爆 炸 与 冲 击
Explosion and Shock Waves

DOI：10.11883/bzycj-2025-0179

图学习驱动的爆炸冲击钢筋混凝土柱结构响应的建模与预测*

潘刘娟[1]，张雍奇[1]，王祉乔[1]，王名川[2]，何勇[2]，胡杰[3]，吴威涛[1]，彭江舟[1]

（1.南京理工大学机械工程学院，江苏 南京 210094；

2.南京理工大学中法工程师学院，江苏 南京 210094；

3. 南京理工大学安全科学与工程学院，江苏 南京 210094；）

摘 要：爆炸冲击下钢筋混凝土构件结构响应的高效准确预测对抢修决策、结构加固与防护设计具有关键意义。现有结构响应快速计算方法例如解析模型、轻量级数据驱动方法虽具备较高计算效率，但在三维结构响应场计算方面精度受限。本文提出一种基于图神经网络（GNN）的钢筋混凝土柱毁伤快速预测模型，通过 GNN 中的领域节点聚合机制高效传递结构内部的力学关联信息，从而在爆炸荷载输入与三维构件结构响应之间建立端到端映射，实现对柱体毁伤状态的快速预测。进一步引入多工况特征耦合训练策略，使模型具备适应不同配筋率、爆炸当量和起爆位置等工况的预测能力，显著提升了模型的跨工况泛用性能。结果表明，该模型单次预测耗时仅 55 毫秒，较传统方法速度提升 4 个数量级，预测误差低于 3.33%，在多种爆炸工况下均实现高精度毁伤预测。该研究展示了 GNN 方法在爆炸毁伤预测中的应用潜力，为爆炸冲击结构毁伤的快速评估与防护优化提供创新技术路径。

关键词：爆炸荷载；钢筋混凝土构件；毁伤效应；深度学习；图神经网络

中图分类号：XXXX.X　　**国标学科代码：**XXXXX　　**文献标识码：**A

Modeling and prediction of blast-Induced response in RC columns using graph neural networks *

PAN Liujuan[1]，ZHANG Yongqi[1]，WANG Zhiqiao[1]，WANG Mingchuan[2]，HE Yong[2]，HU Jie[3]，WU Weitao[1]，PENG Jiangzhou[1]

(1.School of Mechanical Engineering，Nanjing University of Science and Technology，Nanjing 210094，Jiangsu，China ；2. School of Sino-French Engineering，Nanjing University of Science and Technology，Nanjing 210094，Jiangsu，China；3. School of Safety Science and Engineering，Nanjing University of Science and Technology，Nanjing 210094，Jiangsu，China；)

*收稿日期：2025-06-17；　修回日期：2025-10-27；
基金项目：中国博士后基金面上项目（2025M774265）；江苏省自然科学基金青年基金项目（BK20241439）。
第一作者：潘刘娟（2001－ ），女，博士研究生. E-mail: panliujuan@njust.edu.cn；
通信作者：彭江舟（1996－ ），男，博士，博士后. E-mail: pengjz@njust.edu.cn。

录用稿件，非最终出版稿

Abstract: The efficient and accurate prediction of the structural response of reinforced concrete (RC) components under explosive impact is critically important for guiding emergency repair decisions, implementing structural strengthening measures, and informing protective design strategies. While existing fast-calculation approaches, such as simplified analytical models and lightweight data-driven methods, provide considerable computational efficiency, they are often limited in their ability to accurately capture complex three-dimensional structural response fields, which are essential for a comprehensive damage assessment. To overcome this limitation, this paper proposes a novel rapid damage prediction model for RC columns based on Graph Neural Networks (GNN). The core of this model lies in leveraging the powerful neighborhood aggregation mechanism of GNNs, which efficiently transmits and propagates mechanical interaction information throughout the structure's graph representation. This capability allows the model to establish a direct, end-to-end mapping between the input parameters of an explosive load and the full three-dimensional structural responses of the column, thereby facilitating both fast and highly accurate damage prediction. Furthermore, a multi-scenario feature coupling training strategy is introduced to significantly enhance the model's generalization capability. This strategy enables the GNN model to effectively adapt to variations in key design and loading parameters, including reinforcement ratios, explosive charge weights, and detonation locations. The results demonstrate that the proposed model accomplishes a single prediction in merely 55 milliseconds, achieving a computational speed improvement of more than four orders of magnitude compared to traditional high-fidelity simulation methods. Importantly, this speed is attained without sacrificing accuracy, as the model maintains a prediction error below 3.33% and delivers high-precision damage predictions across a wide spectrum of explosive conditions. Its consistent performance across multiple blast scenarios confirms the model's excellent robustness. This study successfully highlights the significant potential of GNN-based approaches in predicting blast-induced damage and offers an innovative, data-driven solution for rapid structural assessment and protective design in the field of blast engineering.

Keywords: explosive load; RC member; damage effect; deep learning; graph neural networks

1 引言

钢筋混凝土（RC）因其低廉的制造成本和优异的力学性能，成为人防工事与一般建筑结构的首选材料，但在短时高压的爆炸载荷作用下容易出现严重结构与功能性破坏。在现代军事对抗中，及时可靠地预测被打击目标的毁伤程度，不仅是提升毁伤评估实时性的关键手段，更是支撑应急响应与作战决策高效开展的迫切需求。因此，探索爆炸载荷作用下结构响应的快速、准确预测方法，对作战资源动态调配与防护效能实时优化具有重要意义。

当前对于 RC 结构的爆炸毁伤评估主要依赖实爆试验、理论分析与数值仿真，其中试验研究可信度最高，能够真实反映爆炸载荷作用下结构响应特征，但其成本高、周期长，且受限于场地、安全与实施条件限制，难以满足多场景、多参数工况下的大规模验证需求；数值仿真能够在不同工况下对结构响应过程进行推演，并提供较高的空间与时间分辨率，但其结果对本构模型、边界条件及参数设定高度敏感，且建模复杂、计算开销高，难以满足实战环境对评估方法高时效性与广适应性的要求；解析方法则通常依赖于对爆炸荷载与结构响应过程的简化假设，适用范围局限于边界条件明确、加载形式单一的场景，对于多因素耦合作用下的复杂爆炸毁伤效应难以有效解析。可以看出，现有毁伤评估受限于方法自身局限，难以满足未来复杂作战条件下对快速、动态化毁伤评估能力的需求[1]。

深度学习数据驱动技术的出现为此类问题的解决提供了可行途径，该技术通过拟合输入数据与输出变量的映射函数，对数据之间的复杂关系进行建模，保持高计算效率的同时，还能充分提取并表征数据的空间分布规律与时间演化特征。近年来，深度学习已在多个复杂工程与科学领域展现出广泛应用潜力：在交通管理[2]中，它可从海量时空数据中挖掘潜在模式，实现动态交通流预测与优化调度；

录用稿件，非最终出版稿

在气象预报[3]中，它能够融合多源、多尺度信息，从而提高对复杂多物理场过程的预测精度；在流动仿真[4]和工程优化[5]中，深度学习通过近似高维偏微分方程解和构建高效代理模型，显著降低了计算成本。上述成果充分证明了深度学习在处理高维非线性、强耦合和多尺度问题上的卓越能力，为其在RC 柱爆炸响应与毁伤预测中的应用奠定了方法论基础。

在计算力学领域，UNNO 等人[6]提出了一种基于决策树模型的损伤识别方法，通过分析桁架结构在常规荷载下的加速度时程信号，实现了对构件损伤的快速诊断。该方法以较低的监测成本与维护需求，显著提升了中小损伤状态下的识别精度。Ban 等人[7]则从静态响应特征入手，采用逻辑回归算法处理螺栓连接桁架的应变信号，实现了在役结构的损伤分类与预警，进一步拓展了机器学习在静载条件下损伤检测的应用范围。另一方面，Mai 等人[8]将深度神经网络与差分进化算法相结合，以位移约束为条件，实现了几何非线性桁架结构的优化设计，展现出机器学习在结构设计与性能控制方面的潜力。上述研究在“小载荷、微损伤、线性行为”的框架内取得了显著进展，为解决常规工况下的结构状态评估提供了有效途径。然而，上述研究尚未充分涉及大尺度损伤导致的非线性响应、强动荷载下的毁伤预测等更具挑战性的问题。

在强动载荷及破坏性工况下的损伤识别与安全评估领域，机器学习方法依旧展现出突破性的潜力。Almustafa 与 Nehdi 构建了覆盖多类钢筋混凝土构件（柱[9]、梁[10-11]、板[12]）的爆炸毁伤预测体系，还采用机器学习与蒙特卡洛模拟相结合的架构[13]整合四种损伤状态，通过概率化建模处理爆炸参数不确定性，实现裂缝模式与破坏状态的概率量化预测，并创新性地引入 BRC 曲线解析参数对损伤状态的影响；此外 Zhou 等人[14]则采用 LSTM 神经网络，以结构参数与爆炸条件为输入直接输出连续型损伤指数，突破传统二值分类局限，绘制 RC 柱损伤程度分区图呈现柱的损伤。Abd-Elhamed A 等人[15]进一步开发了非线性建筑响应预测框架，以炸药量、距离、建筑基本周期、质量和刚度及土壤类型为输入参数，通过机器学习分类模型高效实现四类损伤状态的精准分级。上述研究均可提供高效的毁伤分类预测，但分类形式的预测结果对于结构响应的表征太过笼统，所能描绘的损伤精细程度有限。

