

基于贝叶斯深度主动学习的三维城市建筑群 爆炸载荷快速预测*

潘美霖¹, 张情¹, 邱玖禄¹, 田宙¹, 钟巍¹, 冷春江², 彭卫文²

(1.西北核技术研究所 强脉冲辐射环境模拟与效应全国重点实验室, 陕西 西安 710024;

2.中山大学 智能工程学院, 广东 广州 510275)

摘要: 城市爆炸载荷快速预测对于防灾设计、应急救援及灾后重建具有重要意义。针对现有基于深度学习的预测模型依赖大量高质量样本、建模成本高且样本利用率低的问题, 提出一种基于贝叶斯深度主动学习 (Bayesian Deep Active Learning, BDAL) 的三维城市建筑群爆炸载荷快速预测方法。研究在三维空间构建规则化城市建筑群, 设定包含能量源当量、起爆距离、建筑尺寸及街道特征的七维参数空间, 采用全因子实验设计系统生成参数组合, 并利用 blastFoam 软件开展三维数值模拟, 获取关键位置超压峰值数据。基于贝叶斯推断实现模型参数的概率化建模, 结合主动采样策略量化预测不确定性并优化样本选择, 从而提升样本利用效率。测试结果显示, 在 780 组未经训练样本上, 该方法的平均绝对百分比误差为 13.1%, 预测区间覆盖真实值的概率为 85.9%, 单点预测响应时间小于 20 ms, 仅需约 50% 的标注数据即可达到与全样本训练的被动式深度学习模型相近的精度。结果表明, 该方法可在典型规则化三维城市环境中实现高效、低成本的爆炸载荷预测, 具有防灾减灾领域的应用潜力。

关键词: 三维典型城市; 爆炸载荷; 贝叶斯深度学习; 主动学习

中图分类号: TP183

国标学科代码: 130.3520

文献标识码: A

Fast prediction of blast loading for three-dimensional urban building clusters based on Bayesian deep active learning

PAN Meilin¹, ZHANG Qing¹, QIU Jiulu¹, TIAN Zhou¹, ZHONG Wei¹, LENG Chunjiang², PENG Weiwen²

(1. *National Key Laboratory of Intense Pulsed Radiation Simulation and Effect, Northwest Institute of Nuclear Technology,*

Xi'an 710024, Shaanxi, China;

2. School of Intelligent Systems Engineering, Sun Yat-sen University, Guangzhou 510275, Guangdong, China)

Abstract: To address the high cost and low sample efficiency of deep learning-based blast loading prediction in urban environments, a Bayesian deep active learning (BDAL) method is proposed. The objective is to significantly reduce the dependency on large-scale, high-fidelity numerical simulation data while maintaining prediction accuracy and providing reliable uncertainty quantification. A three-dimensional typical urban building cluster consisting of a 3×3 regular array of cuboid buildings was constructed. A seven-dimensional parameter space was defined, including explosive charge equivalence (1000, 2000, 3000 kT), detonation distance (1000, 2000, 3000 m), building length (10, 20, 30 m), building width (20, 40 m), building height (75, 100 m), street length (50, 75, 100 m), and street width (50, 75 m). A full factorial experimental design was employed,

*收稿日期: 2025-11-25; 修回日期: 2026-0414;

第一作者: 潘美霖 (1999-), 女, 硕士. E-mail: panml25@mails.tsinghua.edu.cn;

通信作者: 钟巍 (1986-), 男, 博士, 研究员. E-mail: zhongwei@nint.ac.cn.

generating 648 parameter combinations. For each combination, the open-source computational fluid dynamics (CFD) software blastFoam was used to perform three-dimensional numerical simulations of blast wave propagation. The background mesh size was set to 30 m based on grid sensitivity analysis, and adaptive mesh refinement (AMR) with local refinement level 2 and dynamic refinement level 1 was applied to capture shock wave details. Peak overpressure values were recorded at 12 points of interest (POIs) in the building cluster, resulting in a dataset of 7776 samples. A BDAL framework was then developed. Bayesian inference was integrated into a deep neural network to enable probabilistic modeling of parameters. Monte Carlo dropout (MC-Dropout) was adopted as an approximate variational inference method to estimate predictive uncertainty. An uncertainty-driven active sampling strategy was designed: the predictive variance of each unlabeled sample was computed via 30 stochastic forward passes with dropout enabled. Samples with variance exceeding 85% of the maximum variance were selected as candidates, and the top 28 cases (336 samples) with the highest variance were chosen in each active learning cycle. These selected samples were labeled by the blastFoam simulator and added to the training set. The model was retrained iteratively until the relative improvement in mean absolute percentage error (MAPE) fell below 1% or the labeled set reached the full training size. On a test set of 780 unseen samples (65 cases), the proposed BDAL method achieved a MAPE of 13.1% and an R^2 of 0.972 for peak overpressure prediction. The 95% prediction interval covered the true values in 85.9% of the cases, with a normalized mean prediction interval width (NMPIW) of 0.026. Single-point prediction response time was below 20 ms, representing a speedup of more than 10^5 compared to high-fidelity numerical simulations. Compared to passive deep learning models trained on the full dataset, the BDAL method required only about 50% of labeled data to reach comparable prediction accuracy. In a comparative experiment with 50% training data, BDAL achieved a MAPE of 17.2%, while a conventional fully connected neural network (FCNN) and a three-dimensional direction-encoded Bayesian neural network (3D-DeBNN) gave MAPEs of 52.9% and 22.6%, respectively. The proposed Bayesian deep active learning method enables efficient and low-cost blast loading prediction in typical regularized urban environments. It effectively reduces the dependency on large-scale numerical simulation data, maintains high prediction accuracy and reliable uncertainty quantification, and achieves millisecond-level inference speed. The method shows strong potential for disaster prevention and mitigation applications, such as pre-disaster anti-blast design and post-disaster emergency response.

