

数据驱动的箍筋加密钢筋混凝土柱爆炸损伤预测与评估模型

王帅帅², 赵春风^{1,2,3}, 邬成勇², 李晓杰³

(1.合肥工业大学安徽省土木工程结构与材料重点实验室, 安徽 合肥 230009;

2.合肥工业大学土木与水利工程学院, 安徽 合肥 230009;

3.大连理工大学工业装备结构分析优化与 CAE 软件全国重点实验室, 辽宁 大连 116024)

摘要: 钢筋混凝土 (reinforced concrete, RC) 柱是工程结构中的核心承重构件, 在爆炸荷载作用下可能发生破坏, 甚至引起结构的整体倒塌。因此, 快速且准确地评估爆炸作用下钢筋混凝土柱的损伤状态对保障结构安全和采取防护措施至关重要。为此, 提出了一种基于机器学习 (machine learning, ML) 的数据驱动模型, 用于预测爆炸荷载作用下 RC 柱的损伤指标。为训练该模型, 构建了一个包含 3133 个样本的综合数据库, 融合了 259 个文献数据样本和 2874 个数值模拟补充数据样本。该数据集不仅包含了 RC 箍筋均匀分布柱, 还包含了符合抗震设计要求的 RC 箍筋加密柱。选用 11 个关键参数作为输入特征, 并将钢筋混凝土柱的损伤指数作为输出特征。利用 6 个 ML 模型对爆炸荷载作用下钢筋混凝土柱的损伤指标进行预测, 并采用四项回归评价指标对六种模型的预测精度进行对比分析。结果表明, 表格先验数据拟合网络 (Tabular Prior-data Fitted Network, TabPFN) 展现出最优的预测精度和泛化能力, 其在测试集上的 R^2 高达 0.989, MAE 值和 RMSE 仅为 0.018 和 0.030。进一步利用 SHAP (Shapley Additive Explanations) 方法对 TabPFN 模型进行可解释性分析。分析表明, 炸药质量、爆炸距离及柱截面深度是主导 RC 柱损伤程度的关键特征。值得注意的是, 体积配箍率在提升 RC 柱抗爆性能方面的贡献度显著优于纵筋配筋率。最后, 通过与独立有限元模拟工况的对比分析, 表明 TabPFN 模型能够较好地拟合数值计算结果, 作为代理模型在未见工况下具备良好的预测稳定性。在计算效能方面, 该模型单次损伤预测耗时仅约 0.5 s, 较传统数值模拟方法的计算效率显著提升了近 4 个数量级。所建立的模型实现了爆炸荷载作用下 RC 柱数值模拟损伤的快速代理计算, 为结构抗爆优化设计的前期参数分析提供指导。

关键词: 钢筋混凝土柱; 爆炸荷载; 机器学习; 损伤评估

文献标识码: A

Data-driven prediction and evaluation model for explosion damage in reinforced concrete columns with densified stirrups

WANG Shuaishuai², ZHAO Chunfeng^{1,2,3}, WU Chengyong², LI Xiaojie³

(1. Anhui Provincial Key Laboratory of Civil Engineering Structures and Materials,
Hefei University of Technology, Hefei 230009, Anhui, China;

*收稿日期: 2025-12-18 ; 修回日期: 2026-07-18 ;

基金项目: 工业装备结构分析优化与 CAE 软件全国重点实验室开放基金项目 (GZ24120); 新疆维吾尔自治区自然科学基金重点基金 (2022D01D33)

第一作者: 王帅帅 (2000—), 男, 硕士研究生. E-mail: 2024171090@mail.hfut.edu.cn;

通信作者: 赵春风 (1983—), 男, 博士, 教授. E-mail: zhaowindy@hfut.edu.cn.

Abstract: Reinforced concrete (RC) columns serve as core load-bearing members in engineering structures. Under explosive loads, they may sustain damage and potentially trigger the collapse of the entire structure. Therefore, rapidly and accurately assessing the damage state of reinforced concrete columns subjected to explosive forces is crucial for ensuring structural safety and implementing protective measures. Accordingly, a data-driven model based on machine learning (ML) is proposed to predict damage indices of RC columns under explosive loading. To train the model, a comprehensive database comprising 3,133 samples was constructed, integrating 259 literature-derived data samples and 2,874 numerically simulated supplementary data samples. This dataset encompasses both RC columns with uniformly spaced stirrups and RC columns with densified stirrups meeting seismic design requirements. Eleven key parameters were selected as input features, with the RC column damage index serving as the output feature. Six ML models were employed to predict damage indices under explosive loading, and their predictive accuracy was comparatively analyzed using four regression evaluation metrics. The results indicate that the Tabular Prior-data Fitted Network (TabPFN) demonstrated optimal prediction accuracy and generalization capability, achieving an R^2 value of 0.989 on the test set with MAE and RMSE values as low as 0.018 and 0.030, respectively. Further interpretability analysis of the TabPFN model was conducted using the SHAP (Shapley Additive Explanations) method. Analysis indicates that charge weight, standoff distance, and column cross-section depth are the key features governing RC column damage severity. Notably, the contribution of volumetric stirrup reinforcement ratio to enhancing RC column blast resistance significantly outperforms that of longitudinal reinforcement ratio. Finally, through comparative analysis with independent finite element simulation results, the TabPFN model was validated to exhibit good prediction stability as a surrogate model under unseen operating conditions. In terms of computational efficiency, the proposed model achieves a single-prediction inference time of approximately 0.5 s, representing a significant efficiency gain of nearly four orders of magnitude compared to conventional numerical simulation methods. The established model enables rapid surrogate computation of simulated damage to RC columns under explosive loading, providing guidance for preliminary parameter analysis in structural blast-resistant optimization design.

Keywords: Reinforced concrete columns; Explosive loading; Machine learning; Damage assessment

1 引言

近几十年来, 由于恐怖袭击和意外爆炸的严重威胁, 工程结构的损伤评估受到了广泛的关注。钢筋混凝土 (reinforced concrete, RC) 柱是工程结构中的核心承重构件, 在遭受爆炸荷载作用下可能发生破坏, 甚至引起结构的整体倒塌^[1-3]。快速、可靠地量化 RC 柱的损伤程度, 不仅是判断结构整体安全性的关键手段, 更是支撑灾后应急救援与修复决策的迫切需求。因此, 探索爆炸荷载作用下 RC 柱损伤的快速、准确预测方法, 对于提升重要基础设施的抗爆性能及灾后快速评估具有重要意义。

目前, 针对 RC 柱在爆炸冲击环境下的动力响应及失效演化机制, 主要通过理论分析、爆炸试验及数值模拟这三种途径展开探讨。其中, 理论分析通过构建特定边界下的运动微分方程并求取精确解, 凭借其变量简练、运算高效等显著优势, 被应用于大规模 RC 柱损伤的快速预估中。Li 等^[4]利用量纲分析法推导了基于等效单自由度模型的无量纲 P-I 曲线, 并通过建立最大位移与破坏准则的关联, 实现了对结构损伤程度的快速评估。Yu 等^[5]采用 Timoshenko 梁理论, 分别定义了确定钢筋混凝土柱典型弯曲破坏、斜向破坏和直剪破坏模式的破坏准则。编制了所提出的有效程序, 引入了改进的非线性循环法来拟合 P-I 曲线, 实现了对 RC 柱在爆炸荷载下破坏模式的快速评估。尽管理论解析在计算效能上具备优势且处于不断完善之中, 但面对真实的爆炸冲击环境, 其局限性依然显著。由于实际工程中涉及材料动态本构以及边界约束条件的复杂性, 而理论推导往往依赖于诸多理想化的简化假

设,难以精准涵盖这些复杂的物理过程,致使该方法的适用范围和计算精度受到制约。

爆炸试验通过对 RC 柱实施真实的爆炸加载,不仅能够直接采集到冲击波荷载数据,还能直观地揭示柱的最终失效特征。Yuan 等^[6]开展了 RC 桥墩在接触爆炸下的现场试验,对比分析了圆截面和方截面柱的动力响应与失效特征,揭示了爆炸荷载下的损伤演化机理。Dua 等^[7]针对不同横截面宽度的矩形 RC 柱开展了接触爆炸试验,旨在探究截面尺寸变化对结构动力响应特征的影响规律。Shi 等^[8]进行了对钢筋混凝土柱近距离爆炸荷载和轴向荷载作用下的试验研究,研究了比例距离和轴向荷载对 RC 柱爆炸荷载作用下损伤程度的影响,结果表明轴压比的增大使 RC 柱在一定的比例距离和轴向荷载组合下爆炸损伤程度由低损伤向中损伤转变。尽管实爆测试对于揭示构件失效机理具有不可替代的价值,但受限于高昂成本与场地条件,难以积累充足样本以满足多工况下的结构损伤量化评估需求。