为实现机器学习算法对爆炸冲击下的结构响应预测，Phi-Long Tran 等人[16]以 12 个 RC 梁结构参数和 2 个爆炸载荷参数作为模型输入，构建多任务学习架构分别预测 RC 梁在爆炸下的中跨位移、毁伤程度和毁伤模式。然而由于模型的输出限制，该研究仅能实现中跨位移的量化预测，无法对爆炸后梁的破碎、剥落、弯曲等结构响应开展预测，制约了更精细化的毁伤快速评估与分析。在另一方面，Ahmed B 等人[17]突破以离散的结构、爆炸参数作为模型的输入范式，以更详尽的像素化结构图像替代离散参数，通过引入自相似矩阵和图像生成器两种技术，赋予特征像素位置以创造空间依赖性，利用卷积神经网络（CNN）预测钢筋混凝土板在空气爆炸载荷下的最大垂直位移。该方法解决了输入参数高度简化导致模型接收信息受限的问题，但通过像素化处理得到的栅格数据形式，会造成原数据精度丢失，同时破坏了原网格节点数据空间的相对分布特征，降低了模型能力上限。

总的来说，现有多数模型主要关注毁伤等级或毁伤类别，针对结构响应的部分研究也仅做出初步探索，缺乏更适配于爆炸冲击结构响应问题的深度学习模型，制约了模型对结构毁伤的精准量化评估。此外，爆炸作用对 RC 构件的毁伤影响因素较多，如爆炸当量、爆炸位置等，除了爆炸源本身因素外，RC 柱子自身的配筋率对其在爆炸载荷下的毁伤也有较大影响，RC 构件结构响应快速预测的难点在于准确辨识不同爆炸参数下结构整体响应特征。

针对上述存在的问题，本文提出采用图神经网络（Graph Neural Network, GNN）方法来预测钢筋混凝土柱在爆炸载荷下的结构响应。与传统机器学习方法或卷积神经网络不同，图神经网络能够直接对有限元网格中的节点与单元连接关系进行建模，完整保留结构的空间拓扑特征，无需依赖额外的数据插值或栅格化预处理，因而在结构几何与力学特征表达上更具优势。依托图神经网络的信息传递机制，模型既能捕捉局部损伤特征，又能建立节点与整体结构响应之间的层级映射关系，更贴合爆炸作用下 RC 柱的力学破坏机理。同时，通过引入多源信息融合建模，实现不同工况下结构响应模式的精准辨识，显著增强模型对复杂爆炸场景的自适应预测能力。相比于仅输出损伤等级或单一指标的传统

录用稿件，非最终出版稿

模型，本研究所构建的 GNN 框架具备对三维结构响应的端到端预测能力，可在多参数、多场景条件下实现快速且准确的结构响应预测。最后，通过与高精度仿真结果比对，验证了模型计算效率与预测准确性，为爆炸载荷作用下 RC 柱结构响应快速评估提供技术支撑。

2 研究方法

本文以 TNT 爆破冲击载荷作用下的钢筋混凝土柱为研究对象，首先通过 Abaqus 软件仿真获取基础数据，继而验证该仿真数据的可靠性，最终基于验证后的可靠数据，完成图神经网络（GNN）模型的搭建与训练。

2.1 物理模型

混凝土柱及其钢筋框架的几何形状如图 1 所示。钢筋为圆形截面，通过改变钢筋截面圆半径控制混凝土柱子的配筋率。在钢筋混凝土柱附近区域至柱表面之间的范围内选取爆炸位置。

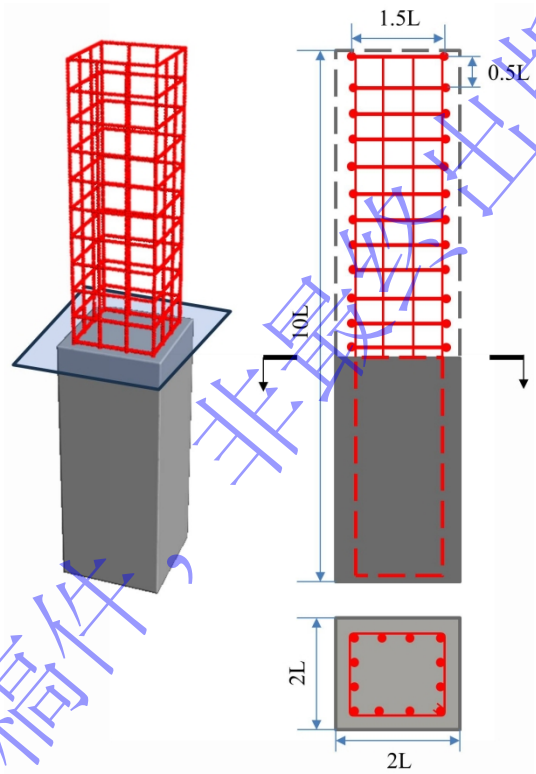

图 1 混凝土与钢筋结构示意图

Fig.1 Concrete and steel structure diagram

在本研究中，等效 TNT 爆炸当量、配筋率以及爆炸位置均在限定区间内进行等间隔选取，以制定多种类工况。针对不同工况爆炸荷载，对混凝土柱的动态响应开展计算分析，计算中采用耦合欧拉 - 拉格朗日（CEL）单元技术。具体而言，柱体与其内部的钢筋分别采用拉格朗日实体单元和桁架单元进行网格划分，使用嵌入式单元技术实现柱体与钢筋之间的连接。经网格无关性分析，柱体单元尺度控制在 5－10 mm，能够兼顾精度与计算效率。爆炸物采用欧拉域建模，并在与柱体接触处建立流固耦合界面，以实现爆炸产物与结构的相互作用。欧拉域边界施加非反射边界条件，避免冲击波在边界处发生非物理反射。炸药采用点起爆方式，通过在欧拉域中施加初始起爆点来触发 JWL 状态方程下的爆轰过程，同时耦合空气材料以保证冲击波传播的连续性。

柱体由混凝土制成，其本构行为采用 Abaqus 中的混凝土损伤塑性（Concrete Damage Plasticity，CDP）模型进行表征[18-20]。钢筋由钢材制成，其硬化行为通过各向同性塑性模型进行简化描述。对于

录用稿件，非最终出版稿

TNT，采用经典的琼斯-威尔金斯-李（Jones-Wilkins-Lee，JWL）模型来定义其流体动力学行为。本研究中所使用的材料参数分别总结于表 1、表 2 和表 3 中。计算过程采用显式时间积分算法，时间步长由 Courant 条件自动控制，以确保爆炸荷载传播过程中的数值稳定性。分析总时长设置为 3－5 ms，足以覆盖冲击波作用与结构主要响应阶段。在计算过程中，通过能量平衡监测和单元畸变控制保证求解可靠性，输出包括柱体位移、加速度、应力应变分布及损伤变量演化，以全面反映不同工况下混凝土柱的动力响应和破坏特征。

将 Abaqus 数值模拟的结果与实验结果进行对比分析，柱子破坏形貌结果如图 2-a 所示，仅在柱子单个侧面接触爆炸，其损伤模拟结果与试验结果吻合较好。此外，柱子结构表面加速度时程曲线[21]对比结果如图 2-b 所示，在柱子四个侧面同时布置爆炸物并引爆，加速度首个峰值时间以及后续应力波的耦合增强现象，模拟计算的峰值与震荡趋势均与试验相近，验证了仿真数值模型的精度和实现的正确性，从而确保其作为生成训练数据来源的可靠性。

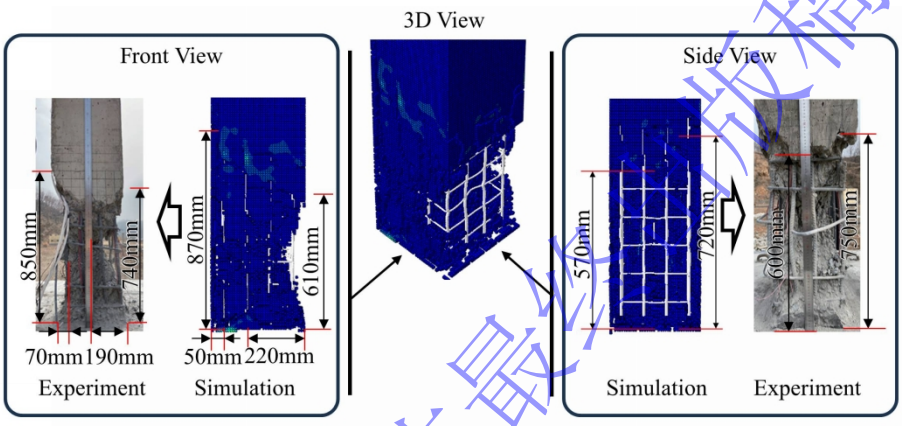

(a) Residual reinforced concrete in RC columns

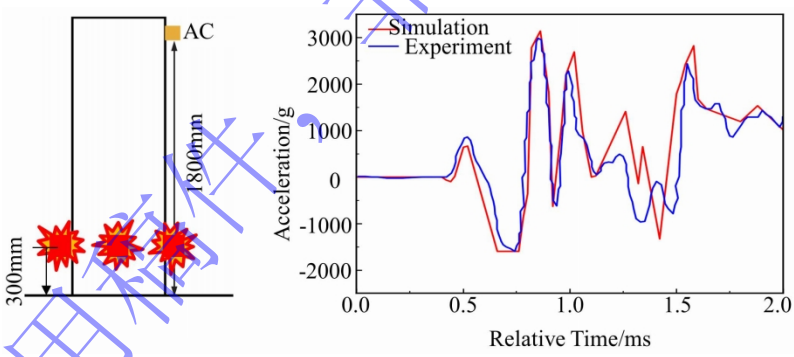

(b) Acceleration time-history curves

图 2 仿真结果与实验结果对比

Fig.2 Comparison between simulation results and experimental results

表 1 混凝土材料参数

Table 1 Material parameters for concrete

参数	值
密度/kg·m^{-3}	2500
杨氏模量/MPa	3×10^4
泊松比	0.2
膨胀角	30
偏心率	0.1
初始等双向压缩屈服应力与初始单向压缩屈服应力	1.16

