距离下作用情况                     |

## 2 爆炸毁伤实时预测方法

城市更新过程中针对老旧钢筋混凝土建筑定向爆破的研究大多计算过程复杂,难以实现对爆炸结果的高精度快速预测与反馈。为了高效准确仿真爆炸冲击工况下结构响应,本文提出一种面

向爆炸毁伤实时仿真的时空网络框架,框架结构图如图2所示。该框架由3大部分组成:多源信息

融合与图结构表达、图时空编码器和位移—失效联合预测。




图2 面向爆炸毁伤实时仿真的时空网络框架

## 2.1 多源信息融合与图结构表达

模型输入由建筑结构信息、爆炸工况、节点时序特征及节点材料类型共同构成。为提升非线性响应区域的表征精度,在图表达阶段引入自适应网格细化(Adaptive Mesh Refinement, AMR)策略,根据应力梯度对高应力梯度区域进行局部细化,从而增强关键区域的几何与拓扑刻画。在此基础上,将加密后的结构离散体构建为图结构<sup>[8]</sup>:

$$G = (V, E) \quad (1)$$

式中: $G$ 表示图结构; $V$ 表示节点; $E$ 表示连接节点的边。

## 2.2 图时空编码器

在本文模型中,GraphSAGE与LSTM采用空间—时间级联结构进行融合。首先,在每个时间步通过两层GraphSAGE图卷积层对建筑结构图进行空间特征编码,通过邻域采样与特征聚合获取节点的空间嵌入表示。在这一过程中,模型除了利用节点信息,还结合爆炸点三维坐标、节点相对爆心的距离与方向等全局信息,实现对局部与整体响应特征的联合表征。其次,将各时间步的节点空间嵌入按时间顺序组成特征序列,并输入单层LSTM进行时序建模,以捕捉爆炸作用下结构响应的动态演化过程。在时间建模后,本文模型引入材料条件归一化,以缓解不同材料在时间响应幅值与尺度上的差异。

针对节点 $v$ 及其邻域 $N(v)$ ,GraphSAGE首先在局部邻域内进行采样,并对采样到的邻居节点特征进行均值聚合,得到邻域表示;其次,将该邻域表示与节点自身特征进行拼接,经线性映射与非线性激活函数处理,获得节点更新后的空间嵌入表示<sup>[8]</sup>:

$$h_v^{(l)} = \sigma \left( W^{(l)} \left[ h_v^{(l-1)} \parallel \frac{1}{|N(v)|} \sum_{u \in N(v)} h_u^{(l-1)} \right] \right) \quad (2)$$

式中: $h_v^{(l)}$ 表示节点 $v$ 在第 $l$ 层的隐藏表示向量; $W^{(l)}$ 表示第 $l$ 层的可学习权重矩阵; $\parallel$ 表示向量拼接操作; $\sigma(\cdot)$ 表示非线性激活函数。

为刻画节点的时间演化过程,本文采用LSTM对节点的时序变化进行建模。对每个节点,其在时间维度上的表示序列被输入至LSTM单元,更新过程可表示为<sup>[17]</sup>:

$$\begin{cases} i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i); \\ f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f); \\ o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o); \\ \tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c); \\ c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t; \\ h_t = o_t \odot \tanh(c_t). \end{cases} \quad (3)$$

式中: $i_t$ 、 $f_t$ 和 $o_t$ 分别表示输入门、遗忘门和输出门; $\tilde{c}_t$ 表示候选记忆状态; $c_t$ 表示记忆单元状态; $h_t$ 表示隐藏状态; $W_i$ 、 $W_f$ 、 $W_o$ 、 $W_c$ 和 $U_i$ 、 $U_f$ 、 $U_o$ 、 $U_c$ 分别表示输入特征和上一时刻隐藏状态对应的可学习权重矩阵; $b_i$ 、 $b_f$ 、 $b_o$ 和 $b_c$ 表示偏置向量; $t$ 表示时间步; $x_t$ 表示输入特征向量; $\sigma(\cdot)$ 表示非线性激活函数; $\odot$ 表示逐元素乘法。