利用 LS-DYNA 等显式动力学软件进行数值模拟,不仅能提供详尽计算数据,还能直观复现 RC 柱在冲击荷载下的损伤演化历程与复杂失效形态。Wu 等^[9]利用数值模拟探讨了近场爆炸下 RC 柱的损伤演化规律,并基于参数回归分析,提出了以无量纲柱尺寸参数预测损伤指数的经验公式。Lin 等^[10]在 LS-DYNA 中建立了有限元模型来探讨钢筋混凝土柱在爆炸荷载作用下的损伤和破坏时间,并建立不同轴压比下钢筋混凝土柱的损伤指数公式。Shi 等^[11]建立了带钢节点的预制 RC 柱的有限元模型,研究其爆炸荷载下的动力响应及破坏演化规律,并分析了配筋率、截面尺寸及混凝土强度等参数对构件损伤程度的影响。数值模拟虽为有力工具,但其计算精度受限于材料本构选择、参数标定及网格划分等模型设置的不确定性。

机器学习(machine learning, ML)通过使用大量数据构建输入特征和输出之间的复杂映射关系,可以用于工程结构的防灾减灾评估^[12]。朱玉富等^[13]采用支持向量机和高斯过程回归算法对近场爆炸作用下 RC 板的最大位移进行预测,利用置换特征重要性和 Sobol 全局敏感性分析方法,对模型特征进行解释。郑文言等^[14]提出一种由体积判断网络和损伤判断网络组成的全新卷积神经网络模型,基于体积损失率评估近距离爆炸下钢筋混凝土柱的损伤。结果表明提出的卷积神经网络模型有较高的准确率。Yang 等^[15]基于 ML 和蒙特卡罗(MC)来研究钢筋混凝土柱在爆炸荷载下的损伤。使用具有八个输入特征的八个 ML 模型预测了柱的损伤指标。基于层次分析法(AHP),CatBoost 模型被确定为最优模型。Zhao 等^[16]使用机器学习方法开发了一种钢筋混凝土板在爆炸荷载下的两阶段损伤预测方法,通过现有的经验方法验证了两阶段预测方法的准确性和可靠性。Peng 等^[17]提出一种基于图神经网络(GNN)的钢筋混凝土柱快速损伤预测模型,该模型有效克服了基于像素的机器学习方法在处理三维空间拓扑结构方面的固有局限性。在实际工程中,柱端箍筋局部加密不仅能有效防止剪切破坏,还能通过增强对核心混凝土的约束作用,改变柱在爆炸冲击下的动力响应与破坏模式。忽视抗震 RC 柱的箍筋局部加密,往往会低估其抗爆承载力,难以满足工程中对灾后精准评估的需求。为了突破现有工作的局限性,明确箍筋局部加密对提升构件抗爆性能的影响,克服传统理论推理和数值模拟的复杂性,亟需提出基于人工智能驱动的 RC 柱爆炸损伤预测和评估方法。

本研究利用六个 ML 模型来预测爆炸荷载作用下 RC 柱的损伤指数。通过比较各 ML 模型的性能评价指标确定最优模型,并研究输入特征对钢筋混凝土柱损伤的影响,为钢筋混凝土柱抗爆设计提供指导。首先,构建了一个包含 3133 个样本的综合数据库,融合了 259 个文献数据样本和 2874 个数值模拟补充数据样本。然后,对五个 ML 模型进行了超参数的优化,利用 4 项性能评价指标,对经过超参数优化的 5 种常规 ML 模型以及表格先验数据拟合网络(Tabular Prior-data Fitted Network, TabPFN)模型进行性能评估。此外,对最佳预测模型进行 SHAP 进行分析,研究了特征参数对钢筋混凝土柱的损伤的影响规律。最后,通过与有限元模拟结果的对比分析,验证了 TabPFN 模型作为数值计算代理模型,在未见工况下具备良好的拟合能力与预测稳定性。

2 数值模拟方法及模型验证

机器学习和深度学习需要大量的数据，目前，已有文献的数据无法满足模型训练对数据集数量的要求，因此通过非线性有限元动力分析软件 LS-DYNA 进行数值模拟补充数据，在数值模拟补充数据之前，要确定正确的数值模拟方法。本节通过数值模拟与爆炸试验进行对比，验证该数值模拟方法的准确性。

2.1 材料模型与应变率效应

采用分离式建模方法建立 RC 柱有限元模型。混凝土材料采用 K&C^[18] (*MAT_CONCRETE_DAMAGE_REL3) 模型，该模型仅需输入密度与轴心抗压强度，即可自动转换并生成其余参数。并考虑了应变率效应与软化行为对材料失效的影响，能够较为真实地反映爆炸冲击过程中的动力响应^[19]。本文数值模拟考虑混凝土材料的应变率效应，采用郝逸飞等^[20]提出的动力放大系数 (dynamic increase factor, DIF)。公式 (1) 表示混凝土抗拉动力系数 (tensile dynamic increase factor, TDIF)，公式 (2) 表示混凝土抗压动力放大系数 (compressive dynamic increase factor, CDIF)：

$$TDIF = \frac{f_{td}}{f_{ts}} = \begin{cases} 0.26(\log \dot{\epsilon}_d) + 2.06 & 10^{-4} \text{ s}^{-1} \leq \dot{\epsilon}_d \leq 1 \text{ s}^{-1} \\ 2(\log \dot{\epsilon}_d) + 2.06 & 1 \text{ s}^{-1} < \dot{\epsilon}_d \leq 2 \text{ s}^{-1} \\ 1.44331(\log \dot{\epsilon}_d) + 2.2276 & 2 \text{ s}^{-1} < \dot{\epsilon}_d \leq 150 \text{ s}^{-1} \end{cases} \quad (1)$$

$$CDIF = \frac{f_{cd}}{f_{cs}} = \begin{cases} 0.0419(\log \dot{\epsilon}_d) + 1.2165 & \dot{\epsilon}_d \leq 30 \text{ s}^{-1} \\ 0.8988(\log \dot{\epsilon}_d)^2 - 2.8255(\log \dot{\epsilon}_d) + 3.4907 & \dot{\epsilon}_d > 30 \text{ s}^{-1} \end{cases} \quad (2)$$

式中， f_{td} 为材料动力抗拉强度， f_{ts} 为材料静力抗拉强度； f_{cd} 为材料的动力抗压强度， f_{cs} 为材料静力抗压强度。

钢筋的材料模型采用 *MAT_PIECEWISE_LINEAR_PLASTICITY 模型，该模型可模拟钢筋的各向同性硬化和考虑应变率效应，较好地反映钢筋的真实力学性能。钢筋的应变率效应采用 Malvar^[21] 提出的公式：

$$DIF = \left(\frac{\dot{\epsilon}}{10^{-4}} \right)^{\alpha} \quad (3)$$

$$\alpha = 0.074 - 0.04 \frac{f_y}{414} \quad (4)$$

式中， $\dot{\epsilon}$ 为钢筋应变率 (s^{-1})， f_y 是钢筋屈服强度 (MPa)，公式适用范围为： $290 \leq f_y \leq 710 \text{ MPa}$ ； $10^{-4} \leq \dot{\epsilon} \leq 225 \text{ s}^{-1}$ 。

2.2 试验介绍

Woodson 和 Baylot^[22]对 1/4 比例的两层钢筋混凝土框架结构进行了爆炸现场试验，评估其在爆炸荷载下的结构响应和破坏。通过数值模拟框架底层钢筋混凝土中柱的爆炸的结构响应，验证所建立钢筋混凝土柱模型的准确性。框架柱形式如图 1 所示，试验中使用 7.1 kg C4 高能炸药 (相当于 8 kg 的 TNT 炸药)，距离地面高度为 0.305 m，距离框架柱迎爆面水平距离为 1.07 m。该爆炸试验研究框架中的首层中柱响应。结构首层中柱截面尺寸为 89 mm×89 mm，中柱的其它尺寸和配筋如图 2 所示，钢筋材料参数见表 1，结构的其它参数可参考文献^[22]。