录用稿件，非最终出版稿

的比值	
拉伸子午线与压缩子午线上第二应力不变量的比值	0.6667
压缩屈服应力/MPa	1.71
压缩强度/MPa	20.13
压缩断裂应变	0.007
拉伸屈服应力/MPa	0.24
拉伸强度/MPa	2.01
拉伸断裂应变	0.0005

表 2 钢筋材料参数

Table 2 Material parameters for steel

参数	值
密度/kg·m^{-3}	7850
杨氏模量/MPa	2.05×10^5
泊松比	0.3
屈服应力/MPa	450
极限强度/MPa	600
极限强度对应应变	0.5

表 3 炸药材料参数

Table 3 Material parameters for the explosive

参数	值
密度/kg·m^{-3}	1630
爆轰波速度/m·s^{-1}	6930
A (爆炸物常数/MPa)	373770
B (爆炸物常数/MPa)	3747.1
ω (爆炸物常数)	0.37
R_1 (爆炸物常数)	4.15
R_2 (爆炸物常数)	0.95
爆轰能量密度/J·kg^{-1}	4.29×10^9
爆轰前体积模量/MPa	1290

2.2 钢筋混凝土柱毁伤预测代理模型

网格由节点及其拓扑关系组成，而图（Graph）本质上是一种定义节点集合及其连接的数据结构。基于此，RC 柱模型的几何网格可被视为一种图结构数据。

图结构数据可表示为G = (V, E)，其中V是网格节点的集合，E是由网格中这些节点之间的连接所确定的边的集合。如图 3 所示，图结构数据与基于像素的传统网格数据相比，图数据具有更优的数据保真性。对于像素数据，其在处理原始数据时，栅格化插值计算使得数据精度丢失，同时破坏了原网格节点数据空间的相对分布特征，不能有效近似曲线上的数据分布；而通过图拓扑结构，图节点与网络节点一一对应，完美融合网络节点间的空间关系、全面包含内在特征，从而提高了代理模型的预测性能。

录用稿件，非最终出版稿

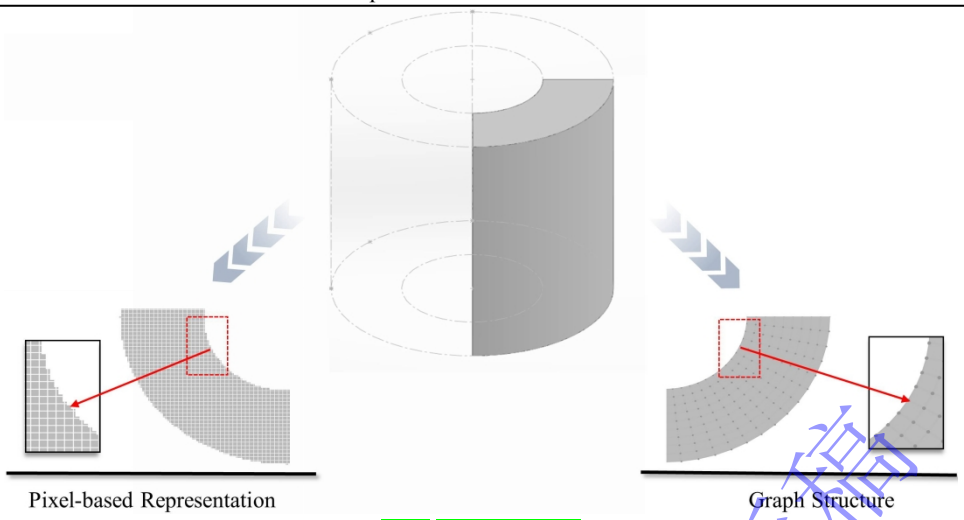

图 3 数据结构比较

Fig.3 The Comparison of the two representation methods on a small scale

为实现离散网格节点向图数据的有效转换、促进模型的特征学习，本研究设计了一种模型框架，该框架由编码器、处理器和解码器三部分组成，如图 4 所示。编码器采用全连接神经网络（Fully Connected Neural Network, FNN），将初始网格节点分布转换为图结构状态。处理器则利用图神经网络[22]的消息传递机制（即 GNN 的邻居节点聚合策略），通过迭代计算节点之间的空间关系及相互作用，以获取图的内在特征。最终，解码器提取这些内在特征，并将其映射回相应的节点，从而预测整个配置的预期状态，即爆炸后钢筋混凝土柱的结构响应。该解码过程同样通过全连接神经网络（FNN）实现。

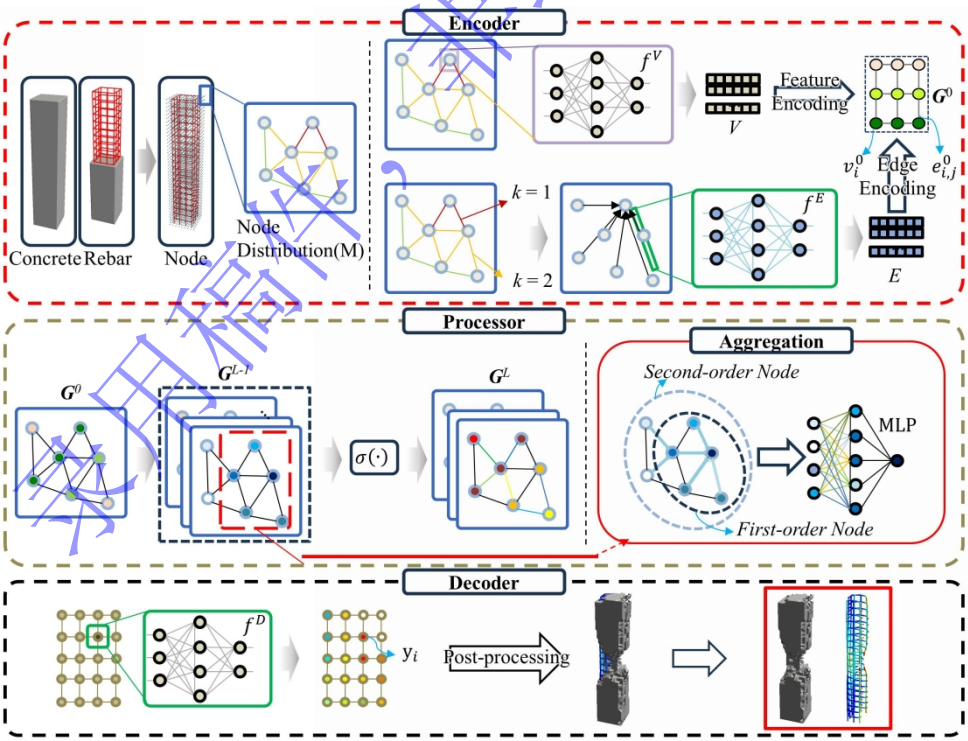

图 4 代理模型的框架图

Fig.4 The framework diagram of the GNN-based RC column damage prediction model

录用稿件，非最终出版稿

在代理模型中，编码器负责将钢筋混凝土柱的节点分布(M)编码为多重图$G=(V,E,\mathrm{f})$。其中，节点集合V包含了每个节点v_i的空间位置信息，所有节点v均通过一个全连接神经网络(f^V)进行编码，从而得到$v_i=\mathrm{f}^V(m_i)$；E 表示连接节点对v_i和v_j的边的集合，每条边e_{ij}封装了节点之间的相互作用信息。这些边构成了图神经网络（GNN）中消息传递的通道。边的生成过程由邻近度k决定，即每个节点都与其k个最近邻节点相连。同样，边也通过一个全连接神经网络进行编码，得到$e_{ij}=\mathrm{f}^E(m_i)$。此外，引入一组图特征r来表示爆炸条件和各组件的强度参数。例如，这些特征可能包括钢筋混凝土柱的配筋率、不同的爆炸当量以及起爆位置等难以明确建模的参数。这些特征用于初始化图的节点属性。随后，这些特征与图 G 中的每个节点进行拼接处理。