Keywords: three-dimensional typical city; blast loading; Bayesian deep learning; active learning

1 引言

爆炸事件在高人口密度和建筑密集的城市环境中具有极大的破坏性^[1-3]。快速预测城市爆炸载荷，是爆炸冲击波对现代城市建筑等目标的毁伤效应评估^[4-5]的核心需求，对指导灾前抗爆结构设计^[6-7]、优化灾后应急响应^[8]具有重要意义。然而，传统基于经验的爆炸载荷计算方法难以应用在复杂城市环境，高精度数值模拟需进行三维显式动力学瞬态计算，资源消耗大、计算时间长。深度学习具备强大的非线性映射与高维特征建模能力，相比数值模拟有显著的速度优势，已成为城市爆炸载荷快速预测研究的重要方向。

基于深度学习的爆炸载荷预测研究呈现从可行性验证到性能提升的演进轨迹。在验证深度学习在爆炸载荷预测领域的可行性方面，Remennikov等^[9]基于Air3D生成涵盖多种街道与建筑尺寸的数值模拟数据，采用四层全连接神经网络（Fully Connected Neural Network, FCNN）预测城市关键位置的压力峰值与冲量，结果表明FCNN预测值与CFD模拟值高度一致（ R^2 分别为0.993与0.995），推理耗时达毫秒级；黄沛吉等^[10]在缩比城市场景中基于FCNN对超压峰值进行高效预测，90%样本相对误差不超过10%、单点预测耗时不超过3 ms；Si等^[11]构建1D-2D-3D多尺度ALE仿真体系并以约19万条数据训练FCNN，实现城市街区建筑表面超压峰值与冲量的快速预测，平均相对误差分别

为 1.69%与 1.28%。这些研究证明了深度学习模型能够高效预测城市爆炸载荷，推理速度远快于数值模拟。

随后，学者们致力于提升深度学习的爆炸载荷预测性能，研究围绕泛化、效率、成本与精度持续推进。为提高爆炸载荷预测方法在不同场景中的泛化性，Dennis 等^[12-13]提出方向编码神经网络（Direction encoded Neural Network, DeNN），将波传播路径与障碍物方向信息等物理先验嵌入模型，在未见复杂场景中平均绝对误差约 5 kPa，该方法通过将空间信息作为模型输入，成功突破传统神经网络对预设场景的依赖性，为不同场景下的快速抗爆评估提供了通用新范式；Wang 等^[14]提出基于图神经网络的 BlastGraphNet，可在复杂三维建筑外表面实时预测超压峰值、冲量峰值与波阵面到达时间，在几何复杂性变化下仍保持强泛化，误差控制在约 2%以内。为提高爆炸载荷预测方法的效率，Dennis 等^[15-16]提出分支算法（Branching Algorithm, BA）以跨场景复用特征，处理 20 个模型批次时计算时间降低约 80%，并与 DeNN 联用以兼顾效率与精度。为降低计算成本，Pannell 等^[17]基于迁移学习在不同装药类型间复用知识，结果表明在数据删减条件下迁移神经网络的性能显著优于普通神经网络；Huang 等^[18]引入超分辨率重建（Super-Resolution Reconstruction, SRR）技术，将符号距离场（Signed Distance Field, SDF）和流场（Flow Region, FR）等记录流场信息的高分辨率通道与低分辨率压力场连接作为网络输入，以高分辨率数据作为网络输出，为获取高分辨率场数据提供了更具成本效益的技术路径。为提高城市复杂场景下的爆炸载荷预测精度，Kang 等^[19]构建融合场景空间信息的三维卷积神经网络（3D Convolutional Neural Network, 3DCNN），预测精度较传统多层感知器（Multilayer Perceptron, MLP）提升 2.5 倍；Peng 等^[20]将空间特征与贝叶斯深度学习（Bayesian Deep Learning, BDL）结合，所构造的 3D-DeBNN 模型在缩比城市场景中实现低于 5%的爆炸载荷预测误差；黄阳等^[21]提出 BlastOFormer，将镜像爆源法、信号距离场与能量密度因子等物理特征融入模型，对典型街区压力场预测的相对误差控制在 20%以内。

总体而言，基于深度学习的爆炸载荷预测方法相对于传统数值模拟有显著的速度优势，且现有研究在融合物理先验、空间编码与高效架构方面取得显著进展。但当前基于深度学习的城市爆炸载荷预测方法均采用被动学习范式，模型取得较高预测精度的前提是具备足够的训练样本。然而，城市爆炸数据的获取成本较高：实验方面，受限于爆炸试验的高危险性、高成本及严格的安全管控，实测数据获取效率极低；数值模拟方面，高精度爆炸流场仿真需采用显式动力学方法进行三维瞬态计算，需要消耗大量计算资源与计算时间，这种数据获取瓶颈导致基于深度学习的城市爆炸载荷预测方法存在模型构建成本高、样本效率低的问题。