表 1 钢筋材料参数

Table 1 Reinforcing steel material parameters

钢筋	面积/mm ²	屈服强度/MPa	极限强度/MPa
W0.5	3.22	441	513
D1	6.45	399	610
D5	32.20	449	513

2.3 数值模型验证

研究对象选取框架首层外部中柱，有限元数值模型如图3所示。有限元模型中混凝土质量密度为 2400 kg/m^3 ，轴心抗压强度 42 MPa ，泊松比为 0.2 ；钢筋密度取为 7800 kg/m^3 ，钢筋泊松比为 0.3 ，杨氏模量为 207 GPa ，失效应变为 0.2 。结构首层外部中柱净高为 0.87 m ，为了准确模拟柱子的约束，数值模型中建立柱头和柱脚，柱头和柱脚采用刚体建模，约束柱脚的全部自由度，约束柱头除轴向自由度外的全部自由度。柱子顶部施加的初始压力为 2.1 MPa ，通过关键字 *LOAD_BLAST_ENHANCED 施加爆炸荷载，该关键字需定义迎爆面、炸药质量、炸药中心点坐标及起爆时间等参数。

数值模拟的 RC 柱中最大位移的时程曲线和试验结果如图4所示，有限元模拟结果显示，柱中最大位移为 11.7 mm ，与试验结果 12.4 mm 相差 5.6% 。因此，这表明本文所建立的数值模型可以较为准确地预测钢筋混凝土柱爆炸荷载下的响应。




图1 现场试验草图^[23]

Fig.1 Sketch of field test^[23]




图2 外部中柱细节^[22]

Fig.2 External center column detail^[22]




图3 中柱有限元模型

Fig.3 Finite element model of the central column




图4 跨中最大位移对比

Fig.4 Comparison of maximum mid-span displacement

3 钢筋混凝土柱爆炸样本数据库

本文构建的数据库共 3133 个数据样本，其中包含 259 个从文献中获得的数据样本，2874 个数值模拟补充的数据样本。

3.1 文献数据

共收集了 259 个文献数据点，其中 253 个数据来自有限元数值模拟，其余 6 个数据来自试验。表 2 概述了本研究收集的数据点的文献来源。收集的实验和数值模拟数据的参数范围如表 3 所示。现有众多研究中参数的多样性，表明了为探索钢筋混凝土柱在各种爆炸荷载下的复杂受力行为已开展了广泛的研究。数据集所包含的参数多样性，有助于对影响钢筋混凝土柱抗爆性能的因素进行全面分析，为后期预测模型的开发提供了坚实的基础。

3.2 数值模拟数据

为了建立数据模型，数据库需要大量的数据样本，收集文献中的数据数量还不足以训练模型，使用验证的有限元数值模拟方法来补充数据。钢筋混凝土柱参数和爆炸荷载参数选择的多样性，影响预测模型的泛化能力。因此，本研究通过选择参数的多样性，数值模拟了 2874 个数据样本点，来提高预测模型的准确性和泛化性。由于手动数值模拟工作量较大，因此通过 MATLAB 软件和 LS-DYNA 联合仿真来减少工作量。

表 2 收集的文献数据统计

Table 2 Statistics of collected literature data

作者	年份	数据类型	数量
Thai et al. ^[24]	2018	数值模拟	9
师燕超等 ^[25]	2021	数值模拟	28
吴文燕等 ^[26]	2021	数值模拟	36
Shi et al. ^[8]	2022	试验	4
Lin et al. ^[10]	2023	试验+数值模拟	2+180

表 3 收集数据的参数范围

Table 3 Parameter ranges for data collection

参数	单位	范围
柱高	mm	500~6000
柱宽	mm	80~1200
柱深	mm	80~800
混凝土立方体抗压强度	MPa	30~60
纵筋屈服强度	MPa	400~500
箍筋屈服强度	MPa	335~500
纵筋配筋率	%	0.2~3.2
体积配箍率	%	0.2~2.4
轴压比	/	0~0.8
炸药质量	kg	0.15~120000
爆炸距离	m	0.09~80

3.2.1 钢筋混凝土柱参数

根据中国《混凝土结构设计规范》GB50010^[27]和太平洋地震工程研究中心提供的钢筋混凝土柱数据库^[28]，选择参数范围如表 4 所示。现行规范对不同截面尺寸柱的截面配筋形式统一按照配筋率考虑，钢筋混凝土柱采用三种常见的截面配筋构造形式如图 5 所示，其中形式 1 用于柱宽和柱深不超过 300 mm 的柱，形式 2 用于柱宽和柱深不超过 500 mm 且大于 300 mm 的柱，形式 3 用于柱宽和柱深不超过 700 mm 且大于 500 mm 的柱^[29, 30]。本文考虑了为抗震设计的箍筋沿柱高度局部加密的加密柱和

箍筋沿柱高度均匀分布的非加密柱。根据中国建筑抗震设计规范^[31]，结构首层柱柱下端箍筋加密区高度不小于柱净高的 1/3；首层柱上端的箍筋加密区的长度不小于柱截面长边尺寸、柱净高的 1/6 和 500 mm 中的最大值；箍筋的加密区间距取 100 mm，非加密区间距取 200 mm。

表 4 数值模拟的钢筋混凝土柱参数范围

Table 4 Parameter ranges for reinforced concrete columns in numerical simulation

参数	单位	符号	选择值或范围
柱高	mm	H	3000, 4000, 5000
柱宽	mm	w	300, 400, 500, 700
柱深	mm	h	300, 400, 500, 600, 700
混凝土立方体抗压强度	MPa	f_{cu}	30, 45, 60
纵筋屈服强度	MPa	f_y	400, 500
箍筋屈服强度	MPa	f_s	335, 400
纵筋配筋率	%	ρ_l	1~2.79
体积配箍率	%	ρ_v	0.48~1.67
轴压比	/	N_r	0, 0.1, 0.2, 0.4

3.2.2 爆炸载荷

爆炸荷载参数对钢筋混凝土柱的动力响应影响较大，爆炸荷载参数主要是炸药质量和爆炸距离。本文主要考虑车辆炸弹爆炸荷载和箱包炸弹爆炸荷载下钢筋混凝土柱的动态响应。根据中国民用建筑防爆设计标准^[32]，典型的箱包、轿车、面包车、轻型卡车、中型卡车爆炸威胁的等效 TNT 当量范围为 25 kg 至 4000 kg，本文采取更宽泛的炸药质量范围为 5 kg 至 4000 kg。根据城市居住区规划设计标准^[33]，爆炸距离范围取为 1 m 至 30 m。RC 柱爆炸荷载参数取值范围如表 5 所示。




图 5 钢筋混凝土柱的截面配筋构造形式

Fig.5 Cross-sectional reinforcement forms for reinforced concrete columns

表 5 钢筋混凝土柱爆炸参数范围

Table 5 Range of explosion parameters for reinforced concrete columns

参数	单位	符号	选择值
炸药质量	kg	W	5, 10, 15, 20, 35, 50, 100, 200, 250, 400, 500, 700, 1000, 1500, 2000, 4000
爆炸距离	m	R	1, 2, 4, 6, 8, 10, 15, 30

3.2.3 损伤评估指标

钢筋混凝土柱爆炸损伤评估需要确定一个损伤指数，本文采用师等^[34]提出的基于钢筋混凝土柱剩余承载力的损伤指数，定义为等式 (5)：

$$D = 1 - \frac{P_r}{P_N} \quad (5)$$

式中， P_r 为爆炸后钢筋混凝土柱的剩余承载力； P_N 为未损伤的钢筋混凝土柱的极限轴向承载力，由数值模拟获得。基于残余承载力的爆炸损伤评估指标适用于包括剪切破坏、弯曲破坏和弯剪破

坏在内的不同破坏模式。基于轴向剩余承载力的损伤指数被众多学者广泛使用^[29, 34-36]，故本文采取损伤指数 D 作为钢筋混凝土柱爆炸损伤评估的依据。因此，本研究后续机器学习模型将以损伤指数 D 作为模型的输出。基于此，参考 Shi 等^[34]提出的损伤评估准则，本文将钢筋混凝土柱的损伤程度按损伤指数 D 划分为四类，具体评判标准如表 6 所示。

3.2.4 RC 柱数值模拟

采用上述的数值模拟方法生成 RC 柱试件数据库，建立含有柱头和柱脚的 RC 柱数值模型。为了验证所选网格尺寸的可靠性，本文进行了网格敏感性分析。数值模拟结果表明，25 mm 网格已具备较好的计算精度。进一步细化网格仅能有限地提高精度，但计算成本会大幅增加。结合 Shi 等^[34]与张等^[37]相关研究中采用的 25 mm 网格，本文在兼顾计算精度与大规模数据生成可行性的前提下，最终在数值模拟补充数据样本中采用 25 mm 作为有限元网格尺寸。