处理器由 L 个相同的信息传递模块构成，其主要功能是传输并迭代更新节点特征信息。这些模块构成了图神经网络（Graph Neural Network, GNN）的核心计算单元。经过L轮信息传递后，处理器逐步将原始输入的几何信息G^0转换为高度编码的特征图G^L。每层的信息传递机制概括如下：首先，利用聚合函数对当前节点的邻居信息进行汇总，然后将汇总结果与节点自身的特征信息进行融合，最后通过更新函数对当前节点的特征表示进行更新。随着信息传递过程的迭代，节点将逐步获取更多关于其邻居的信息。从数学角度来看，聚合规则是通过多层感知机（Multilayer Perceptron, MLP）实现的，其表达式为：

$$\mathrm{G}^{l+1}=\sigma\left(W_1G_i^l+W_2\cdot Aggregate_k G_j^l\right), j\in\mathcal{N}(i) \tag{1}$$

其中，W为可学习的权重矩阵，$\sigma(\cdot)$为激活函数，在本研究中使用 ReLU 激活函数，而“*Aggregate*”则代表聚合函数。下标k表示从给定节点i出发向外k步的距离范围，$\mathcal{N}(i)$表示节点i的邻域集合。

在图神经网络的每层信息传递过程中，节点i的新特征表示G_{i}^{l+1}是由其自身在第l层的特征表示G_{i}^l与其邻域节点在第l层的特征表示经过聚合函数处理后的结果共同决定的。其中，权重矩阵W_1和W_2分别用于对节点自身特征和邻域特征进行加权，而激活函数$\sigma(\cdot)$则引入了非线性，使得模型能够学习到更加复杂的特征表示。

模型的最后一个阶段为解码器（Decoder），其主要任务是从处理器生成的最终特征图中提取有关组件结构响应的具体预测结果。解码器从处理器输出的最终特征图G^L中获取每个节点的特征表示v_i^L，并利用这些特征来预测每个节点的状态y_i，其中解码预测使用全连接神经网络（FNN）来实现，其具体过程为$\mathrm{y_i}=\mathrm{f}^D(\mathrm{v_i^L})$。在本研究中，训练标签包括了混凝土组件在爆炸破坏后节点位置与破坏前节点位置之间的相对位移信息。因此，框架结构的最终状态是由初始节点状态和模型输出状态的叠加形成的，即：

$$\mathrm{m}_i^L=\mathrm{m}_i^0+\mathrm{y}_i \tag{2}$$

其中，m_i^L为模型的最终输出状态，m_i^0为初始节点状态，y_i为模型预测的位移状态。这种叠加方式能够精准地反映爆炸荷载作用下钢筋混凝土柱的结构响应，为后续的结构分析和设计提供重要参考依据。

2.3 数据集设计

为保证模型能够在多种不同工况下进行准确预测，训练数据必须覆盖广泛的特征场景。通过提取和识别这些数据特征，模型能够学习目标构件在不同条件下损伤变化的规律，从而实现自适应预测的目标。因此，本研究构建的数据集涵盖了构件的多种爆炸当量、起爆位置和配筋率等信息。此外，数

录用稿件，非最终出版稿

据集还记录了在不同配筋率、爆炸当量和起爆位置组合下计算得到的固定结构钢筋混凝土（Reinforced Concrete, RC）柱的结构响应。

考虑到钢筋混凝土柱绕 z 轴具有 90° 旋转对称性，起爆位置只需设置在一个面上即可。同时，为了涵盖接触爆炸和非接触爆炸的情况，起爆点沿水平轴距离柱表面分别设置在 0、2L 和 4L 的位置，具体如图 5 所示。对于每个起爆位置，考虑了五种炸药爆炸当量[1kg, 2kg, 4kg, 8kg, 16kg]，并通过字符如[Ⅰ, Ⅱ, Ⅲ, Ⅳ, Ⅴ]进行区分。钢筋混凝土柱的配筋率包括八个值，每个柱的配筋数量相同，通过改变钢筋截面积改变配筋率，利用字符[0.4, 0.6, 0.8, 1.0, 1.2, 1.4, 1.6, 1.8]进行区分。所有钢筋混凝土柱的网格划分方式均相同，以确保结果的一致性与可比较性。

在最终构建的数据集中，每个案例随机分配一种爆炸当量、起爆位置和配筋率信息的组合。这种设计方法能够确保数据集的多样性和代表性，为模型的训练和验证提供了坚实的基础。通过在这些多样化的数据集上进行训练，模型能够学习到不同工况下钢筋混凝土柱损伤变化的规律，从而在实际应用中实现更准确、更可靠的预测。

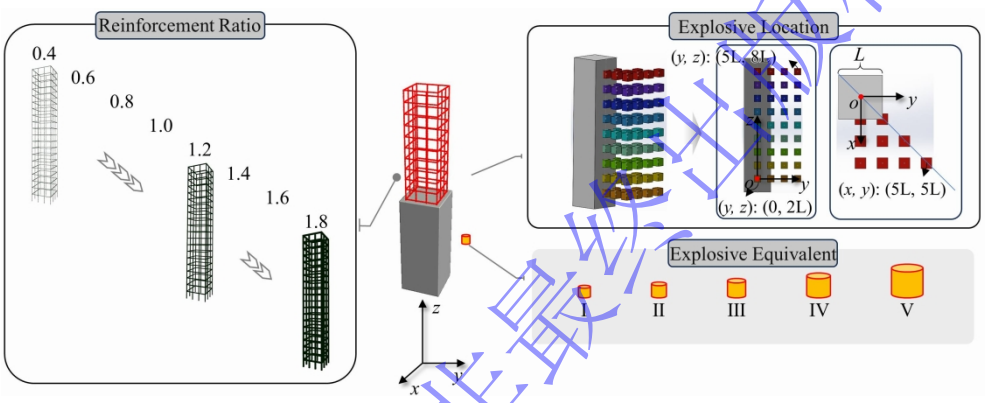

图 5 训练数据集工况设计

Fig.5 Configuration of the Training Dataset

就单个案例样本而言，模型的输入数据结构为[n,3]，其中 n 表示案例中的节点数量，3 对应每个节点的空间位置信息（x, y, z 坐标）。此外，由于爆炸位置分布较为密集，不同案例之间的特征差异相对较小，这使得模型难以根据细微的位置变化自适应地预测损伤。为了解决这一问题，本研究引入了基于相对距离的额外特征，以补充输入数据中的节点坐标信息。相对距离是指钢筋混凝土柱上每个节点到爆炸中心的最短距离，如图 6 中的“额外特征”部分所示。这为模型提供了足够的信息以区分不同案例之间的特征差异。此外，额外特征还包括爆炸当量信息和配筋率。最终，模型的单样本输入数据结构变为[n,3+3]，其中“+3”对应三类特征，分别为相对距离、爆炸当量和配筋率。

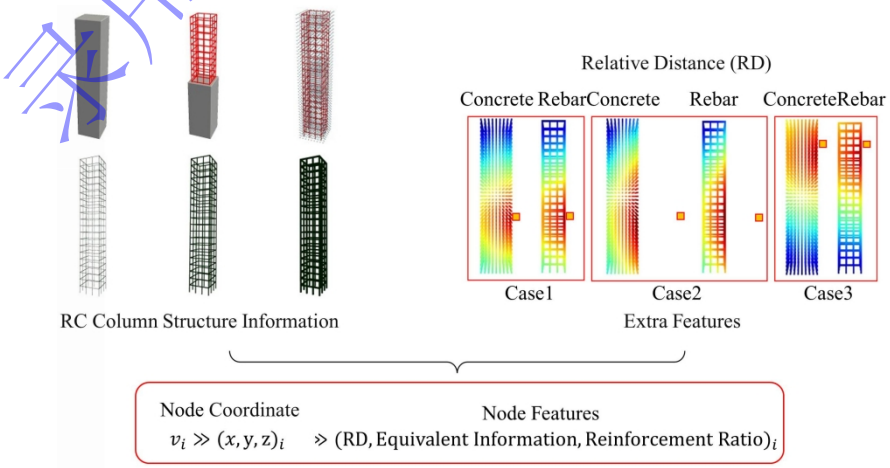

图 6 数据集设计与额外特征

录用稿件，非最终出版稿

Fig.6 The dataset design and the additional feature

对于模型输出，本研究设计的数据表示爆炸后节点位置相对于破坏前位置的相对位移信息，输出结构同样为[n,3]。所有输入特征均通过最大最小归一化方法独立归一化，以确保不同类型特征之间的尺度一致性。同时，所有输出特征通过全局标准化处理，这增强了模型收敛过程的稳定性，并提高了其泛化能力[23-25]。最后，输入和输出数据配对，以支持图神经网络（GNN）模型的端到端训练。

训练和测试数据集总共包含 2,652 个样本，其中 265 个样本分配给测试集，用于测试模型泛化能力、评估模型的最终性能，占总样本量的 10%。在剩余 90%的 2387 个样本中，20%（477 个）用于模型结构的选择与超参数的调优，80%（1910 个）用于训练模型，最终获得最优化的模型参数。通过这种数据划分和处理方式，可以全面评估模型在不同工况下的性能表现，为后续的结构分析和设计提供可靠的依据。

2.4. 代理模型训练结构

初始学习率设置为 1e-4，并使用指数衰减策略逐渐降低学习率。学习率衰减的数学表达式为：

$$\mathrm{lr}_{init}{}^{new} = \mathrm{lr}_{init}{}^{old} \times \mathrm{lr}_{decay}{}^{global_{step}/1e6} \tag{3}$$