## 2.3 位移—失效联合预测

为同时刻画建筑物在爆炸作用下的位移响应与失效演化特征,本文采用多层感知机解码器对预测任务进行分解,分别输出节点位移、失效概率以及失效指标预测结果。解码器包含3个任务头:位移回归头输出三维位移预测量 $\hat{u}_{3d}$ ;数据驱动失效头输出数据预测失效logit概率 $\hat{l}_{fail}$ ;物理失效头对物理失效指标status进行预测,并输出物理预测失效标签 $\hat{y}_{phys}$ 。

在推理阶段,为增强失效预测的物理一致性,引入物理门控<sup>[18]</sup>将数据失效概率与物理失效预测进行融合。数据 logit 失效概率  $\hat{l}_{\text{fail}}$  经过非线性激活后得到数据失效概率  $\hat{p}_{\text{fail}} = \sigma(\hat{l}_{\text{fail}})$ , 将  $\hat{p}_{\text{fail}}$  替换为文献[18]中的数据失效概率, 将  $\hat{y}_{\text{phys}}$  替换为文献[18]中的物理失效预测概率, 则门控后的失效预测概率可表示为

$$\hat{p}_{\text{fail}}^{\text{gated}} = \alpha \cdot \hat{p}_{\text{fail}} + (1 - \alpha) \cdot \hat{y}_{\text{phys}} \quad (4)$$

式中:  $\hat{p}_{\text{fail}}$  表示数据驱动失效概率;  $\hat{y}_{\text{phys}}$  表示物理失效预测结果;  $\alpha$  表示融合系数, 为兼顾数据学习能力与物理一致性约束, 取  $\alpha = 0.5$ , 实现二者等权融合。

## 2.4 损失函数与评价指标

为协调 3 个任务头在联合训练过程中的优化贡献, 模型训练采用多任务目标, 总损失由位移预测损失、数据预测损失与物理预测损失 3 个部分构成。位移预测损失采用平均绝对误差 (Mean Absolute Error, MAE)<sup>[19]</sup>:

$$L_{\text{disp}} = \frac{1}{N} \sum_{i=1}^N \|\hat{\mathbf{u}}_{i,t} - \mathbf{u}_{i,t}\|_2 \quad (5)$$

式中:  $N$  表示节点个数;  $\hat{\mathbf{u}}_{i,t}$  表示预测节点位移;  $\mathbf{u}_{i,t}$  表示真实节点位移;  $\|\cdot\|_2$  表示  $L_2$  范数。

失效预测属于二分类任务, 采用二分类交叉熵<sup>[20]</sup> (Binary Cross-Entropy, BCE) 作为失效预测任务的基础损失, 以度量模型预测失效概率与真实失效标签之间的差异。考虑到爆炸毁伤场景中失效样本占比较低、类别分布不平衡, 进一步在二分类交叉熵损失基础上引入焦点损失函数<sup>[21]</sup>, 以增强模型对少数类失效样本和困难样本的关注。将门控后的失效预测概率  $\hat{p}_{\text{fail}}^{\text{gated}}$  替换为文献[21]中的模型预测概率, 真实物理失效标签记为  $y_{\text{phys}} \in \{0, 1\}$ , 则模型的失效预测概率定义为

$$p_i = \hat{p}_{\text{fail}}^{\text{gated}} \cdot y_{\text{phys}} + (1 - \hat{p}_{\text{fail}}^{\text{gated}}) \cdot (1 - y_{\text{phys}}) \quad (6)$$

标准二分类交叉熵<sup>[20]</sup>形式为

$$\text{BCE}(p, y) = -\ln(p_i) \quad (7)$$

在此基础上, 进一步引入焦点损失<sup>[21]</sup>中的调制因子  $(1 - p_i)^\gamma$ 。因此, 失效预测损失函数定义为

$$L_{\text{fail}} = -(1 - p_i)^\gamma \ln(p_i) \quad (8)$$

式中:  $L_{\text{fail}}$  表示失效预测损失;  $p_i$  表示模型失效预测概率;  $\gamma$  表示调制因子, 本文取  $\gamma = 1$ 。