表 6 钢筋混凝土柱损伤评估准则

Table 6 Damage assessment criteria for reinforced concrete columns				
损伤程度	轻度破坏	中度破坏	重度破坏	倒塌
损伤指数 D	$0 \leq D \leq 0.2$	$0.2 < D \leq 0.5$	$0.5 < D \leq 0.8$	$0.8 < D \leq 1$

在边界条件与模型设置方面，约束柱脚的全部自由度，以及约束柱头的除轴向自由度（ z 方向自由度）外的全部自由度。爆炸源高度均距离地面 1 m，混凝土和钢筋相关参数与上述数值模型参数相似。侵蚀准则参考其他研究者确定^[30, 38]，混凝土侵蚀准则采取最大主应变为 0.1，在数值模拟过程中，当混凝土单元满足侵蚀准则时，混凝土的相应失效单元将被删除。

RC 柱的残余承载力可以通过下面步骤获得^[34]：首先通过动力松弛将轴向荷载施加于柱顶，同时施加了柱本身重力荷载，待结构达到静力平衡状态后，施加爆炸荷载；爆炸冲击结束后，当 RC 柱上所有节点的速度衰减至 0.1 m/s 以下时，将节点速度重置为 0，保留其爆炸残余变形与材料损伤状态；最后，对处于受损状态的 RC 柱顶部施加位移，直至结构发生破坏。提取该过程中轴力的峰值，即为 RC 柱的爆炸后残余承载力 P_r 。获得 P_r 后，即可根据公式（5）计算出每个模拟工况的损伤指数 D 。

为了更直观地展示上述流程及损伤指数，以本数据库中典型钢筋混凝土柱样本为例。该柱截面尺寸为 500 mm × 500 mm，高度 5000 mm，混凝土立方体抗压强度为 45 MPa，轴压比为 0.2。在经受 50 kg 炸药质量、距离 2 m 的爆炸荷载冲击并完成速度重置后，对其柱头施加轴向位移荷载。有限元模型如图 6(a)所示。图 6(b)为爆炸荷载下 RC 柱的归一化损伤指标云图。鉴于 K&C 模型对裂缝等现象的表征存在一定局限性，本文仅将该云图作为破坏区域的直观示意。从图中可见，柱底及柱身中部的受拉区数值较高，反映了该区域混凝土力学性能发生了严重退化。图 6(c)展示了受损柱在爆炸后位移加载下的归一化损伤指标分布，用于呈现柱身中上部区域损伤的进一步演化。需要明确的是，本文对 RC 柱损伤程度的定量评估并未依赖云图数值，而是统一基于结构的轴力-位移曲线进行计算。图 7 展示了无损柱和爆炸受损柱的轴力-位移曲线，无损柱的极限承载力 P_N 为 10454.66 kN，而爆炸受损后柱的剩余极限承载力 P_r 为 7412.57 kN。基于公式（5）计算得到的有限元模拟损伤指数为 0.291，依据表 6 的评估准则判定为中度破坏。




图6 有限元模拟: (a) 有限元模型; (b) 爆炸荷载下归一化损伤指标; (c) 爆炸后位移加载下归一化损伤指标

Fig. 6 Finite element simulation: (a) Finite element model; (b) Scaled damage measure under blast loading; (c) Scaled damage measure under displacement loading after blast.

参数化数据库的构建涉及大量数值计算, 手动建模并逐一计算效率较低, 因此本文采用 MATLAB 与 LS-DYNA 联合仿真方法^[29]。由于 RC 柱的柱高、柱宽、柱深、箍筋间距及截面配筋形式等参数在 LS-DYNA 关键字文件中不易直接修改, 本文预先手动建立了涵盖不同基础参数的关键字模板。随后, 通过编写 MATLAB 脚本自动修改模板中的其它变量, 批量生成新的关键字文件, 并驱动 LS-DYNA 和 LS-Prepost 软件实现自动化的批量计算与数据提取。基于上述联合仿真流程, 本文最终补充了 2874 个数值模拟数据样本。

4 钢筋混凝土柱爆炸损伤预测模型

本文建立 6 种不同的机器学习模型来预测钢筋混凝土柱的损伤指数 D 。机器学习模型的输入由 9 个选定的 RC 柱参数和 2 个爆炸荷载参数组成, 而结果输出是损伤指数 D 。本研究建立的 RC 柱爆炸损伤预测模型的方法流程图如图 8 所示。在训练预测模型之前, 需要对数据进行预处理。在本文研究中使用公式 (6) 进行数据标准化, 将数据转换为均值为 0、标准差为 1 的分布。该过程消除特征间的量纲差异, 从而提高算法的性能。

$$z = \frac{x - \mu}{\sigma} \quad (6)$$

其中 z 是标准化后的数值, x 是原始数值, μ 是特征的平均值, σ 是特征的标准差。




图7 无损柱和爆炸受损柱轴力-位移曲线

Fig. 7 Axial force-displacement curves of undamaged and blast-damaged columns




图 8 方法流程图

Fig.8 Method flowchart

4.1 机器学习方法

使用包括决策树（decision tree, DT）、随机森林（random forest, RF）、极限梯度提升（Extreme Gradient Boosting, XGBoost）、轻量级梯度提升机算法（Light Gradient Boosting Machine, LightGBM）、多层感知机（multi-layer perceptron, MLP）和表格先验数据拟合网络（Tabular Prior-data Fitted Network, TabPFN）等 6 种回归算法开发预测模型。6 种算法原理示意图如图 9 所示。每个模型包括 H 、 w 、 h 、 f_{cu} 、 f_y 、 f_s 、 ρ_l 、 ρ_v 、 N_t 、 W 、 R 共 11 个输入特征和 1 个损伤指数 D 输出特征，所有模型都是在 Python 3.9 环境中实现。

4.1.1 决策树 DT

决策树（DT）回归算法通过构建分层判断逻辑，将输入数据划分到不同的子集中。如图 9(a) 所示，该模型由根节点、内部节点和叶节点组成。预测时，输入特征从根节点开始，根据判断条件逐层向下传递，最终分配到某个叶节点上。对于本文的回归问题，叶节点的输出值通常取该区域内所有训练样本损伤指数 D 的平均值。从数学表达来看，假设输入特征空间被划分为 M 个相互独立的区域 R_m ，则决策树回归模型 $f(x)$ 的表达式为：

$$f(x) = \sum_{m=1}^M c_m I(x \in R_m) \quad (7)$$

其中， I 为指示函数，当输入样本 x 属于区域 R_m 时取值为 1，否则为 0； c_m 为模型在区域 R_m 内的输出常量。为了最小化预测误差，最优的 c_m 值即为对应叶节点内样本损伤指数的平均值^[39]。

4.1.2 随机森林 RF

随机森林（RF）是一种将 Bagging 集成学习理论与随机子空间方法相结合的机器学习算法^[40]。通过 Bootstrap 从训练数据集中随机迭代抽取样本，创建多个训练样本，再从每个样本中生成决策树，形成随机森林（图 9(b)）。在训练过程中，每个决策树基于各自的特征子集独立预测目标变量。在预测阶段，对于回归问题，利用全部决策树的预测结果，通过平均所有回归结果获得最终结果，公式如下所示：

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (8)$$

其中， B 为森林中决策树的总数量， $T_b(x)$ 表示第 b 棵回归树对输入样本 x 的预测输出值。

4.1.3 极限梯度提升 XGBoost

极限梯度提升（XGBoost）回归算法是一种基于梯度提升的高效集成算法，通过残差迭代构建弱学习器，逐步优化目标函数，示意图如图 9(c) 所示。XGBoost 目标函数包含损失函数和正则化项，其函数形式为：

$$Obj = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_k^K \Omega(f_k) \quad (9)$$

其中, n 是样本数量, y_i 是 i 个样本的真实值, $\hat{y}_i$ 是 i 个样本的预测值, f_k 是第 k 棵树, $L(y_i, \hat{y}_i)$ 是损失函数, $\Omega(f_k)$ 是正则化项。同时该算法利用泰勒公式展开损失函数, 一阶导数和二阶导数的信息可以同时利用, 使得梯度下降更准确和快速。XGBoost 还利用了收缩和树修剪等正则化技术, 控制了模型的复杂度, 有效防止模型的过拟合和提高模型泛化能力^[41]。