其中，lr_{init}为学习率的初始值，lr_{decay}为学习率调整乘数的底数，设置为 0.1，$global_{step}$为模型在训练过程中完成的总迭代次数。

损失函数选用 Smooth-L1 损失函数，其数学表达式为：

$$l_i = \begin{cases} 0.5(\tilde{y}_i - y_i)^2/beta, & if\,|\tilde{y}_i - y_i| < beta \\ |\tilde{y}_i - y_i| - 0.5 \times beta, & otherwise \end{cases} \tag{4}$$

其中，$\tilde{y}_i$为模型预测值，y_i为真实值，参数$beta$定义了函数的分段点，其默认值为 1。

最后，本研究采用 Adam 优化器[26]对损失函数值进行优化。Adam 优化器是一种基于梯度下降的优化算法。整个训练过程在单个 NVIDIA GeForce RTX 4090 图形处理器上大约耗时 1 小时。模型的超参数设置如表 4 所示。

表 4 训练超参数与代理模型结构

Table 4 The structure of the GNN model and training hyperparameters

超参数	值
MLP 隐藏层层数	2
隐藏层大小	128
消息传递步数	8
连接半径(k)	7
节点特征数	3
激活函数	ReLU
批量大小	2
Beta	1
学习率	1e-4

3 模型分析

3.1 模型评价标准

平均绝对误差（Mean Absolute Error, MAE）和均方根误差（Root Mean Squared Error, RMSE）都是度量预测模型误差的方法。平均绝对误差对异常值包容性强，而均方根误差对异常值敏感，两者通常搭配使用以全面评估模型的性能。其定义如下：

录用稿件，非最终出版稿

$$E_{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{\tilde{y}_i-y_i}{y_i}\right|\times 100\% \tag{5}$$

$$E_{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(\tilde{y}_i-y_i)^2}\times 100\% \tag{6}$$

其中，n 表示每个计算案例中的节点。

3.2. 爆炸效应预测

在 3.2 节将展示代理模型在不同爆炸场景下对钢筋混凝土柱损伤状况的预测性能。为了便于结果的可视化分析，本研究对模型输出进行了预处理：移除了位移大于 0.25L 的混凝土单元和位移超过 0.8L 的钢筋单元。这种处理方式更关注爆炸作用后 RC 柱残余的混凝土单元和钢筋单元，有助于突出显示损伤较为严重的区域，从而更直观地评估模型的预测效果。

3.2.1 可视化结果

为验证模型可自适应爆炸位置的毁伤预测能力，本研究在接触爆炸与非接触爆炸两种工况下各选取多个位置工况进行预测，通过与数值模拟结果对比，分析模型在不同工况下预测结果的误差以及造成误差的主要原因。

(1) 接触爆炸

在接触爆炸工况下，沿 z 轴依次从高到低改变爆炸位置，得到 5 种爆炸结果，各工况的爆炸位置信息以及相应的误差统计结果如表 5 所示。

表 5 接触爆炸下 GNN 模型预测与 Abaqus 仿真结果误差

Table 5 The error between GNN model prediction and Abaqus simulation results under contact explosion

序号	爆炸位置	MAE/%		RMSE/%	
	(*x*, *y*, *z*)	混凝土	钢筋	混凝土	钢筋
1	(2.68,0,16)	3.02	1.97	9.87	4.98
2	(2.68,0,13)	3.18	2.22	10.96	4.62
3	(2.68,0,10)	2.66	2.48	9.01	4.56
4	(2.68,0,7)	2.75	1.98	9.75	3.54
5	(2.68,0,4)	2.33	1.37	8.67	2.96
方差		0.0870	0.1354	0.6289	0.5729

录用稿件，非最终出版稿

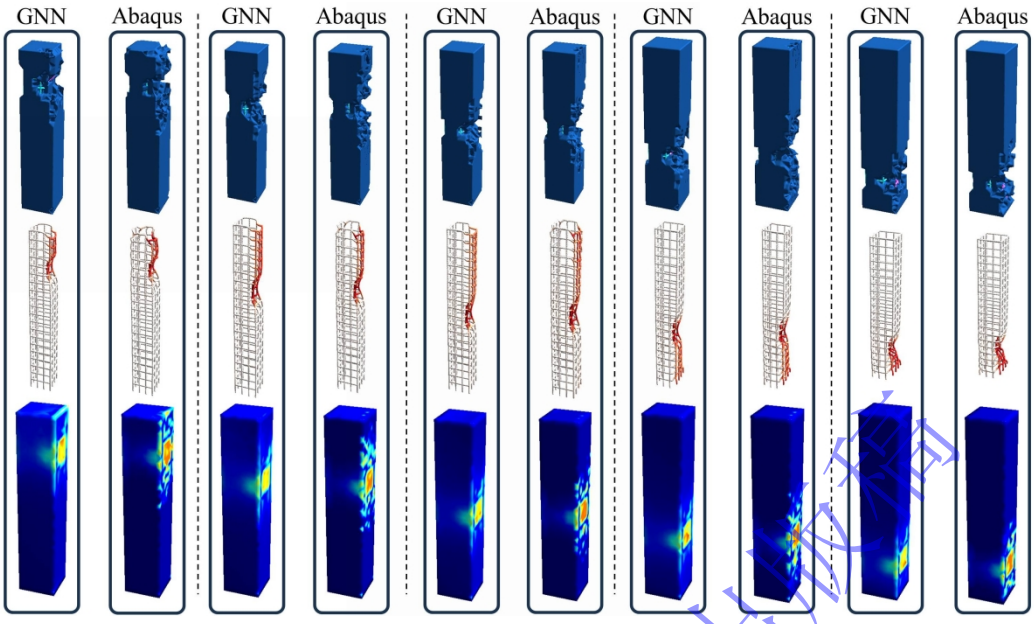

图 7 接触爆炸下 GNN 模型与 Abaqus 仿真可视化结果对比

Fig.7 Visualization comparison between GNN model and Abaqus simulation under contact explosion conditions

在接触爆炸工况下观察 Abaqus 仿真可视化结果，结果如图 7 所示，可观察到 RC 柱迎爆面的爆炸位置附近，混凝土单元损失严重，钢筋单元向内凹陷，严重程度随着远离爆炸中心衰减；在 RC 柱背爆面，混凝土单元部分损失，钢筋单元未发生明显损伤。对比 GNN 模型与 Abaqus 仿真可视化结果，可观察到无论是迎爆面还是背爆面，混凝土单元损失位置与损失严重程度高度相似，钢筋单元的弯曲凹陷位置相同程度较高。观察混凝土单元损失云图，主要损伤区域轮廓重合程度高。随爆炸位置变化，混凝土单元主要损伤区域与仿真结果依旧高度匹配，证明了模型对不同打击位置的自适应预测能力。再对两种方法进行误差分析，结果如表 5 所示，5 种爆炸位置之间混凝土和钢筋预测平均绝对误差的方差为 0.0870 和 0.1354、均方误差的方差为 0.6289 和 0.5729，不同爆炸位置下预测误差值之间的方差较低，没有偏移较大的异常预测。由此可见，GNN 模型学习到了强动载荷下 RC 柱的内在响应机理，实现了在接触爆炸工况下对爆炸位置的自适应能力。

(2) 非接触爆炸

在非接触爆炸工况下，依次由远到近改变爆炸距离，得到 4 种爆炸结果，爆炸具体位置信息以及模型预测误差结果记录在表 6 中。

表 6 非接触爆炸下 GNN 模型预测与 Abaqus 仿真结果误差表

Table 6 The error between GNN model prediction and Abaqus simulation results under non-contact explosion

序号	爆炸位置	MAE/%		RMSE/%	
	(*x*, *y*, *z*)	混凝土	钢筋	混凝土	钢筋
1	(6,4,2)	2.13	1.44	5.87	2.63
2	(6,10,6)	1.29	0.47	4.79	0.64
3	(6,10,2)	2.32	1.67	5.91	3.05
4	(10,7,0)	1.62	1.33	3.55	1.93
方差		0.1664	0.2063	0.9320	0.8346

录用稿件，非最终出版稿

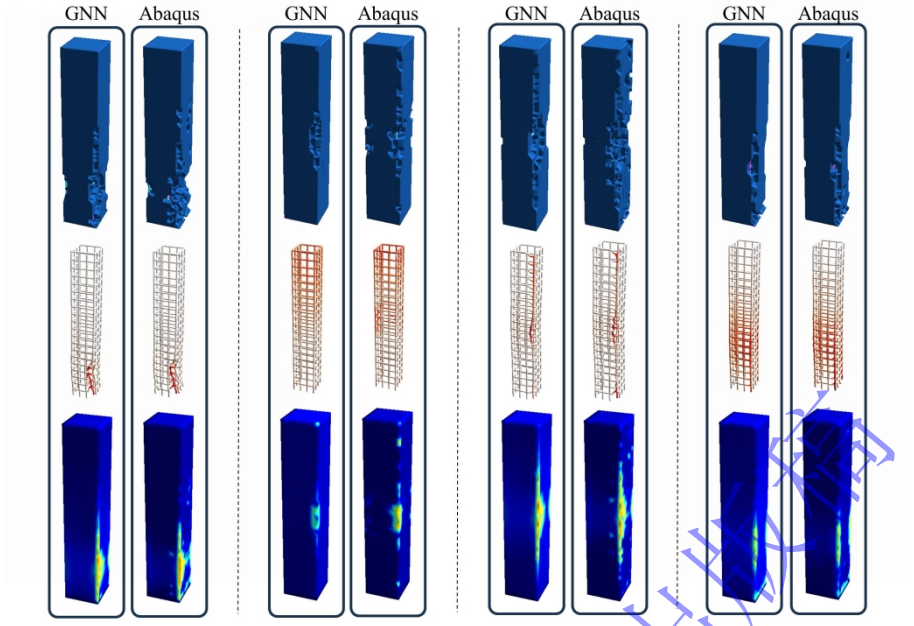

图 8 非接触爆炸下 GNN 模型与 Abaqus 仿真可视化结果对比

Fig.8 Visualization comparison between GNN model and Abaqus simulation under non-contact explosion