参考文献[18]中物理引导损失思想, 并采用参考文献[19]中的 MAE 形式构建物理损失函数:

$$L_{\text{phys}} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_{\text{phys},i} - y_{\text{phys},i}| \quad (9)$$

式中:  $\hat{y}_{\text{phys},i}$  表示第  $i$  个物理失效预测结果;  $y_{\text{phys},i}$  表示第  $i$  个真实物理失效标签。

为平衡多任务学习, 使用不确定性自适应加权形式<sup>[22]</sup>组合 3 项损失, 用对数方差参数  $s_{\text{disp}}$ 、 $s_{\text{fail}}$ 、 $s_{\text{phys}}$  表示各任务的不确定性:

$$L_{\text{total}} = \frac{1}{2} \left( \frac{L_{\text{disp}}}{e^{s_{\text{disp}}}} + \frac{L_{\text{fail}}}{e^{s_{\text{fail}}}} + \frac{L_{\text{phys}}}{e^{s_{\text{phys}}}} + s_{\text{disp}} + s_{\text{fail}} + s_{\text{phys}} \right) \quad (10)$$

式中:  $L_{\text{total}}$  表示总损失;  $L_{\text{disp}}$ 、 $L_{\text{fail}}$ 、 $L_{\text{phys}}$  分别表示位移预测损失、失效预测损失和物理失效预测损失;  $s_{\text{disp}}$ 、 $s_{\text{fail}}$ 、 $s_{\text{phys}}$  分别表示对应任务观测噪声方差的对数形式。

为与式(5)位移预测损失  $L_{\text{disp}}$  区分, 评价指标中的位移预测误差指标<sup>[19]</sup>采用  $L_{\text{MAE}}$  表示:

$$L_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N \|\hat{\mathbf{u}}_{i,t} - \mathbf{u}_{i,t}\|_2 \quad (11)$$

参考文献[23]中的相对误差评价思想, 并结合位移预测任务, 构建归一化精度指标, 用于衡量模型在不同时间步下的相对预测性能:

$$A_{\text{acc},t} = 1 - \frac{1}{U} \sum_{\tau=1}^t L_{\text{MAE},\tau} \quad (12)$$

式中:  $A_{\text{acc},t}$  表示前  $t$  个时间步的位移精度;  $\sum_{\tau=1}^t L_{\text{MAE},\tau}$  表示前  $t$  个时间步的累积位移平均绝对误差;  $U_t$  表示  $t$  时间步所有节点相对于初始状态的真实累计位移平均值。

在爆炸毁伤预测任务中, 节点失效仅发生于局部区域与有限时间步, 正负样本分布高度不均衡。PR-AUC (Precision-Recall Area Under Curve) 通过综合刻画精确率与召回率在不同判定阈值下的变化关系, 对少数类失效样本的识别性能更为敏感, 其表示形式为<sup>[24]</sup>

$$C_{\text{PR-AUC}} = \int_0^1 P(R) dR \quad (13)$$

式中:  $P$  表示精确率;  $R$  表示召回率。

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (14)$$

$$R = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (15)$$

式中:  $N_{\text{TP}}$  表示正确预测为正类 (失效) 的样本数;  $N_{\text{FP}}$  表示错误预测为正类 (误报失效) 的样本数;  $N_{\text{FN}}$  表示未被识别的正类 (漏检失效) 的样本数。

## 3 模型训练与实验

### 3.1 实验环境与配置

Abaqus 数值计算所采用的实验硬件平台为 13th Gen Intel® Core™ i9-13900HX CPU, 支持 32

线程并行计算。深度学习模型训练所使用的硬件平台为 NVIDIA A100 Tensor Core GPU,显存容量为 80 GB。软件环境方面,Python 版本为 3.9,深度学习框架、并行计算架构和深度神经网络加速库分别为 PyTorch 1.13、CUDA 11.7 和 cuDNN 8.5。

模型采用两阶段训练策略:第 1 阶段对时空主干网络进行端到端训练,主要进行失效预测的训练;第 2 阶段在冻结空间—时间主干和失效预测头的情况下,仅对位移回归分支进行精调训练。在优化过程中,模型采用 Adam 优化器,初始学习率为  $1\times 10^{-4}$ ,并结合基于验证集性能指标的自适应学习率退火策略,在模型性能进入平台期时逐步降低学习率步长,以促进网络进一步收敛。