针对上述不足，本文融合主动学习^[22-23]与贝叶斯深度学习，提出面向三维城市建筑群的贝叶斯深度主动学习（Bayesian Deep Active Learning, BDAL）框架，旨在在保证可信性的前提下，显著降低数据需求与模型构建成本，提升城市复杂环境中的快速预测能力。首先构建爆源与环境参数在较大范围内可变的典型城市建筑群，基于开源 CFD 软件进行不同工况下冲击波传播数值模拟，通过网络灵敏度分析和自适应网格细化获取兼顾模拟速度与计算精度的爆炸数据。然后，将贝叶斯原理与深度学习相结合，在快速给出城市载荷预测的同时输出预测不确定性，提升方法的工程可信性，并为主动样本选择与风险评估提供依据。进而利用基于不确定性的主动学习准则评估样本的边际价值，主动选择高价值数据用于训练，使模型在显著减少训练样本的条件下达到与被动深度学习相当的预测精度。最后，通过预测精度与不确定性量化效果评估、物理一致性验证以及主动学习效率分析等多维度验证，全面评估所提方法的有效性 with 优越性。

与已有工作相比，本文的主要创新点如下：

（1）首次将主动学习引入城市爆炸载荷预测任务。区别于现有被动式深度学习方法，本文构建了“训练-查询-标注-再训练”的动态迭代框架，通过不确定性驱动的样本筛选策略，显著降低模型对大规模预标注数据的依赖。

(2) 融合贝叶斯深度学习与主动采样机制。与同样采用贝叶斯神经网络 (Bayesian Neural Networks, BNN) 的 3D-DeBNN^[20]相比, 本文进一步将预测不确定性作为样本价值度量指标, 主动选择高信息密度样本进行仿真标注, 实现了模型精度与数据效率的联合优化。

(3) 构建了覆盖多维度参数空间的三维典型城市爆炸数据库。相较于现有研究多采用有限场景或二维简化模型, 本文设计了涵盖爆源当量、起爆距离、建筑尺寸、街道尺度等七维参数的 648 组典型工况, 基于 blastFoam 开展高保真三维数值模拟, 为主动学习方法提供了高质量的实验验证平台。

2 三维典型城市爆炸数值模拟

本研究采用 blastFoam 对城市场景爆炸载荷进行三维数值仿真, 通过动态监测城市关键位置处的压力, 量化分析并提取各监测位置的最大超压, 建立三维典型规则化城市爆炸载荷数据库, 为深度学习模型的训练和验证提供数据支撑。

2.1 场景构建与网格划分

2.1.1 规则化城市场景设计

在三维空间中设计典型 3×3 建筑群场景如图 1 所示, 9 个长方体建筑的形态参数 (建筑长度、宽度及高度) 相同, 均匀排列在建筑区 (各街道的长度和宽度相同), 自由场区“当量 Q ”的球形能量源在“起爆距离 R ”处引爆, 产生的冲击波与城市建筑群相互作用。

图 1 中灰色平面为建筑群中截面 ($\frac{h}{2}$ 高度水平面), 为表征建筑群区域内冲击波压力场的空间分布特征, 在建筑群中截面上系统性选取 12 个关键位置作为监测点 (图中红点), 涵盖建筑表面中点与街道中点, 以捕获压力场在典型几何特征处的响应。图 2 通过建筑群的侧视图和俯视图来进一步说明各感兴趣位置点 (Point of Interest, POI) 位置, 并给出 12 个 POI 的编号。

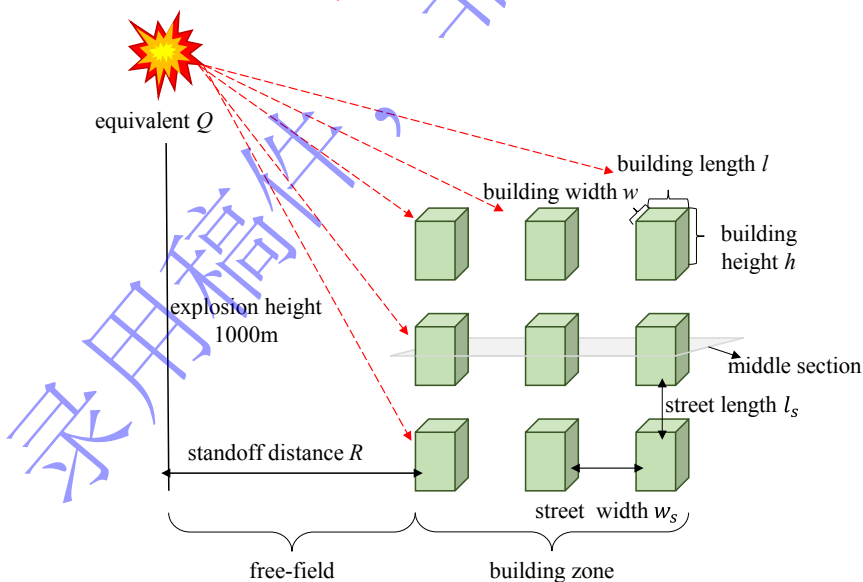


图 1 三维典型规则化城市场景模型

Fig.1 Three-dimensional typical regularized urban scene model

爆炸与冲击
Explosion and Shock Waves




图2 建筑群中监测点位置说明

Fig.2 Illustration of POI location in the building complex

表1 场景参数设计

Table 1 Scene parameter design

类型	参数	符号	单位	参数取值
爆源	爆源当量	Q	kT	(1000, 2000, 3000)
	起爆距离	R	m	(1000, 2000, 3000)
结构	建筑物长	l	m	(10, 20, 30)
	建筑物宽	w	m	(20, 40)
	建筑物高	h	m	(75, 100)
街道	街道长	l_s	m	(50, 75, 100)
	街道宽	w_s	m	(50, 75)