在非接触爆炸工况下，观察 Abaqus 仿真可视化结果，结果如图 8 所示， 冲击波对 RC 柱的作用虽有所减弱，但在迎爆面，混凝土单元仍损失严重，钢筋单元弯曲损伤程度随爆炸距离变远而逐渐减轻；背爆面混凝土单元和钢筋单元的损失轻微。对比 GNN 模型与 Abaqus 仿真可视化结果，可观察到无论是迎爆面还是背爆面，混凝土单元损失位置与损失严重程度高度相似，钢筋单元的弯曲位置相同且程度相似，随爆炸距离变化的损伤程度趋势相同。观察混凝土单元损失云图，损失核心区域轮廓重合程度高。随爆炸位置变化，混凝土单元损失核心区域依旧高度匹配，证明了模型对不同打击位置的自适应预测能力。再对两种方法进行误差分析，结果如图 9 所示，4 种爆炸距离间的混凝土和钢筋预测平均绝对误差的方差为 0.1664 和 0.2063，均方误差的方差为 0.9320 和 0.8346。不同爆炸距离下，预测误差值之间的方差较低，没有偏移较大的异常项。由此可见，GNN 模型学习到了强动载荷下 RC 柱的内在反应机理，实现了在非接触爆炸工况下对爆炸距离的自适应能力。

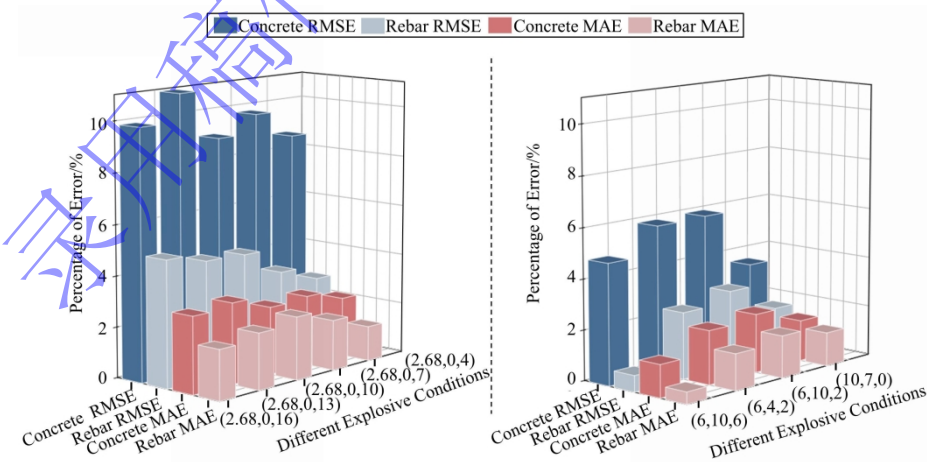

(a)接触爆炸工况 (b)非接触爆炸工况

图 9 接触爆炸与非接触爆炸误差指标柱状图

Fig.9 Contact explosion and non-contact explosion error index histogram

更进一步，通过图 9 直观呈现了模型在各个工况下的预测误差。在接触与非接触爆炸工况下，采用相同误差评判标准时，混凝土的误差值大于钢筋。其原因在于混凝土韧性低于钢筋，在强动载荷

录用稿件，非最终出版稿

作用下不仅破碎程度更高，且碎裂后的游离块体位移量远大于钢筋，其运动规律也更难预测。

3.2.2 多工况分析

配筋率与爆炸当量是影响 RC 构件在爆炸载荷下毁伤特性的重要因素，调整二者是研究其爆炸响应机理的重要手段，亦可用以检验模型对 RC 构件爆炸响应规律的学习能力及对这两个参数的自适应能力。

(1) 爆炸当量规律

在测试模型对爆炸当量的自适应表现中，采用控制变量法，通过固定配筋率与爆炸位置依次增加爆炸当量，具体规律如图 10 所示。

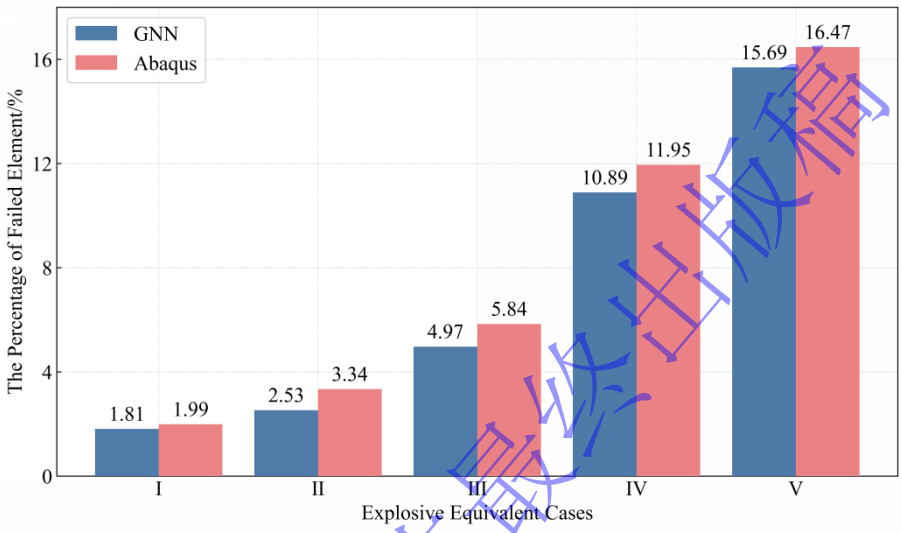

图 10 RC 柱单元损失百分比随当量变化趋势图

Fig.10 Trend diagram of RC column element percentage with equivalent change

分析图 10 中数值仿真爆炸趋势可得，随爆炸当量逐步增加，RC 构件在强动载荷作用下，其受冲击波影响程度增强，混凝土单元与钢筋单元破坏崩落程度加剧，随之单元损失百分比上升。对比数值仿真与代理模型的表现，可看出代理模型预测与数值仿真结果相近；且呈现出随爆炸当量增加单元损失百分比上升的趋势。这说明代理模型能够捕捉到爆炸当量工况变化下的内在规律。

(2) 配筋率规律

在测试模型对配筋率的自适应表现中，采用控制变量法，通过固定爆炸当量与爆炸位置依次增加配筋率，具体规律如图 11 所示。

录用稿件，非最终出版稿

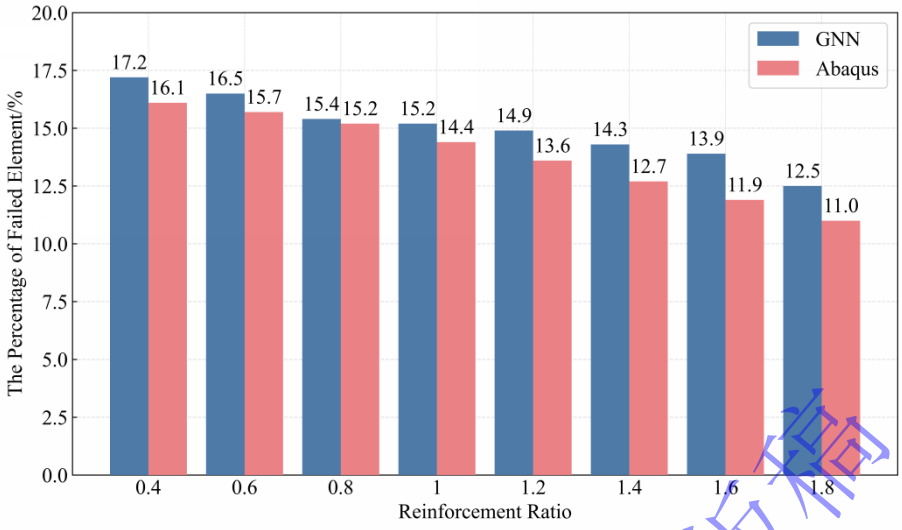

图 11 RC 柱单元损失百分比随配筋率变化趋势图

Fig.11 The change trend of RC column unit percentage with reinforcement ratio

分析图 11 中数值仿真的单元损失百分比趋势，可以得出随着配筋率的增加，RC 柱构件的损失百分比有所降低。由于 RC 柱整体的损失变化是钢筋与混凝土共同耦合作用的结果，所以单从 RC 柱的整体单元损失百分比的角度看还不够全面。配筋率变化最直接的影响对象就是钢筋本身，在强动载荷冲击下，钢筋的单元损失百分比最能直接反映配筋率变化对应的内在规律。因此，需要单独提取分析钢筋的单元损失百分比趋势，具体变化规律如图 12 所示。