3.2 模型训练收敛分析

模型训练损失曲线如图 3 所示。随着训练轮数增加,训练集与验证集的损失量呈现持续下降

趋势,并在约 30 个训练轮数之后逐步进入平缓收敛阶段。整体来看,验证曲线变化平稳,虽然在中前期存在一定幅度的局部波动,但未出现明显异常震荡或发散现象,说明模型在训练过程中具有较好的优化稳定性与泛化能力。




图 3 训练损失曲线

3.3 消融实验结果与分析

为评估模型中各关键模块对整体性能的贡献,开展一系列消融实验,对不同网络模块的作用进行对比分析,并据此确定最优的模型配置方案,实验结果如表 4 所示。

表 4 模型消融实验结果表

| 模型     | PR-AUC/% |       |       | MAE/m   | 前 150 个时间步<br>位移精度 /% |
|--------|----------|-------|-------|---------|-----------------------|
|        | 钢材材料     | 混凝土材料 | 全局    |         |                       |
| 完整模型   | 96.25    | 94.22 | 95.86 | 0.281 2 | 96.45                 |
| 去除焦点损失 | 93.12    | 90.34 | 91.47 | 0.468 5 | 90.89                 |
| 去除物理损失 | 89.49    | 87.01 | 88.75 | 0.648 5 | 78.95                 |
| 去除物理门控 | 91.66    | 85.13 | 87.08 | 0.597 3 | 86.44                 |
| 去除网格加密 | 93.50    | 90.07 | 91.84 | 0.454 6 | 91.59                 |
| 去除归一化  | 94.35    | 88.74 | 90.19 | 0.307 9 | 95.06                 |
| 仅时间网络  | 94.42    | 93.57 | 94.25 | 0.314 5 | 94.75                 |
| 仅空间网络  | 93.78    | 89.43 | 90.61 | 0.427 8 | 92.23                 |

消融实验结果表明,完整模型在各项指标上整体表现最优。去除焦点损失后,模型的失效识别性能和位移预测精度均有所下降,说明焦点损失有助于缓解失效样本占比较低导致的类别不平衡问题。去除物理损失或物理门控后,模型性能下降更为明显,表明物理约束信息能够提升失效预测的物理一致性。去除网格加密后,位移预测误差增大,说明自适应网格细化有助于增强模型对局部非线性响应的表征能力。去除材料条件归一化后,模型对不同材料工况的适应能力下降,说明材料归一化能够缓解材料响应差异对模型训练的影响。此外,仅采用时间网络或仅采用空间网络时,模型性能均低于完整模型,表明爆炸毁伤演化过程需要同时建模空间拓扑关系与时间演化特征。总体来看,各模块均对模型性能提升具有积极作用,验证了模型结构设计的有效性。

3.4 对比实验结果与分析

为验证所提模型的有效性,本文将其与多种典型时序与图学习模型的组合进行了对比实验,除网络结构不同外,其他训练策略一致,实验结果如表 5 所示。从时间建模模块来看,LSTM 整体表现优于 GRU、TCN 和 Transformer。GRU 在部分材料工况下的毁伤识别能力下降较明显;虽然 TCN 的推理速度较快,但位移预测误差相对较大;Transformer 的推理时间明显增加,整体效率较低。从空间图网络对比来看,MeshNet、GCN、GNS 和 GAT 等空间编码方式的综合性能整体低于 GraphSAGE,说明 GraphSAGE 在不规则建筑结构图的空间拓扑表征中也具有较好的适用性。总体而言,GraphSAGE 与 LSTM 能够较好融合结构空间特征与爆炸响应时序特征,使模型在预测精度和计算效率方面均表现较优,验证了本文主体网络结构选择的合理性。