本文所构建的三维城市建筑群为规则排列的长方体建筑阵列，建筑形态与街道布局参数统一，属于典型参数化场景。场景中可变参量包括能量源当量 Q 、起爆距离 R 、建筑长 l 、建筑宽 w 、建筑高 h 、街道长 l_s 、街道宽 w_s 七个参数，结合实际场景与应用需求，设计每个参数的具体可选项如表1所示。其中，爆源当量取值为1000、2000、3000 kT，起爆距离取值为1000、2000、3000 m，对应强爆炸场景（如大型工业爆炸）。该参数范围的选取参考了强爆炸效应评估中的典型工况，旨在考察城市建筑群在极端爆炸载荷下的响应特征。穷举表1中的所有参数组合，得到共计648种计算工况。对于每种计算工况，基于Python构建blastFoam能够直接读取的建筑群STL模型，在每次数值模拟前导入到blastFoam算例下的几何文件路径。

2.1.2 计算网格划分

在建筑群模型导入后，构建包含爆源与建筑群的背景计算域。为精确捕捉冲击波传播细节，在背景网格划分基础上，进一步采用自适应网格细化（Adaptive Mesh Refinement, AMR）对关键区域进行局部加密。

(1) 基于灵敏度分析的背景网格划分

网格尺寸的设置直接影响数值模拟的精度与效率。一般而言，较大的网格尺寸可节省计算资源、提高计算速度，但会损失模拟精度；较小的网格则能更准确地捕捉物理细节，但计算成本显著增加。本研究利用blastFoam中的blockMesh工具生成背景网格，并通过网格灵敏度分析评估不同尺寸对计算结果的影响，以兼顾精度与效率。参照表1中的648种参数场景，随机选取一种基准工况，固定其余参数，改变背景网格尺寸，分析测点1处超压峰值的变化。结果如图3所示：随着网格尺寸减小，超压峰值逐渐增大并趋于稳定。当网格尺寸为30 m时，测点1处的超压峰值已接近稳定值；进

一步减小网格尺寸，结果仅在较小范围内波动，而计算时间显著增加。因此，为平衡计算精度与效率，最终选取 30 m 作为背景网格的最优尺寸。

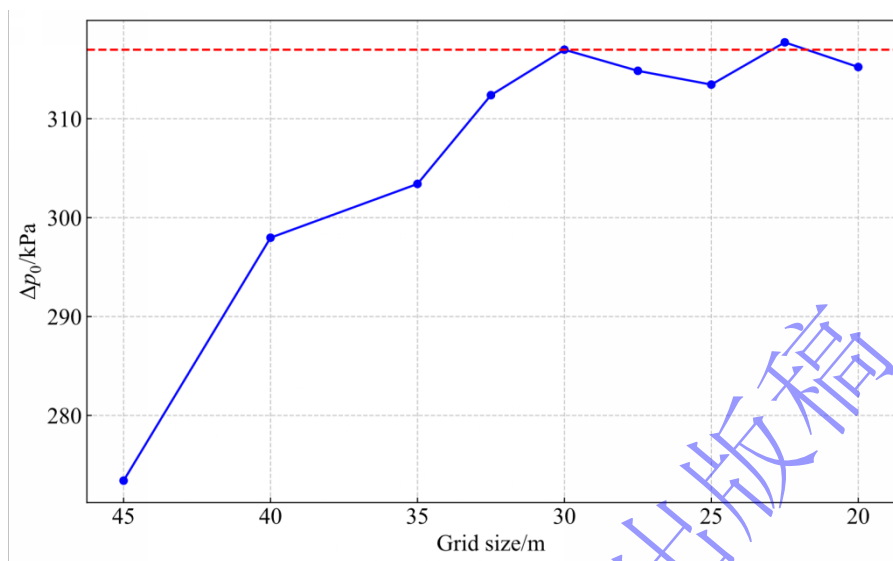



图3 网格灵敏性分析

Fig.3 Grid sensitivity analysis

(2) 自适应网格细化

AMR 能够根据物理场特征自动优化网格结构，在背景网格基础上对关键区域实施局部或动态加密，从而提高数值模拟的计算精度。其中，局部网格细化主要针对建筑结构附近区域，而动态网格细化则聚焦于冲击波传播前沿区域。