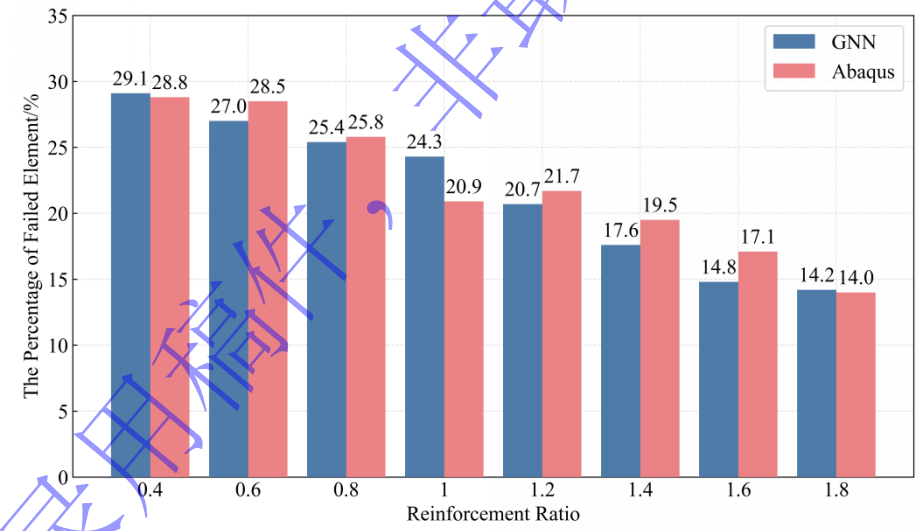

图 12 钢筋单元损失百分比随配筋率变化趋势图

Fig.12 Trend diagram of reinforcement unit percentage with reinforcement ratio

观察图 12 中数值仿真结果下钢筋单元损失百分比趋势可得，随配筋率增加，钢筋单元损失百分比降低。其原因在于随配筋率增加，钢筋的拉伸极限增加，从而钢筋损失单元数也随之降低。对比数值仿真与代理模型的表现，可看出代理模型预测与数值仿真结果相近；且呈现出随配筋率增加钢筋单元损失百分比降低的趋势。这说明代理模型能够捕捉到配筋率参数变化下的内在规律。

3.3. 模型自身能力评估

在 3.3 节将对比不同输入数据缺失情况下的模型性能表现，进而分析出主导模型性能的输入数据；再对比分析代理模型与传统数值仿真方法的用时成本，并分析模型的稳定性。

3.3.1 主导影响因素分析

录用稿件，非最终出版稿

GNN 模型在训练阶段融合了多个数据特征以辅助模型学习潜在的特征表达方式，为进一步验证各个数据特征在模型训练时贡献的权重，本小节独立分析了每个特征对模型训练结果的影响。输入模型的数据共可分为如下 5 类：节点坐标数据、爆炸当量数据、配筋率数据、爆炸位置数据、爆炸相对距离数据。依次制作缺失上述一种数据的数据集，并重新训练模型，对比同种工况下的模型性能表现，具体表现如图 13 所示。

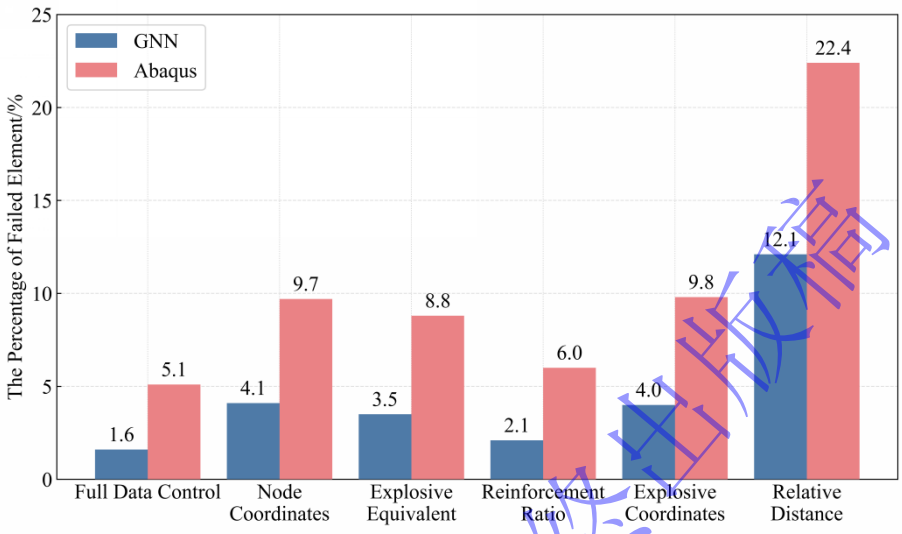

图 13 模型影响因素分析图

Fig.13 Analysis chart of model influencing factors

分析图 13 中各因素表现得出，相对距离数据在模型预测中至关重要，其缺失对模型性能的影响显著高于其他数据类型。这是由于相对距离数据直接为每个钢筋和混凝土单元赋值，单元与单元间的相对距离数据差异明显，更便于代理模型识别工况差异。然而当这一数据缺失时，模型难以适应新的数据分布情况，在训练时对不同工况间的区分能力严重下降，进而导致模型难以捕捉到爆炸冲击下钢筋与混凝土的内在变化关系，最终致使模型预测性能显著下降。

3.3.2 模型耗时成本分析

深度学习的端到端训练模式使代理模型能够跨过数值模拟中的层层推理过程，从而极大地提升爆炸毁伤预测效率。表 7 记录了 GNN 模型与 Abaqus 数值仿真在 5 种不同爆炸当量、爆炸位置和钢筋混凝土柱配筋率组合的各种场景下，具体用时成本。

表 7 GNN 模型与 Abaqus 数值仿真耗时对比

Table 7 Comparison of time-consuming between GNN model and Abaqus numerical simulation

模型	时间/s				
	Case 1	Case 2	Case 3	Case 4	Case 5
GNN	0.055	0.054	0.055	0.054	0.054
Abaqus	2100	2220	2160	2220	2520

表中结果显示，在损伤评估过程中，代理模型的计算效率显著优于传统有限元分析软件 Abaqus。代理模型完成单次损伤评估所需时间不超过 0.06 秒，而 Abaqus 软件则需要更多时间。代理模型在单次损伤评估效率方面较 Abaqus 软件的提升约为 4 个数量级。其结果表明，代理模型在计算效率方面显著高于传统有限元模拟方法。通过这种高效的计算能力，代理模型在抗爆结构设计优化、智能防护系统研发以及相关工程应用领域展现出巨大的潜力，能够有效提升设计效率、降低成本并拓展技术应用场景。

3.3.3 模型稳定性分析

为验证代理模型的稳定性，本研究选取了不同配筋率、不同爆炸当量、不同爆炸位置的 150 种

录用稿件，非最终出版稿

工况进行预测。为量化不同爆炸位置的差异，采用其与 RC 柱重心之间的绝对距离，作为表征指标。汇总结果如图 14 所示。

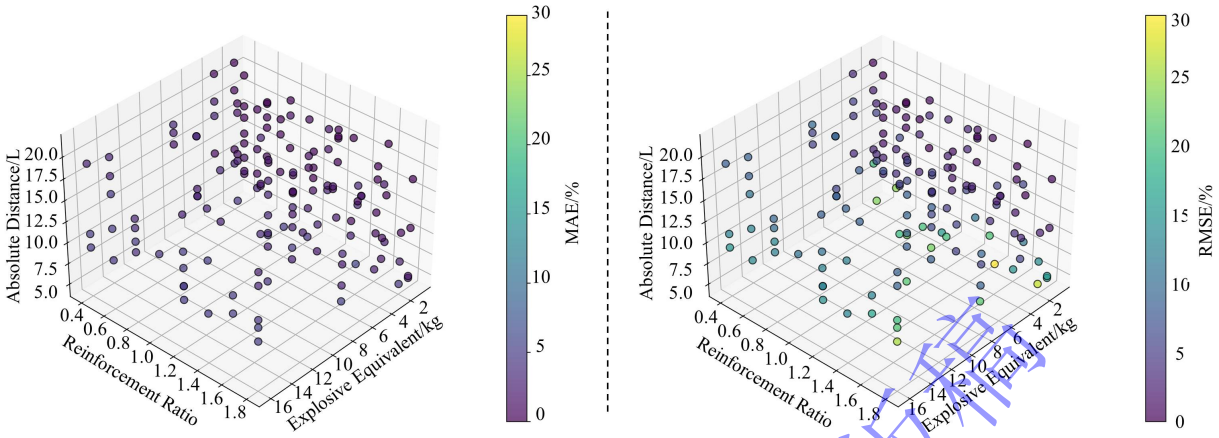

(a)MAE (b)RMSE

图 14 模型多案例稳定性表现

Fig.14 Model multi-case stability performance

从图 14 中可直观地观察到随爆炸当量降低，冲击波对 RC 柱的载荷有所减弱，使 RC 柱损失单元数下降，进而导致预测难度降低、预测误差降低、案例点颜色加深；同样，随着爆炸绝对距离变远，冲击波在空气中衰减，其对 RC 柱的载荷同样有所减弱，但冲击波的衰减速度缓慢，进而导致 Abaqus 仿真出的 RC 柱损失单元数下降同样缓慢，最终导致随绝对距离变远，预测误差下降缓慢，案例点颜色加深趋势较小；随配筋率的增加，钢筋抗拉强度增强，但最外围的混凝土单元依旧承受同样的冲击波载荷，因此 Abaqus 仿真结果中 RC 柱损失单元数变化不明显，预测难度相同也就难以看出随配筋率变化的算例点颜色趋势。