表5 模型对比实验结果表

| 模型                    | PR-AUC/% |       |       | MAE/m   | 前 150 个时间步<br>位移精度/% | 推理时间/s |
|-----------------------|----------|-------|-------|---------|----------------------|--------|
|                       | 钢材材料     | 混凝土材料 | 全局    |         |                      |        |
| GraphSAGE+LSTM        | 96.25    | 94.22 | 95.86 | 0.281 2 | 96.45                | 10.60  |
| GraphSAGE+GRU         | 92.93    | 82.56 | 91.72 | 0.329 5 | 95.10                | 12.38  |
| GraphSAGE+TCN         | 94.75    | 92.63 | 93.12 | 0.477 6 | 89.41                | 6.49   |
| GraphSAGE+Transformer | 93.29    | 87.04 | 89.65 | 0.305 9 | 95.54                | 42.57  |
| MeshNet+LSTM          | 93.41    | 89.64 | 92.38 | 0.382 8 | 93.76                | 22.31  |
| GCN+LSTM              | 94.80    | 85.96 | 87.26 | 0.334 8 | 94.53                | 15.50  |
| GNS+LSTM              | 94.83    | 95.07 | 94.95 | 0.398 2 | 93.46                | 23.42  |
| GAT+LSTM              | 94.87    | 89.28 | 93.04 | 0.295 4 | 95.73                | 19.86  |

3.5 模型推理结果与测试集对比分析

在确定最优模型后,基于测试集开展性能评估,并将模型预测得到的位移场、失效区域结果与有限元仿真结果进行对比分析,部分典型工况毁伤对比结果如图4所示。其中:图4(a)工况墙体厚度为0.04 m,TNT当量为1 000 kg,爆炸距离为1 m;图4(b)工况墙体厚度为0.1 m,TNT当量为50 kg,

爆炸距离为0.1 m;图4(c)工况墙体厚度为0.2 m,TNT当量为300 kg,爆炸距离为1 m;图4(d)工况墙体厚度为0.25 m,TNT当量为300 kg,爆炸距离为0.1 m。

由图4可以看出,模型预测的位移场分布及失效区域演化与有限元仿真结果在空间分布和发展趋势上具有较好一致性。




图4 不同时间步下仿真结果与模型结果对比

为评估模型在时间维度上的预测性能,统计所有测试工况在不同时间步 $t$ 下的平均MAE、平均位移精度以及全局平均PR-AUC,实验结果如表6所示。

| 表6 不同时间步 $t$ 下模型平均位移预测与节点失效结果 |         |          |              |
|-------------------------------|---------|----------|--------------|
| 时间步 $t$                       | 平均MAE/m | 平均位移精度/% | 全局平均PR-AUC/% |
| 10                            | 0.025 4 | 99.30    | 97.98        |
| 40                            | 0.078 7 | 98.81    | 97.64        |
| 80                            | 0.169 7 | 97.66    | 96.39        |
| 150                           | 0.281 2 | 96.45    | 95.86        |

由表6可以得到,随着时间步增加,平均MAE呈上升趋势,平均位移精度和全局平均PR-AUC呈下降趋势。该现象表明,在长时序预测过程中,模

型误差存在累积效应,但整体精度下降幅度较小,能够有效刻画爆炸响应的动态演化过程。在150个时间步范围内,模型仍能够保持96%以上的位移预测精度和95%以上的毁伤识别性能,说明所提方法具有较好的长时预测能力,能够有效刻画爆炸响应的动态演化过程。

进一步地,为分析不同参数条件下的模型预测性能与计算效率,本文从建筑结构模型、材料类型、墙体厚度、TNT当量和爆炸距离等方面选取典型工况进行可视化对比,如图5所示。同时,统计了参数类别中所有工况的平均MAE、平均前150个时间步位移精度、平均PR-AUC、有限元平均计算时间和模型平均推理时间,结果如表7所示。