(a) The grid at the forefront of the shock wave

(b) The overall partitioning effect of the computational domain grid

图4 自适应网格细化效果展示

Fig.4 Display of adaptive mesh refinement effect

局部网格细化通过 snappyHexMesh 工具实现。由于冲击波在结构附近易发生反射、绕流等现象，导致物理参数变化剧烈，加密该区域网格有助于捕捉更准确的波传播特征。细化等级设定为 0 时，结构附近网格与背景网格尺寸相同；等级每提高一级，网格数量翻倍，例如等级 1 对应网格数量为背景的两倍，等级 2 为四倍，以此类推。动态网格细化基于 dynamicMesh 工具完成。该方法实时追踪冲击波的位置、速度与强度等参数，根据其传播特性自适应地加密波阵面区域的网格，从而精确捕捉冲击波传播过程中的细节特征。动态细化的等级设置与局部细化方式一致，各等级对应的网格密度关系相同。

为保证计算精度与计算效率，数值模拟实验中最终指定背景网格尺寸为 30m，局部细化和动态细化级别分别为 2 和 1。自适应网格细化效果如图 4 所示，其中图 4(a)可以明显观察到数值模拟过程中冲击波前沿的网格划分情况，图 4(b)展示计算域全局的网格划分情况，可以看到自适应网格细化使得冲击波前沿和结构附近的网格单元数量明显大于其他区域的网格单元数量。

2.2 数学模型与运算控制

本研究基于 blastFoam 求解器进行三维城市冲击波传播的数值计算。blastFoam 基于可压缩 Navier-Stokes 方程，通过 phaseProperties 文件定义状态方程模型及其输运系数。空气采用理想气体状态方程，TNT 采用式(1)所示的 JWL (Jones-Wilkins-Lee) 状态方程。

$$p = A \left(1 - \frac{\omega \rho}{R_1 \rho_0} \right) e^{-\frac{R_1 \rho_0}{\rho}} + B \left(1 - \frac{\omega \rho}{R_2 \rho_0} \right) e^{-\frac{R_2 \rho_0}{\rho}} + \omega p e^{\#(1)}$$

式中： p 为压力，单位 Pa； ρ 为当前密度，单位 kg/m^3 ， ρ_0 为初始未反应装药密度，单位 kg/m^3 ； e 为比内能，单位为 J/kg； A 、 B 为压力常数，单位为 Pa，由实验标定，控制高压段行为； R_1 、 R_2 为无量纲衰减系数，控制指数项衰减速率； ω 为热力学耦合系数，关联压力与内能的非理想气体效应。

场景顶部及周边设置为流出边界条件以忽略冲击波反射影响。实验中不考虑地表及结构表面的形变，故将其设定为刚性边界条件。除爆源和结构外的区域设定为空气，并采用正常大气初始条件。数值计算的时间步长为 $1e-6s$ ，计算过程中自动调整时间步长。通过 blastFoam 中 decomposePar 工具将计算域按并行运算所需的核心数切割为 320 份，在天河二号超级计算平台上实现 320 并行度的数值计算。

对于每次数值模拟，在建筑群中截面的 12 个感兴趣位置点处布置压力检测器，监控数值仿真过程中测点处的压力变化。数值计算完成后，收集每个测点处的压力-时间结果文件并进行异常值清除和缺失值填充，提取各位置超压峰值，构建反映建筑群区域压力场空间分布的离散数据集，为后续场分布预测建模提供支持。

为了增强特征的信息表达能力，在由“能量源当量 Q ”、“起爆距离 R ”、“建筑长 l ”、“建筑宽 w ”、“建筑高 h ”、“街道长 l_s ”和“街道宽 w_s ”构成的原始特征参数 $\mathbf{x}^0 = [Q, R, l, w, h, l_s, w_s]$ 的基础上，进一步加入 POI 位置坐标 (x_p, y_p, z_p) ，以及式(2)所示的比例距离 d ，构成样本特征 $\mathbf{x} = [(x_p, y_p, z_p), d, Q, R, l, w, h, l_s, w_s]$ ，样本标签为相应 POI 处的“超压峰值 Δp_0 ”。基于表 1 设计的 648 种场景参数，构建得到 648 组不同工况的数值模拟算例，每种场景参数下包含 12 个压力测点，因此共计获得包含 7776 组数据的超压峰值数据集。

$$d = \frac{L}{\sqrt[3]{Q}} \#(2)$$

式中： L 为 POI 到能量源中心的直线距离，单位 m； Q 为能量源当量，单位 kg。

3 基于贝叶斯深度主动学习的爆炸载荷快速预测

3.1 贝叶斯深度学习

贝叶斯深度学习区别于传统方法的核心特征在于其参数处理机制。该技术通过贝叶斯推断框架对模型参数进行概率建模，基于马尔可夫链蒙特卡洛采样技术完成模型优化过程。这种概率建模范式赋予爆炸载荷预测模型独特的优势：通过概率分布形式输出超压峰值，不仅提供预测结果，还能同步生成对应的置信度评估结果^[25]。

(1) 贝叶斯神经网络后验分布建模

训练数据集 $D_{train} = \{\mathbf{X}, \mathbf{Y}\}$ 中包含 N 个样本，其中 $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^N$ 表示样本特征， $\mathbf{Y} = \{y_i\}_{i=1}^N$ 表示样本标签。定义 $\boldsymbol{\theta} = \{\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots\}$ 为贝叶斯神经网络的参数集合，BNN 以特征向量 \mathbf{x} 为输入，以目标标量 y 为输出。已知模型参数 $\boldsymbol{\theta}$ 的先验分布 $p(\boldsymbol{\theta})$ 时，参数 $\boldsymbol{\theta}$ 的后验分布可以通过贝叶斯定理表示为：

$$p(\boldsymbol{\theta} | \mathbf{X}, Y) = \frac{p(\boldsymbol{\theta}) \cdot \prod_{i=1}^N p(y_i | \mathbf{x}_i, \boldsymbol{\theta})}{p(Y | \mathbf{X})} \quad \#(3)$$