进一步地对图 14 中散点分布进行分析可知，在绝大多数案例中，其 MAE 指标均低于 5%，表明模型预测值与实际值之间的绝对误差相对较小，整体预测精度较高。大部分案例的 RMSE 指标处于 10%以下，仅有少部分案例的 RMSE 超过 10%。然而，这少部分 RMSE 较高的案例，其对应的 MAE 依然维持在 5%以下，进一步印证了模型在整体预测上具备较高的准确性，出现偏差的仅为个别单元。从 150 种案例的综合表现来看，无论是 MAE 还是 RMSE 指标，均展现出较为理想的结果，这充分说明所构建的模型具有较强的稳定性。在实际应用中，可凭借其稳定的性能，为相关研究或实践提供可靠的数据支持与决策依据。

4 结论

本研究基于图神经网络（GNN）构建了钢筋混凝土柱在爆炸冲击载荷下的损伤预测模型。通过 Abaqus 仿真获取基础数据并验证其可靠性后，搭建并训练了爆炸冲击 RC 构件结构响应代理模型。本研究利用图数据结构表征构件几何、GNN 的消息传递机制捕捉爆炸冲击波在结构内的传播路径，实现对钢筋混凝土柱爆炸结构响应的准确预测。具体结论如下：

(1) 利用图拓扑法将构件几何的离散网格表示为图数据结构。与传统像素化数据预处理方法相比，该图拓扑法能更精细地捕捉局部结构间的复杂关系。

(2) GNN 模型分别对不同配筋率、不同爆炸当量、不同爆炸位置的 150 种工况进行预测，结果显示模型的平均绝对误差（MAE）指标均低于 5%，预测值与实际值之间的绝对误差相对较小。大部分案例的均方根误差（RMSE）指标处于 10%以下。从综合表现来看，模型在

录用稿件，非最终出版稿

整体预测上具备较高的准确性，能够为相关研究或实践提供一定的技术支持。

(3) GNN 模型采用端到端预测框架，省去了传统模拟的中间步骤，提高了预测速度。GNN 模型在单次损伤评估中的用时约为 55 毫秒，而传统的 Abaqus 仿真软件仿真计算相同的工况用时约为 40 分钟。相比之下，GNN 模型的预测速度相比 Abaqus 仿真提升了约 4 个数量级，且训练完成后的 GNN 模型还可快速适用于多种场景。

同时值得注意的是，GNN 模型目前仍存在若干局限。首先，模型尚未考虑轴压对钢筋混凝土柱受力和破坏的影响，这在一定程度上限制了模型在真实复杂受力环境中的适用性。其次，模型的适用范围较为有限，仅适用于柱状构件在爆炸荷载下的响应预测，若应用于其他结构形式（如框架或板壳），需重新进行数据制备与模型再训练。此外，该方法依赖数据驱动，未能显式嵌入爆炸冲击破坏的物理机制，模型的可解释性目前仍高度依赖于训练数据所隐含的统计规律。在后续工作中，将考虑引入轴压比等关键参数，并探索融合物理机理的混合建模方法，以增强模型的准确性与可解释性。

参考文献

[1] 马春茂，孙卫平，李炎，等. 武器装备毁伤评估研究进展[J]. 火炮发射与控制学报，2019, 40(4): 96–101.
MA C M, SUN W P, LI Y, et al. Research progress in damage assessment of weapon equipment [J]. Journal of Gun Launch and Control, 2019, 40(4): 96–101.

[2] CHAI C, REN C, YIN C, et al. A multifeature fusion short-term traffic flow prediction model based on deep learnings [J]. Journal of Advanced Transportation, 2022, 2022(1): 1702766.

[3] WEYN J A, DURRAN D R, CARUANA R. Improving data - driven global weather prediction using deep convolutional neural networks on a cubed sphere [J]. Journal of Advances in Modeling Earth Systems, 2020, 12(9): e2020MS002109.

[4] 张帆，张恒，李卓越，等. 基于深度学习方法的圆柱绕流实验缺失数据重构[J]. 物理学报，2025, 74(7): 074701-1-074701-13.
ZHANG F, ZHANG H, LI Z Y, et al. Reconstruction of gappy data in cylindrical flow experiments based on deep learning method [J]. Acta Physica Sinica, 2025, 74(7): 074701-1-074701-13.

[5] LIU H, ZHANG G. Enhancing efficiency and energy optimization: Data-driven solutions in process industrial manufacturing [J]. EAI Endorsed Transactions on the Energy Web, 2024, 11(1).

[6] UNNO K, MIKAMI A, SHIMIZU M. Damage detection of truss structures by applying machine learning algorithms [J]. GEOMATE Journal, 2019, 16(54): 62-67.

[7] BANG H, LEE T H, LEE G C, et al. Strain-based fault detection of bolted truss structures using machine learning [J]. Advances in Mechanical Engineering, 2020, 12(11): 1687814020971890.

[8] MAI H T, KANG J, LEE J. A machine learning-based surrogate model for optimization of truss structures with geometrically nonlinear behavior [J]. Finite Elements in Analysis and Design, 2021, 196: 103572.

[9] ALMUSTAFA M K, NEHDI M L. Machine learning model for predicting structural response of RC columns subjected to blast loading [J]. International Journal of Impact Engineering, 2022, 162: 104145.

[10] ALMUSTAFA M K, NEHDI M L. Novel hybrid machine learning approach for predicting structural response of RC beams under blast loading [C]// Structures. Elsevier, 2022, 39: 1092-1106.

[11] ALMUSTAFA M K, NEHDI M L. Machine learning prediction of structural response of steel fiber-reinforced concrete beams subjected to far-field blast loading [J]. Cement and Concrete Composites, 2022, 126: 104378.

[12] ALMUSTAFA M K, NEHDI M L. Machine learning prediction of structural response for FRP retrofitted RC slabs subjected to blast loading [J]. Engineering Structures, 2021, 244: 112752.

[13] ALMUSTAFA M K, BALOMENOS G P, NEHDI M L. Data-driven reliability framework for qualitative damage states of reinforced concrete beams under blast loading [J]. Engineering Structures, 2023, 294: 116803.

录用稿件，非最终出版稿

[14] ZHOU X Q, HUANG B G, WANG X Y, et al. Deep learning-based rapid damage assessment of RC columns under blast loading [J]. Engineering Structures, 2022, 271: 114949.

[15] ABD-ELHAMED A, ALKHATIB S, ABDELFATTAH A M H. Prediction of blast-induced structural response and associated damage using machine learning [J]. Buildings, 2022, 12(12): 2093.

[16] TRAN P L, TRAN V L, KIM J K. Mid-span displacement and damage degree predictions of RC beams under blast loading using machine learning-based models [C]// Structures. Elsevier, 2024, 65: 106702.

[17] AHMED B, PARK T, JEON J S. Blast response and damage assessment of reinforced concrete slabs using convolutional neural networks [J]. International Journal of Damage Mechanics, 2023: 10567895231204640.

[18] LUBLINER J, OLIVER J, OLLER S, et al. A plastic-damage model for concrete [J]. International Journal of solids and structures, 1989, 25(3): 299-326.

[19] LEE J, FENVES G L. Plastic-damage model for cyclic loading of concrete structures [J]. Journal of engineering mechanics, 1998, 124(8): 892-900.

[20] HILLERBORG A, MODÉER M, PETERSSON P E. Analysis of crack formation and crack growth in concrete by means of fracture mechanics and finite elements [J]. Cement and concrete research, 1976, 6(6): 773-781.

[21] 武伟超,夏柳,潘艾刚,等. 多点同时爆炸对钢筋混凝土方柱构件的毁伤特性[J]. 爆炸与冲击,2023,43(12):94-107.
WU W C, XIA L, PAN A G, et al. Damage characteristics of reinforced concrete square columns subjected to multipoint simultaneous explosion [J]. Explosion and Shock Waves, 2023, 43(12): 94-107.

[22] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks [J]. IEEE transactions on neural networks and learning systems, 2020, 32(1): 4-24.

[23] SUJON K M, HASSAN R B, TOWSHI Z T, et al. When to use standardization and normalization: empirical evidence from machine learning models and XAI [J]. IEEE Access, 2024.

[24] GAL M S, RUBINFELD D L. Data standardization [J]. NYUL Rev., 2019, 94: 737.

[25] TRAN T N, LAM B M. Effects of data standardization on hyperparameter optimization with the grid search algorithm based on deep learning: A case study of electric load forecasting [J]. Advances in Technology Innovation, 2022, 7(4): 258.

[26] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. arXiv preprint arXiv:1412.6980, 2014.

录用稿件，非最终出版稿