图5 不同参数类别下模型预测可视化结果

表 7 不同参数类别下模型预测与推理时间结果

| 参数类别               | 参数信息     | 平均 MAE/m | 平均前 150 个时间步<br>位移精度/% | 平均 PR-AUC/% | 有限元平均<br>计算时间/s | 模型平均<br>推理时间/s |
|--------------------|----------|----------|------------------------|-------------|-----------------|----------------|
| 建筑结构模型             | 框架结构模型   | 0.349 6  | 94.58                  | 93.72       | 564.95          | 14.89          |
|                    | 平板模型     | 0.254 5  | 97.64                  | 96.43       | 292.62          | 7.28           |
|                    | 中空正八面体模型 | 0.320 7  | 94.12                  | 95.69       | 471.51          | 12.73          |
|                    | 中空正六面体模型 | 0.274 0  | 96.35                  | 95.53       | 301.42          | 7.49           |
| 材料类型               | 钢材料      | 0.267 6  | 96.58                  | 95.75       | 405.79          | 10.51          |
|                    | 混凝土材料    | 0.298 0  | 95.24                  | 94.22       | 409.85          | 10.74          |
| 墙体厚度/m             | 0.04     | 0.243 2  | 98.38                  | 92.49       | 398.72          | 9.42           |
|                    | 0.10     | 0.256 2  | 97.63                  | 94.82       | 403.20          | 10.16          |
|                    | 0.20     | 0.289 0  | 95.29                  | 96.51       | 412.38          | 11.45          |
|                    | 0.25     | 0.304 7  | 94.70                  | 97.19       | 416.09          | 12.01          |
| 混凝土材料<br>TNT 当量/kg | 10       | 0.074 6  | 97.50                  | 98.53       | 402.70          | 9.68           |
|                    | 30       | 0.123 7  | 96.33                  | 97.83       | 405.09          | 10.05          |
|                    | 50       | 0.324 9  | 95.17                  | 95.73       | 408.38          | 10.69          |
|                    | 100      | 0.536 6  | 92.98                  | 90.61       | 411.96          | 11.93          |
| 钢材料<br>TNT 当量/kg   | 100      | 0.087 4  | 97.94                  | 99.06       | 401.54          | 9.59           |
|                    | 300      | 0.149 2  | 96.70                  | 97.84       | 404.98          | 10.13          |
|                    | 500      | 0.295 5  | 95.61                  | 96.14       | 409.67          | 10.59          |
|                    | 1 000    | 0.498 3  | 94.17                  | 92.79       | 416.20          | 11.42          |
| 爆炸距离/m             | 0.1      | 0.237 9  | 96.63                  | 96.03       | 406.59          | 10.49          |
|                    | 1        | 0.320 5  | 95.74                  | 95.17       | 407.89          | 10.65          |
| 所有工况               |          | 0.281 2  | 96.45                  | 95.86       | 407.63          | 10.60          |

由图5可视化结果和表7定量结果可知,模型预测性能随结构形式、材料类型、构件厚度、TNT当量和爆炸距离的变化呈现出一定规律。对于不同建筑结构模型,规则结构的预测精度整体高于复杂框架结构。对于不同材料类型,混凝土材料相较于钢材料预测精度更低,说明混凝土材料在爆炸荷载下的非线性损伤、开裂和失效演化特征更复杂。从构件厚度变化来看,随着墙体厚度增加,模型位移预测误差呈上升趋势,PR-AUC呈上升趋势,说明较厚构件在爆炸作用下的位移响应和内部应力传递更加复杂,但其失效区域特征相对更加集中和清晰。从TNT当量变化来看,随着爆炸强度增加,平均MAE明显增大,平均前150个时间

步位移精度和平均PR-AUC整体下降,表明高爆炸强度工况下结构响应更加剧烈,非线性毁伤演化更加明显,模型预测难度更高。从爆炸距离变化来看,近距离爆炸工况下模型整体预测性能略优于远距离爆炸工况,说明近距离爆炸时结构响应和毁伤区域更集中,特征更显著。

计算效率方面,模型平均推理时间相较于有限元计算时间实现近40倍的计算加速。在实际工程应用中,爆破方案设计需要对多种爆炸参数组合进行快速比选与安全评估,通常要求在分钟级甚至更短时间内完成。当需要进行数十至上百次工况分析时,传统有限元仿真总计算时间往往达到数小时,难以满足工程现场快速决策的需求。