为规避高维积分的计算，通过变分推断（Variational Inference, VI）将后验推断问题重构为变分优化任务。VI的核心思路是借助 Kullback-Leibler 散度（KL 散度）的优化过程，使近似分布 $q_\lambda(\boldsymbol{\theta})$ 与真实后验分布之间实现渐进式收敛。具体而言，通过系统地最小化两分布间的 KL 散度值，建立参数化分布对目标后验的数学逼近关系，其数学表达式及优化目标由式(4)和式(5)给出。

$$\begin{aligned} KL[q_\lambda(\boldsymbol{\theta}) || p(\boldsymbol{\theta} | D)] &= \int q_\lambda(\boldsymbol{\theta}) \log \left(\frac{q_\lambda(\boldsymbol{\theta})}{p(\boldsymbol{\theta} | D)} \right) d\boldsymbol{\theta} \\ &= \int q_\lambda(\boldsymbol{\theta}) \log \left(\frac{q_\lambda(\boldsymbol{\theta})}{p(\boldsymbol{\theta}, D) / p(D)} \right) d\boldsymbol{\theta} \quad \#(4) \\ &= \int q_\lambda(\boldsymbol{\theta}) \log p(D) d\boldsymbol{\theta} - \int q_\lambda(\boldsymbol{\theta}) \log \left(\frac{p(\boldsymbol{\theta}, D)}{q_\lambda(\boldsymbol{\theta})} \right) d\boldsymbol{\theta} \\ &= \log p(D) - \int q_\lambda(\boldsymbol{\theta}) \log \left(\frac{p(\boldsymbol{\theta}, D)}{q_\lambda(\boldsymbol{\theta})} \right) d\boldsymbol{\theta} \\ \lambda^* &= \arg \min_{\lambda} \left\{ - \int q_\lambda(\boldsymbol{\theta}) \log \left(\frac{p(\boldsymbol{\theta}, D)}{q_\lambda(\boldsymbol{\theta})} \right) d\boldsymbol{\theta} \right\} \\ &= \arg \min_{\lambda} \left\{ \int q_\lambda(\boldsymbol{\theta}) \log \left(\frac{q_\lambda(\boldsymbol{\theta})}{p(\boldsymbol{\theta})} \right) d\boldsymbol{\theta} - \int q_\lambda(\boldsymbol{\theta}) \log p(D | \boldsymbol{\theta}) d\boldsymbol{\theta} \right\} \quad \#(5) \\ &= \arg \min_{\lambda} \left\{ KL[q_\lambda(\boldsymbol{\theta}) || p(\boldsymbol{\theta})] - E_{\boldsymbol{\theta} \sim q_\lambda} [\log p(D | \boldsymbol{\theta})] \right\} \end{aligned}$$

式中： $E_{\boldsymbol{\theta} \sim q_\lambda} [\log p(D | \boldsymbol{\theta})]$ 为对数似然函数， λ^* 是最佳变分参数。

该优化等价于最小化证据下界（Evidence Lower Bound, ELBO）：

$$ELBO(\lambda) = E_{q_\lambda} [\log p(D | \boldsymbol{\theta})] - KL[q_\lambda(\boldsymbol{\theta}) || p(\boldsymbol{\theta} | D)] \quad \#(6)$$

式中：等号右边的第一项为数据似然的期望，推动变分分布拟合数据；第二项约束变分分布接近先验，防止过拟合。

基于参数后验分布的推导结果，BNN 对于新观测值 \mathbf{x}' 建立的预测分布可以表述为：

$$p(y' | \mathbf{x}', \mathbf{X}, Y) = \int p(\boldsymbol{\theta} | \mathbf{X}, Y) \cdot p(y' | \mathbf{x}', \boldsymbol{\theta}) d\boldsymbol{\theta} \quad \#(7)$$

(2) 基于蒙特卡洛随机失活（Monte Carlo-Dropout, MC-Dropout）的近似变分推断

传统变分推断需要假设特定分布形式（如高斯分布），其协方差矩阵的计算复杂度随参数的维度平方增长。为此，蒙特卡洛随机失活提出一种轻量化替代方案：将 Dropout 操作解释为伯努利变分分布，即通过在神经网络训练和推理阶段随机屏蔽部分神经元，从而隐式地对网络权重施加伯努利先验。设模型第 s 层权重 $\boldsymbol{\theta}^s$ 中每个元素以 p 的概率被置为 0，则其变分分布可以建模为：

$$q_\lambda(\boldsymbol{\theta}^s) = \prod_{ij} (p \cdot \delta(0) + (1-p) \cdot \delta(\boldsymbol{\theta}_{ij}^s)) \quad \#(8)$$

式中 $\delta(\cdot)$ 为 Dirac 函数。

此时，损失函数融合了数据拟合项与正则化项：

$$\mathcal{L} = \frac{1}{2N} \sum_{i=1}^N \|y_i - f_{\boldsymbol{\theta}}(\mathbf{x}_i)\|^2 + \gamma \|\boldsymbol{\theta}\|^2 \quad \#(9)$$