4.1.4 轻量级梯度提升机算法 LightGBM

轻量级梯度提升机算法 (LightGBM) 是一种高效的梯度提升决策树算法, 广泛应用于分类和回归问题, 原理图如图 9(d) 所示。为了解决传统梯度提升决策树算法在海量数据下计算效率低下的问题, LightGBM 提出了单边梯度采样算法 (GOSS)。其修正后的增益估计公式如下:

$$\tilde{V}_j(d) = \frac{1}{n} \left(\frac{\left(\sum_{x_i \in A_L} g_i + \frac{1-a}{b} \sum_{x_i \in B_L} g_i \right)^2}{n_L^j(d)} + \frac{\left(\sum_{x_i \in A_R} g_i + \frac{1-a}{b} \sum_{x_i \in B_R} g_i \right)^2}{n_R^j(d)} \right) \quad (10)$$

其中, $\tilde{V}_j(d)$ 表示特征 j 在分裂点处的估计方差增益; n 表示训练样本的总数; g_i 表示第 i 个样本损失函数的梯度; A_L, A_R 分别表示大梯度样本集合中, 根据分裂点 d 划分到左子节点和右子节点的样本数据集; B_L, B_R 分别表示小梯度样本集合中, 被划分到左子节点和右子节点的样本数据集; a 和 b 是大梯度和小梯度样本的采样比例, $(1-a)/b$ 是对小梯度样本权重的调整因子; $n_L^j(d)$ 与 $n_R^j(d)$ 分别表示分裂后左子节点和右子节点的加权样本统计量。与传统的梯度提升决策树相比, 采用基于直方图的算法, 减少了分裂点数量与内存占用, 加快了训练进程。增加了互斥特征捆绑算法, 稀疏特征中互斥的特征合并降低了特征维度, 进一步提高了算法效率^[42]。

4.1.5 多层感知机 MLP

多层感知机 (MLP) 算法是一种包括多层节点的人工神经网络框架, 由输入层、数个隐藏层及输出层组成, 如图 9(e) 所示。MLP 旨在通过层级非线性变换, 构建输入特征与目标变量之间的复杂映射关系。第 l 层的数学表达形式如下:

$$h^{(l)} = \sigma(W^{(l)}h^{(l-1)} + b^{(l)}) \quad (11)$$

其中, $h^{(l)}$ 和 $h^{(l-1)}$ 分别表示第 l 层和第 $l-1$ 层的输出向量, $W^{(l)}$ 和 $b^{(l)}$ 分别表示权重矩阵和偏置向量, σ 代表非线性激活函数。模型通过反向传播算法迭代优化权重与偏置参数, 从而最小化预测误差, 实现对未知样本的有效预测^[43]。




图9 算法模型示意图[15, 39, 44-46]

Fig.9 Schematic diagram of the algorithm model[15, 39, 44-46]

4.1.6 表格先验数据拟合网络 TabPFN

表格先验数据拟合网络 (TabPFN) 是一种基于 Transformer 的创新表格数据预测方法。通过在数百万个合成的数据上进行预训练，建立一个泛化能力极强的学习模型。该模型的核心创新在于上下文学习机制 (ICL) 机制，能够自动学习解决表格数据预测任务的通用算法，无需针对每个数据集单独训练或进行大量超参数调优。TabPFN 使用双注意力机制，行内注意力用于捕捉样本内部不同特征之

间的关联，列间注意力用于学习同一特征在不同样本之间的模式。通过 MLP 处理生成的预测输出不仅能提供点估计值，还能提供预测值分布的密度^[44]。示意图如图 9(f)所示。

4.2 机器学习损伤预测模型的建立

4.2.1 性能评价指标

为客观评估模型的预测精度，本文选用决定系数（coefficient of determination, R^2 ）、平均绝对误差（mean absolute error, MAE）、均方根误差（root mean square error, RMSE）及中位绝对误差（median absolute error, MedAE）四项标准指标进行量化评价。各指标的定义及计算公式如下：

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (12)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (14)$$

$$MedAE(y, \hat{y}) = \text{median}(|y_1 - \hat{y}_1|, \dots, |y_n - \hat{y}_n|) \quad (15)$$

其中， y_i ， $\hat{y}_i$ ， $\bar{y}$ 分别表示真实值、预测值和真实值的平均值。 n 表示数据集中的样本总数。 R^2 衡量模型与数据的拟合程度，表示模型对可变性的解释程度。MAE 计算预测值和真实值之间的平均绝对偏差，能够客观反映模型预测误差的总体水平。RMSE 计算预测值与真实值之间的均方根误差，其数值与原始数据在同一量纲，使得误差解释更为直观。MedAE 计算预测值和真实值的绝对误差的中位数，提供了一个对异常值不敏感、更稳健的指标，更好地反映了模型对大多数样本的预测能力。 R^2 越趋近于 1，表明模型对数据变异性的解释程度越高，模型拟合度及预测可靠性也随之提升。相反，MAE、RMSE 和 MedAE 作为误差度量指标，其值越逼近 0，表明预测结果与实测数据之间的残差越小，表征模型具备更高的预测精度。

4.2.2 机器学习模型优化超参数的过程

在构建机器学习损伤预测模型时，超参数的配置对模型性能具有决定性影响。鉴于此，本研究采用 Akiba 等^[47]提出的 Optuna 自动优化框架进行超参数寻优。该框架的核心优势在于引入了树结构 Parzen 估计器（Tree-structured Parzen Estimator, TPE）作为采样算法。相较于传统的网格搜索或随机搜索，TPE 能够基于历史评估结果构建概率模型，从而自适应地向高潜力的参数区域收敛，显著提升了搜索效率与优化质量。

为了评估模型的泛化能力，本研究采用随机抽样法将原始数据集按 80%与 20%的比例进行划分。其中，2506 组数据被划分为训练集，用于模型构建及参数寻优，剩余的 627 组数据则组成独立的测试集，用于模型最终性能评估。在模型训练阶段，为了确定最优超参数组合并降低过拟合风险，采用了 5 折交叉验证策略。具体而言，训练集被随机划分为 5 个互斥的子集，模型进行 5 次迭代训练；在每一轮迭代中，依次循环选取其中 1 个子集作为验证集，剩余 4 个子集则作为训练集进行模型拟合。本研究选用平均绝对误差（MAE）（公式（13））作为评价指标，最终的模型得分为 5 次验证结果的算术平均值。该交叉验证流程如图 10 所示。

基于上述的 5 折交叉验证评估框架，本研究引入 Optuna 贝叶斯优化框架，旨在系统挖掘匹配当前数据集的最优模型配置。相较于传统的人工试错，Optuna 能够为超参数的选择提供更为科学、可靠的方法论支撑。各模型的关键超参数及其搜索空间设定详见表 7，其余超参数保持默认值。通过在预设的搜索范围内进行多轮迭代与验证，算法最终收敛至使 5 折交叉验证的平均 MAE 最小的最优超

参数组合。值得注意的是，鉴于本文 4.1.6 节所述的 TabPFN 模型基于预训练先验知识，其独特的架构无需进行传统意义上的大量超参数调优。因此，本节仅对常规机器学习模型执行优化流程，TabPFN 则直接采用标准配置参与对比。




图 10 5 折交叉验证

Fig.10 5-fold cross-validation

表 7 模型中的关键超参数

Table 7 Key hyperparameters in the model

模型	超参数	搜索范围	最优值
DT	max_depth	(3, 21)	20
	min_samples_leaf	(1, 10)	1
	min_samples_split	(2, 10)	3
	Splitter	{best, random}	best
RF	n_estimators	(100, 500)	500
	max_depth	(3, 16)	16
	min_samples_leaf	(1, 10)	1
	min_samples_split	(2, 10)	2
XGBoost	max_depth	(3, 16)	8
	learning_rate	(0.05, 0.3)	0.05
	n_estimators	(100, 1200)	700
LightGBM	num_leaves	(6, 50)	44
	min_data_in_leaf	(1, 10)	3
	learning_rate	(0.05, 0.3)	0.05
	n_estimators	(100, 1000)	700
MLP	hidden_layers	(1, 5)	3
	nodes	(12, 24)	16
	solver	{adam, sgd}	adam