相比之下,本文提出的模型能够将单个工况的计算时间压缩至秒级至十秒级,并可支持多工况并行推理,从而在分钟级时间内完成数十种爆破方案评估,显示出其在爆炸毁伤多方案评估、方案优化和快速决策场景中的显著优势。

## 4 结束语

提出一种结合 GraphSAGE 与 LSTM 的爆炸毁伤实时仿真模型,实现了从测绘数据直接驱动的位移场与毁伤分布高精度实时仿真。实验结果表明,与多种典型时序模型与图学习模型组合相比,所提方法在位移预测精度和毁伤识别性能方面均表现出较大优势,在推理速度方面较有限元方法加速近 40 倍,为城市更新背景下老旧建筑物定向爆破拆除过程中的安全评估与多方案评选提供了有效的技术支撑。

尽管本文方法能够快速准确仿真爆炸对建筑物的毁伤效果,但其主要适用于特定钢筋混凝土建筑结构爆炸响应的快速评估应用场景,在超出当前训练数据分布范围的复杂结构或材料条件下,仍建议结合高保真数值模拟方法进行验证。未来工作将结合实测数据,并进一步扩展爆炸工况与材料模型的多样性,以提升模型在定向爆破场景下的动态推演能力和工程应用可靠性。

### 参考文献:

- [1] 郭攀,刘君,武文华.爆炸冲击载荷作用下流固耦合数值模拟[J].力学学报,2013,45(2):283-287.
- [2] PARK D, LEE T H, LEE Y, et al. Blast simulations of a reinforced concrete slab using the continuous surface cap model (CSCM)[J]. Journal of Building Engineering, 2024, 96: No.110603.
- [3] 潘美霖,彭卫文,冷春江,等.基于贝叶斯深度学习的复杂结构爆炸载荷的快速估计[J].爆炸与冲击,2025,45(8):144-156.
- [4] PFAFF T, FORTUNATO M, SANCHEZ-GONZALEZ A, et al. Learning mesh-based simulation with graph networks [C]//Proceedings of the 9th International Conference on Learning Representations. Appleton, USA: ICLR, 2021. DOI: 10.48550/arXiv.2010.03409.
- [5] SANCHEZ-GONZALEZ A, GODWIN J, PFAFF T, et al. Learning to simulate complex physics with graph networks [C]//Proceedings of the 37th International Conference on Machine Learning. New York, USA: ACM, 2020: 8459-8468.
- [6] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[C]//Proceedings of the 5th International Conference on Learning Representations. Appleton, USA: ICLR, 2017. DOI: 10.48550/arXiv.1609.02907.
- [7] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [C]//Proceedings of the 6th International Conference on Learning Representations. Appleton, USA: ICLR, 2018. DOI: 10.48550/arXiv.1710.10903.
- [8] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, USA: Curran Associates Inc., 2017:1025-1035.
- [9] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Stroudsburg, USA: ACL, 2014:1724-1734.
- [10] LEA C, FLYNN M D, VIDAL R, et al. Temporal convolutional networks for action segmentation and detection [C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2017:1003-1012.
- [11] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997,9(8):1735-1780.
- [12] WANG Z Q, PENG J Z, HU J, et al. BlastGraphNet: an intelligent computational method for the precise and rapid prediction of blast loads on complex 3D buildings using graph neural networks[J]. Engineering, 2025,49:205-224.
- [13] LI Y G, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting [C]//Proceedings of the 6th International Conference on Learning Representations. Appleton, USA: ICLR, 2018. DOI: 10.48550/arXiv.1707.01926.
- [14] 孙忠秋,程承旗.GeoSOT-3D 椭球体剖分真三维数据表达[J].地理信息世界,2016,23(3):40-46.
- [15] HYDE D W. Microcomputer programs CONWEP and FUNPRO, applications of TM 5-855-1, 'fundamentals of protective design for conventional weapons' (user's guide) [R]. Vicksburg, USA: US Army Engineer Waterways Experiment Station, 1988:1-22.
- [16] 张帝,杨军,曾丹,等.钢筋混凝土排架结构的抗爆破坏等级[J].爆炸与冲击,2020,40(12):43-54.
- [17] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: a search space odyssey [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28 (10): 2222-2232.

(下转第 378 页)