式中 γ 为权重衰减系数，与 Dropout 概率相关联。

MC-Dropout 的核心优势在于其高效的不确定性估计能力，对于每个输入，多次采样结果的统计特性能够反映模型的认知不确定性。MC-Dropout 的实现包含以下关键步骤：首先在模型训练与推理阶段持续启用 Dropout 机制，对每个测试样本执行多次前向计算迭代。在每次迭代过程中，随机屏蔽部分神经元连接并采集网络输出层的预测值。通过预设次数的蒙特卡洛采样后，将获得的预测结果集进行集成计算，最终输出具有统计意义的预测均值。

(3) 不确定性量化与模型可解释性

针对每个测试样本，贝叶斯深度学习框架的迭代预测会产生波动性输出，这种特性为评估模型预测的可信程度提供了数据基础。当前主流的可信度评估指标主要包括预测方差和预测区间两类方法。其中，预测区间通过界定模型输出值的可能分布范围，在设定置信度后给出新样本预测值落入该区间的概率范围。本研究基于多次蒙特卡洛前向传播结果，取 2.5% 和 97.5% 分位数构建 95% 预测区间 (Prediction Interval, PI)，作为评估预测不确定性的标准。区间范围越宽，表明模型对当前输入的预测确定性越低。

预测模型的测试阶段打开 Dropout，通过 T 次前向传播采样，获得输出的经验分布：

$$p(y^* | x^*, X, Y) = \frac{1}{T} \sum_{t=1}^T p(y^* | f_{\hat{\theta}_t}(x^*)), \hat{\theta}_t \sim q_{\lambda^*}(\theta) \quad (10)$$

式中： $\hat{\theta}_t$ 为变分推断中近似变分分布 $q_{\lambda^*}(\theta)$ 的样本，最优参数为 λ^* ， x^* 为新输入模型的样本， y^* 为模型预测值， T 为采样次数。

将新的测试样本 x^* 输入训练完成的 BDL 模型，爆炸载荷的不确定性量化通过 T 次预测结果的 95% 预测区间来表达，如式(11)所示：

$$\text{PredictionInterval}(x^*, f_{\theta}(x^*)) = [l_{x^*}, u_{x^*}] \quad (11)$$

式中： l_{x^*} 是 T 次预测结果第 2.5% 的分位数， u_{x^*} 是 T 次预测结果第 97.5% 分位数。

3.2 主动学习原理

作为传统监督学习的标准范式，被动学习采用静态数据训练机制，其核心特征在于模型对完整标注数据集的绝对依赖性。该范式遵循以下严格流程：在数据预处理阶段，所有样本的标签信息必须通过实验测定或有限元仿真等数值模拟手段完整获取；在模型训练阶段，通过最小化预设损失函数完成参数优化，整个过程不涉及数据集的动态调整。尽管该范式在数据充足场景下具有理论完备性，但应用在爆炸载荷预测等计算密集型任务中时面临严重的效率瓶颈：首先，爆炸载荷仿真涉及复杂的数值计算，网格数量较大时单次数值模拟往往需要数小时至数天的计算周期，导致标注过程需要消耗较大的计算资源；其次，静态采样机制导致训练集存在数据冗余现象，部分样本对最终模型精度的边际贡献度低于整体水平。

针对上述问题，主动学习构建了动态优化的训练范式，通过设计智能查询机制实现训练数据的利用效率最大化。与被动学习不同，主动学习方法通常从少量初始标注数据出发，选取部分样本构建基础训练集。在模型初步训练后，系统会运用查询策略筛选未标注数据。例如，通过评估模型预测结果的不确定性，优先选择置信度最低的样本；或采用委员会投票法，让多个模型共同投票决定需标注的关键样本。筛选出的样本通过数值仿真生成标签后，会被加入训练集并触发模型增量更新。这种“筛选-标注-训练”的循环持续进行，直至模型达到预定精度或标注预算耗尽。

相比于传统方法，主动学习的自适应边界采样策略有望减少所需的数值模拟次数，为复杂城市场景的爆炸载荷预测提供高效的解决方案。因此，本研究将主动学习与基于贝叶斯神经网络的爆载荷预测模型结合，通过主动选择高质量的训练样本减少深度学习模型的构建成本。

3.3 贝叶斯深度主动学习框架

针对城市爆炸载荷预测中高保真数值仿真成本高昂的问题，本文提出一种贝叶斯深度主动学习框架。该框架的核心思想是：利用贝叶斯深度学习模型提供的预测不确定性作为向导，动态地从海量未标注样本中智能选择最具信息价值的子集进行仿真标注，从而以最小的计算代价，实现模型性能的快速提升。