4.3 结果和讨论

4.3.1 模型的对比和选择

本研究中训练的机器学习模型用于预测爆炸荷载下 RC 柱基于残余承载力的损伤指数 D 。将预测值和真实值进行比较，以评估模型的性能。图 11 展示了训练数据集和测试数据集的预测值和真实值的比较，大部分数据点位于 $y = x$ 线附近，表明预测值与真实值良好吻合。此外，表 8 全面地总结了用于评估机器学习模型的性能指标，分别比较了 R^2 ，MAE，RMSE，MedAE 四个性能评价指标，高的 R^2 和低的 MAE，RMSE，MedAE 表明模型的性能良好。由表 8 可知，各模型在训练集上的评估指标均优于测试集。此外，所有模型中最低的 R^2 为 MLP 模型的 0.958，反映出这些机器学习模型均能较准确地预测爆炸荷载下 RC 柱的损伤指数 D 。在六个机器学习模型中有两个模型性能较为突出，基于 XGBoost 训练集的 $R^2=0.999$ ，MAE=0.006，RMSE=0.008，MedAE=0.004 和测试集的

$R^2=0.986$, $MAE=0.024$, $RMSE=0.034$, $MedAE=0.018$; 基于 TabPFN 训练集的 $R^2=0.997$, $MAE=0.008$, $RMSE=0.015$, $MedAE=0.005$ 和测试集的 $R^2=0.989$, $MAE=0.018$, $RMSE=0.030$, $MedAE=0.011$ 。为了评估模型的实际性能, 测试集的准确性更为重要。在六个评估模型中, 基于 TabPFN 算法的模型在测试集上表现出最佳的性能。因此, 在研究的后续部分选择 TabPFN 模型进行进一步分析。




图 11 六种算法的预测值与真实值的比较

Fig.11 Comparison of predicted value and actual value for six algorithms

4.3.2 SHAP 可解释分析

图 12 显示了 SHAP 的条形图和蜂群图。条形图通过平均绝对 SHAP 值量化特征的重要性, 用于比较不同特征的重要性。 W 和 R 对钢筋混凝土柱的损伤程度影响最大。第三个重要的是 h , 表示在爆炸荷载的冲击下, 柱截面深度的抗损伤能力比柱的其它参数更重要。柱宽 w 不变, 调整柱深 h 来改变 RC 柱的截面面积, 增大柱截面面积的同时, 作用在 RC 柱迎爆面上的爆炸荷载不变。代表着在本

文特定的爆炸荷载作用方向下, 增加 h 是增大柱抗弯和抗剪承载力的较快方法。其次重要的特征是 N_r , 表示柱在受到爆炸之前的初始轴压状态。

表 8 每个机器学习模型的性能指标

模型	数据集	R^2	MAE	RMSE	MedAE
DT	Training set	0.998	0.007	0.014	0.005
	Testing set	0.970	0.029	0.050	0.015
RF	Training set	0.996	0.010	0.017	0.006
	Testing set	0.981	0.026	0.040	0.018
XGBoost	Training set	0.999	0.006	0.008	0.004
	Testing set	0.986	0.024	0.034	0.018
LightGBM	Training set	0.997	0.011	0.016	0.008
	Testing set	0.984	0.024	0.036	0.018
MLP	Training set	0.984	0.026	0.036	0.019
	Testing set	0.958	0.039	0.059	0.024
TabPFN	Training set	0.997	0.008	0.015	0.005
	Testing set	0.989	0.018	0.030	0.011

注: 粗体值表示模型在这方面表现最佳




图 12 TabPFN 模型的 SHAP 值

Fig.12 SHAP values for the TabPFN model

值得注意的是, 体积配箍率比纵筋配筋率更重要。拉筋与外围箍筋构成的复合约束影响了体积配箍率的大小。缩小箍筋间距及增加内部拉筋, 不仅提高了构件的抗剪能力, 同时增强了对核心混凝土的侧向约束作用。在爆炸冲击下, 箍筋加密与这种复合约束抑制了核心混凝土的剥落, 改变了柱的动力响应与破坏模式, 进而影响其抗爆剩余承载力, 在提升柱体抗爆能力方面效果显著。因此, 在进行抗爆设计时, 纵向受力钢筋的配筋率并非重要考虑因素, 通常仅需满足 RC 柱常规承载力设计要求即可。

图 12 蜂群图展示单个特征 SHAP 值分布情况, 识别特征的整体影响方向。图中的每个点代表一

个样本在该特征上的 SHAP 值，表示每个参数如何影响爆炸作用下柱的损伤指数 D ，正值表示模型输出的增加，负值表示模型输出的减少。图中数据点的颜色表示特征值的大小，红色映射较大值特征，蓝色则映射较小值特征。从图 12 中可以看出，炸药质量和爆炸距离对模型的输出有显著的影响。炸药质量的增加导致模型输出损伤指数的增加，爆炸距离的增加导致模型输出损伤指数的减少。同时，柱深和柱宽的增加均会使得损伤指数变小。类似的解释可以应用于其它特征。

4.4 与有限元模拟的对比

为了评估 TabPFN 模型作为有限元代理模型，在未参与模型训练和测试的新工况下的预测稳定性，本研究构建了 6 组测试工况（编号 C1-C6）。这些工况的输入特征涵盖了数据库中未曾涉及的截面尺寸、轴压比及爆炸参数，具体参数如表 9 所示。这些数据完全独立于训练集和测试集，旨在模拟实际工程中可能遇到的未知场景，以此检验模型对未知数据的处理能力。

表 9 六组测试工况的几何尺寸及爆炸荷载参数

Table 9 Geometric dimensions and explosion load parameters for six test conditions

编号	H/mm	w/mm	h/mm	f_{cu}/MPa	f_y/MPa	f_s/MPa	$\rho_l/\%$	$\rho_v/\%$	N_t	W/kg	R/m
C1	5000	400	400	45	400	335	1.57	0.97	0.3	30	1
C2	5000	400	400	45	400	335	1.57	0.97	0.1	300	5
C3	5000	450	450	45	400	335	1.50	1.30	0.4	30	1
C4	5000	450	450	45	400	335	1.50	1.30	0.4	300	5
C5	5000	600	600	40	400	335	1.64	1.76	0.1	30	1
C6	5000	600	600	40	400	335	1.64	1.76	0.2	300	5

将上述 6 组工况输入训练好的 TabPFN 模型，并将预测得到的损伤指数 D 与 LS-DYNA 有限元数值模拟结果进行对比，结果如表 10 所示。由表可知，TabPFN 模型的预测值与有限元模拟值高度吻合。在所有测试工况中，相对误差均控制在较低水平。其中，工况 C2 的预测精度最高，相对误差仅为 0.98%；即使是误差最大的工况 C5，其相对误差也仅为 5.60%，仍在工程允许的误差范围内。这表明 TabPFN 模型能够很好地捕捉数值模拟中输入特征与损伤指数之间复杂的非线性映射关系，作为有限元计算的代理模型，在面对不同参数组合时表现出了较好的拟合能力与稳定性。

表 10 TabPFN 模型预测值与有限元模拟结果的对比

Table 10 Comparison of TabPFN model predictions with finite element simulation results

编号	有限元模拟值 D	TabPFN 模型预测值 D	相对误差/%	损伤程度
C1	0.692	0.683	1.30	重度破坏
C2	0.715	0.722	0.98	重度破坏
C3	0.382	0.376	1.57	中度破坏
C4	0.570	0.555	2.63	重度破坏
C5	0.393	0.415	5.60	中度破坏
C6	0.457	0.451	1.31	中度破坏

依据第 3.2.3 节确立的损伤评估准则，本研究对 6 组验证工况的损伤等级进行了划分，结果如表 10 所示。为了进一步验证预测结果的可靠性，图 13 展示了各工况对应的有限元模拟归一化损伤指标云图（侧视图）。

综合表 10 的损伤评级与图 13 直观示意的破坏形态对比分析可知：对于被判定为中度破坏的 C3、C5 及 C6 柱，模型预测值分布在 0.2 至 0.5 区间内。与之对应的图 13(c)、图 13(e)和图 13(f)显示，高数值的损伤区域分布范围较窄且呈现局部化特征。这反映了该工况下混凝土的力学性能退化未发生大范围扩展，结构虽受损但整体形态保持相对完整。对于被判定为重度破坏的 C1、C2 及 C4 柱，TabPFN 模型的预测值均超过 0.5。这一预测结果与图 13(a)、图 13(b)和图 13(d)中呈现的大面

积、连续性的高数值损伤区域相吻合，直观地展现了柱身较严重的力学性能退化。这种预测数值与有限元损伤分布特征之间的对应关系，证实了该模型能够有效地代理数值模拟，快速识别 RC 柱的失效风险。需要明确的是，本研究构建的模型本质上属于有限元结果的代理模型，其适用范围主要集中于本文数据库参数范围覆盖的区间内进行规律预测与参数分析。对于真实复杂爆炸场景下的 RC 柱损伤预测，仍需在未引入大量试验数据进行进一步的修正。




图 13 六组测试工况下的 RC 柱有限元归一化损伤指标云图（侧视图）：(c)、(e)、(f) 中度破坏；
(a)、(b)、(d) 重度破坏

Fig. 13 Finite element scaled damage measure contours of RC columns under six test cases (side view): (c), (e), (f) moderate damage; (a), (b), (d) severe damage.

在计算时效性方面，TabPFN 模型展现了显著优势。针对上述六组工况，传统的有限元数值模拟平均单次耗时约 1 小时，而本模型单次损伤评估仅需约 0.5 秒。这意味着在保证对数值计算结果具有良好拟合精度的前提下，该模型将计算效率提升了近 4 个数量级，实现了爆炸荷载作用下 RC 柱数值模拟损伤的快速代理计算，能够为 RC 柱抗爆优化设计的前期参数分析提供高效的数据支持。

4.5 研究局限性及展望

尽管本研究提出了基于 TabPFN 模型的 RC 柱爆炸损伤预测方法，但当前数据库仍存在一定局限性。首先，在构建的 3,133 个样本中，数值模拟数据占据主导，真实试验数据占比较小，这种样本比例失衡可能引入潜在偏差。由于机器学习模型主要学习 LS-DYNA 内置的物理法则与本构规律，难以完全涵盖真实爆炸场景中的复杂因素。因此，尽管生成数据前已通过 Woodson & Baylot 试验验证了数值方法的准确性，模型在处理真实极端爆炸场景时的泛化能力仍面临挑战。鉴于真实爆炸试验成本高昂且实施受限，未来研究将致力于收集更多高质量的现场试验数据，并考虑引入迁移学习策略，即利用大规模模拟数据进行预训练，再结合小样本真实数据进行微调，从而消除潜在偏差，提升预测模型在实际工程应用中的泛化能力。此外，本文在特征输入方面仍存在一定局限性。在现行结构设计规范中，RC 柱的配筋通常由截面配筋构造形式与配筋率进行统一表达。由于截面配筋构造形式作为单独变量直接输入模型不易实现，采用体积配箍率替代导致现有分析无法直接区分箍筋总量和内部拉筋布置方式的独立影响。未来研究将探索更合理的特征变量，以明确不同配筋构造的力学机制。

5 结论

本研究通过数值模拟与实验数据的对比验证，确立了数值模拟方法的可靠性，并考虑箍筋局部加密以贴近工程实际。在此基础上，结合 259 组文献数据样本和 2874 组数值模拟补充数据，构建了 RC 柱爆炸荷载作用下损伤数据库，开发了六种机器学习模型以预测 RC 柱的爆炸损伤指数，并引入

SHAP 方法评估输入特征的重要性。最后,通过模型预测值与有限元模拟结果的对比分析,验证了 TabPFN 模型作为代理模型在未见工况下具备良好的预测稳定性。主要结论如下:

(1) 通过整合文献数据样本与数值模拟扩充的数据样本,建立了包含 3133 组样本的 RC 柱爆炸损伤数据集。该数据集涵盖了箍筋局部加密等关键特征,为基于剩余承载力的损伤评估提供了可靠的数据支撑。

(2) 在对比的 DT、RF、XGBoost、LightGBM、MLP 和 TabPFN 六种模型中,TabPFN 展现出最优的泛化能力与预测精度。其在测试集上的决定系数 (R^2) 高达 0.989、平均绝对误差 (MAE) 及均方根误差 (RMSE) 仅为 0.018 和 0.030,性能指标显著优于其它模型,被确定为预测 RC 柱爆炸损伤指数的最佳模型。

(3) 基于 SHAP 的可解释性分析表明,炸药质量 (W)、爆炸距离 (R)、柱深 (h) 及轴压比 (N_f) 是主导 RC 柱抗爆性能的关键特征,在损伤评估中需重点考量。特征重要性分析显示,体积配箍率 (ρ_v) 对抗爆性能的贡献度显著高于纵筋配筋率 (ρ_l)。通过减小柱端箍筋间距可以有效提升抗爆能力;相比之下,增加纵筋配筋率的抗爆收益有限。因此,在进行抗爆设计时,纵向受力钢筋的配筋率并非重要考虑因素,通常仅需满足 RC 柱常规承载力设计要求即可。

(4) 基于模型预测值与独立有限元模拟工况的对比分析,验证了 TabPFN 模型能够较好地拟合本文涉及的数值计算结果,作为代理模型在多参数耦合工况下具有良好的预测稳定性。在计算效能方面,该模型单次损伤预测耗时仅约 0.5 s,较传统数值模拟方法的计算效率显著提升了近 4 个数量级。建立的模型实现了爆炸荷载作用下 RC 柱数值模拟损伤结果的高效代理计算,在本文所限定的参数范围内,可为结构抗爆前期设计与参数敏感性分析提供快速的数据支撑。

参考文献

- [1] KIAKOJOURI F, DE BIAGI V, CHIAIA B, et al. Strengthening and retrofitting techniques to mitigate progressive collapse: A critical review and future research agenda [J]. *Engineering Structures*, 2022, 262: 114274. DOI: 10.1016/j.engstruct.2022.114274.
- [2] YUAN S, LI Y, ZONG Z, et al. A review on close-in blast performance of RC bridge columns [J]. *Journal of Traffic and Transportation Engineering (English Edition)*, 2023, 10(4): 675-696. DOI: 10.1016/j.jtte.2023.07.001.
- [3] BYFIELD M, PARAMASIVAM S. Murrah Building Collapse: Reassessment of the Transfer Girder [J]. *Journal of Performance of Constructed Facilities*, 2012, 26(4): 371-376. DOI: 10.1061/(ASCE)CF.1943-5509.0000227.
- [4] LI Q M, MENG H. Pressure-impulse diagram for blast loads based on dimensional analysis and single-degree-of-freedom model [J]. *Journal of Engineering Mechanics*, 2002, 128(1): 87-92. DOI: 10.1061/(ASCE)0733-9399(2002)128:1(87).
- [5] YU R, CHEN L, FANG Q, et al. Generation of pressure-impulse diagrams for failure modes of RC columns subjected to blast loads [J]. *Engineering Failure Analysis*, 2019, 100: 520-535. DOI: 10.1016/j.engfailanal.2019.02.001.
- [6] YUAN S, HAO H, ZONG Z, et al. A study of RC bridge columns under contact explosion [J]. *International Journal of Impact Engineering*, 2017, 109: 378-390. DOI: 10.1016/j.ijimpeng.2017.07.017.
- [7] DUA A, BRAIMAH A, KUMAR M. Experimental and numerical investigation of rectangular reinforced concrete columns under contact explosion effects [J]. *Engineering Structures*, 2020, 205: 109891. DOI: 10.1016/j.engstruct.2019.109891.
- [8] SHI Y C, HU Y, CHEN L, et al. Experimental investigation into the close-in blast performance of RC columns with axial loading [J]. *Engineering Structures*, 2022, 268: 114688. DOI: 10.1016/j.engstruct.2022.114688.
- [9] WU K-C, LI B, TSAI K-C. Residual axial compression capacity of localized blast-damaged RC columns [J]. *International Journal of Impact Engineering*, 2011, 38(1): 29-40. DOI: 10.1016/j.ijimpeng.2010.09.002.
- [10] LIN S C, HU Z Q, HAN J Q, et al. Failure time of reinforced concrete column under blast load [J]. *Structures*, 2023, 53:

- 1122-1134. DOI: 10.1016/j.istruc.2023.04.128.
- [11] SHI Y C, XIE C L, YU M L. Numerical derivation of pressure-impulse (P-I) diagrams of prefabricated RC columns with steel joints subjected to blast loads [J]. Structures, 2024, 66: 106796. DOI: 10.1016/j.istruc.2024.106796.
- [12] 赵春风, 吴艺秀, 向思麒, 等. 基于 XGBoost 的 PC 板爆炸损伤评估模型 [J]. 爆炸与冲击, 2026, 46(5): 051443. DOI: 10.11883/bzycj-2025-0250.
- ZHAO C F, WU Y X, XIANG S Q, et al. Blast damage assessment model of PC slabs based on XGBoost [J]. Explosion and Shock Waves, 2026, 46(5): 051443. DOI: 10.11883/bzycj-2025-0250.
- [13] 朱玉富, 赵春风, 周志航. 基于机器学习的钢筋混凝土板在爆炸作用下的最大位移预测模型 [J]. 高压物理学报, 2023, 37(02): 92-106. DOI: 10.11858/gywlxb.20220667.
- ZHU Y F, ZHAO C F, ZHOU Z H. Prediction model of maximum displacement for rc slabs under blast load based on machine learning [J]. Chinese Journal of High Pressure Physics, 2023, 37(02): 92-106. DOI: 10.11858/gywlxb.20220667.
- [14] 郑文言, 段利亚, 方辉. 近距离爆炸下钢筋混凝土柱损伤的图像识别及快速评估 [J]. 防灾减灾工程学报, 2023, 43(04): 712-720. DOI: 10.13409/j.cnki.jdpme.20211122002.
- ZHENG W Y, DUAN L Y, FANG H. Assessment of reinforced concrete column damage after near-field explosion based on image recognition [J]. Journal of Disaster Prevention and Mitigation Engineering, 2023, 43(04): 712-720. DOI: 10.13409/j.cnki.jdpme.20211122002.
- [15] YANG D K, YANG J, SHI J. Prediction and analysis of damage to RC columns under close-in blast loads based on machine learning and Monte Carlo method [J]. Engineering Structures, 2024, 318: 118787. DOI: 10.1016/j.engstruct.2024.118787.
- [16] ZHAO C F, SU J, ZHU Y F, et al. Machine learning-based two-stage damage prediction method for RC slabs under blast loads [J]. Advances in Engineering Software, 2025, 208: 103959. DOI: 10.1016/j.advengsoft.2025.103959.
- [17] PENG J Z, PAN L J, WANG Z Q, et al. Self-adaptive graph neural network for predicting blast-induced damage in RC columns across multiple scenarios [J]. Engineering Structures, 2025, 337: 120505. DOI: 10.1016/j.engstruct.2025.120505.
- [18] MALVAR L J, CRAWFORD J E, WESEVICH J W, et al. A plasticity concrete material model for DYNA3D [J]. International Journal of Impact Engineering, 1997, 19(9-10): 847-873. DOI: 10.1016/s0734-743x(97)00023-7.
- [19] LI J, HAO H. Influence of brittle shear damage on accuracy of the two-step method in prediction of structural response to blast loads [J]. International Journal of Impact Engineering, 2013, 54: 217-231. DOI: 10.1016/j.ijimpeng.2012.11.008.
- [20] HAO Y F, HAO H. Influence of the concrete DIF model on the numerical predictions of RC wall responses to blast loadings [J]. Engineering Structures, 2014, 73: 24-38. DOI: 10.1016/j.engstruct.2014.04.042.
- [21] MALVAR L J, CRAWFORD J E. Dynamic increase factors for steel reinforcing bars [J]. 1998.
- [22] BAYLOT J T, BEVINS T L. Effect of responding and failing structural components on the airblast pressures and loads on and inside of the structure [J]. Computers & Structures, 2007, 85(11-14): 891-910. DOI: 10.1016/j.compstruc.2007.01.001.
- [23] SHIN J, JEON J S. Retrofit scheme of FRP jacketing system for blast damage mitigation of non-ductile RC building frames [J]. Composite Structures, 2019, 228: 111328. DOI: 10.1016/j.compstruct.2019.111328.
- [24] THAI D K, KIM S E. Numerical investigation of the damage of RC members subjected to blast loading [J]. Engineering Failure Analysis, 2018, 92: 350-367. DOI: 10.1016/j.engfailanal.2018.06.001.
- [25] 师燕超, 李绍琦, 李忠献, 等. 基于实测频率的钢筋混凝土柱爆炸损伤快速评估方法 [J]. 建筑结构学报, 2021, 42(11): 155-164. DOI: 10.14006/j.jzjgxb.2019.0664.
- SHI Y C, LI S Q, LI Z X, et al. Rapid evaluation method for blast damage of reinforced concrete columns based on measured frequency [J]. Journal of Building Structures, 2021, 42(11): 155-164. DOI: 10.14006/j.jzjgxb.2019.0664.
- [26] 吴文燕, 卢伟. 爆炸作用时钢筋混凝土柱损伤因素分析 [J]. 工程爆破, 2021, 27(02): 58-65. DOI:

- 10.19931/j.EB.20200063.
- WU W Y, LU W. Analysis of explosion damage factors in reinforced concrete columns [J]. *Engineering Blasting*, 2021, 27(02): 58-65. **DOI:** 10.19931/j.EB.20200063.
- [27] GB 50010-2010. 混凝土结构设计规范 [S]. 北京: 中国建筑工业出版社, 2015.
- [28] BERRY M. PEER structural performance database user's manual (version 1.0) [J]. University of California, 2004.
- [29] LI Z X, ZHANG X J, SHI Y C, et al. Predication of the residual axial load capacity of CFRP-strengthened RC column subjected to blast loading using artificial neural network [J]. *Engineering Structures*, 2021, 242: 112519. **DOI:** 10.1016/j.engstruct.2021.112519.
- [30] 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. **DOI:** 10.1016/j.engstruct.2022.114949.
- [31] GB 50011-2010. 建筑抗震设计规范 [S]. 北京: 中国建筑工业出版社, 2010.
- [32] T/CECS 736-2020. 民用建筑防爆设计标准 [S]. 北京: 中国建筑工业出版社, 2020.
- [33] GB50180-2018. 城市居住区规划设计标准 [S]. 北京: 中国建筑工业出版社, 2018.
- [34] SHI Y C, HAO H, LI Z X. Numerical derivation of pressure-impulse diagrams for prediction of RC column damage to blast loads [J]. *International Journal of Impact Engineering*, 2008, 35(11): 1213-1227. **DOI:** 10.1016/j.ijimpeng.2007.09.001.
- [35] BAO X L, LI B. Residual strength of blast damaged reinforced concrete columns [J]. *International Journal of Impact Engineering*, 2010, 37(3): 295-308. **DOI:** 10.1016/j.ijimpeng.2009.04.003.
- [36] LI J, WU C Q, HAO H, et al. Post-blast capacity of ultra-high performance concrete columns [J]. *Engineering Structures*, 2017, 134: 289-302. **DOI:** 10.1016/j.engstruct.2016.12.057.
- [37] 张兴站. 爆炸荷载作用下钢筋混凝土箍筋加密柱的动力响应 [D]. 西安: 西安建筑科技大学, 2018: 46-46.
- [38] ZHOU B X, CHEN X, CHEN S W. Failure mechanism and residual load bearing capacity of blast-loaded reinforced concrete bridge column considering bottom corrosion effect [J]. *Structures*, 2025, 75: 108668. **DOI:** 10.1016/j.istruc.2025.108668.
- [39] HE J G, JIANG L Q, JIANG L Z, et al. Estimation of blast-induced peak response of concrete-filled double-skin tube columns by intelligence-based technique [J]. *Thin-Walled Structures*, 2023, 186: 110670. **DOI:** 10.1016/j.tws.2023.110670.
- [40] BREIMAN L. Random Forests [J]. *Machine Learning*, 2001, 45(1): 5-32. **DOI:** 10.1023/a:1010933404324.
- [41] CHEN T, GUESTRIN C. XGBoost: A Scalable Tree Boosting System [Z]. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco, California, USA; Association for Computing Machinery, 2016: 785-794. **DOI:** 10.1145/2939672.2939785.
- [42] KE G, MENG Q, FINLEY T, et al. Lightgbm: A highly efficient gradient boosting decision tree [J]. *Advances in neural information processing systems*, 2017, 30. **DOI:** 10.5555/3294996.3295074.
- [43] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. *Nature*, 1986, 323(6088): 533-536. **DOI:** 10.1038/323533a0.
- [44] HOLLMANN N, MULLER S, PURUCKER L, et al. Accurate predictions on small data with a tabular foundation model [J]. *Nature*, 2025, 637(8045): 319-326. **DOI:** 10.1038/s41586-024-08328-6.
- [45] HU J, JIANG L, HU Y, et al. Machine learning-based axial compressive capacity estimation of cold-formed steel build-up sections [J]. *Thin-Walled Structures*, 2025, 206: 112669. **DOI:** 10.1016/j.tws.2024.112669.
- [46] YANG J, HAO Y, PENG D, et al. Machine Learning-Based Methods for Predicting the Structural Damage and Failure Mode of RC Slabs Under Blast Loading [J]. *Buildings*, 2025, 15(8): 1221. **DOI:** 10.3390/buildings15081221.
- [47] AKIBA T, SANO S, YANASE T, et al. Optuna: A next-generation hyperparameter optimization framework [C]// *proceedings of the Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data*

mining, 2019: 2623-2631.

录用稿件，
非最终出版稿