3.3.1 不确定性驱动的样本选择准则

将完整数据集 D 划分为已标注集 $D_{labeled} = \{(X_L, Y_L)\}$ 和未标注集 $D_{unlabeled} = \{X_U\}$ 。主动学习的目标是设计一个查询策略，迭代地从 $D_{unlabeled}$ 中选择一批样本，通过数值仿真获取其标签 Y_U 后加入 $D_{labeled}$ ，从而高效更新模型。本文的查询策略基于BDL模型提供的预测不确定性。对于回归任务，采用预测方差作为不确定性的量化指标。给定一个已训练的贝叶斯神经网络 $f_{BDL}(\cdot)$ ，对于未标注样本 $x_i \in D_{unlabeled}$ ，通过MC-Dropout进行 T 次随机前向传播，得到一组预测值 $\{y_i^{(1)}, y_i^{(2)}, \dots, y_i^{(T)}\}$ 。其预测方差 $\sigma^2(x_i)$ 计算如下：

$$\sigma^2(x_i) = \frac{1}{T} \sum_{t=1}^T (y_i^{(t)} - \bar{y}_i)^2 \quad (12)$$

式中： T 为蒙特卡洛采样次数， $y_i^{(t)}$ 为第 t 次采样的预测值， $\bar{y}_i = \frac{1}{T} \sum_{t=1}^T y_i^{(t)}$ 为预测均值。

方差越大，表明模型对该样本的预测越不确定，其真实标签蕴含的信息量可能越大，因此标注该样本对改善模型认知的期望收益越高。为高效筛选高不确定性样本，采用一种改进型边界采样策略。每轮迭代中，计算未标注集中所有样本的预测方差，并设定动态阈值 $\tau = \alpha \cdot \max_{x \in D_{unlabeled}} \sigma^2(x)$ ，其中 α 为置信阈值。随后，从满足 $\sigma^2(x_i) > \tau$ 的样本中，选择方差最大的 K 组构成本轮的查询集 Q 。本研究经实验确定 $\alpha = 0.85$ ， K 为28组算例包含的336条样本（约占初始训练算例的5%），该设置能在模型更新频率与单轮计算成本之间取得良好平衡。

3.3.2 BDAL 算法流程

BDAL是一个“训练-查询-标注-再训练”的动态迭代过程，其完整流程如图5所示，具体步骤归纳如下：

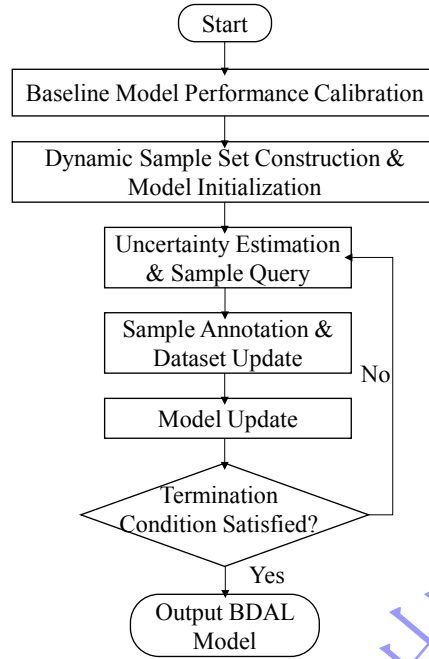


图 5 BDAL 实现流程

Fig.5 BDAL implementation process

步骤 1: 基准模型性能标定。采用分层随机抽样策略, 将原始数据集 D 按照 9:1 的比例分为训练集 D_{train} 和测试集 D_{test} 。通过 MC-Dropout 近似推理方法, 在完整训练集 D_{train} 上构建基准 BDL 模型, 并计算测试集 D_{test} 上爆炸载荷的预测精度作为基准精度 a_0 , 建立模型性能的量化基准。

步骤 2: 初始化。从初始训练集 D_{train} 中随机筛选出小部分样本 (本文为 28 组算例, 包含 336 条样本数据) 构成标记集 $D_{labeled}$, 剩余样本构成未标记集 $D_{unlabeled}$ 。利用 $D_{labeled}$ 训练一个初始的 BDL 模型。

步骤 3: 不确定性评估与样本查询。建立基于信息熵的主动查询机制, 使用当前模型对 $D_{unlabeled}$ 中的所有样本进行 T 次前向传播采样, 计算每个样本的预测方差 σ^2 。依据 3.3.1 节所述策略, 筛选出 K 组不确定性最高的样本。

步骤 4: 样本标注与数据集更新。对查询到的 K 组样本, 调用高保真数值仿真器计算其超压峰值标签。将这些新获得的 (样本, 标签) 对加入 $D_{labeled}$, 并从 $D_{unlabeled}$ 移除。

步骤 5: 模型更新: 使用扩增后的 $D_{labeled}$ 对整个 BDL 模型进行重新训练, 更新其网络权重参数。

步骤 6: 收敛判断。重复步骤 3-5, 直至满足预设的终止条件。本文设定双重终止准则: 当相对精度提升率 $\Delta a = |a_t - a_{t-1}| / a_0 < 1\%$ (a_t 为 t 次的模型预测精度, a_{t-1} 为第 $t-1$ 次的模型预测精度) 时, 或累计标注样本数 $N_{labeled} \geq N_{threshold} = |D_{train}|$ ($N_{labeled}$ 为累积标记样本数量, $N_{threshold}$ 为设定的最大样本标记数量) 时终止迭代, 输出最终的 BDAL 模型。

上述流程的伪代码如算法 1 所示。基于以上步骤, 最终得到用于爆炸载荷快速预测的训练 BDAL 模型。在计算资源受限场景下, 模型的训练数据通过优先筛选高不确定性的样本构建。

本文 BDAL 算法支持在线主动采样的工程闭环, 通过自研 Python 脚本实现模型与 blastFoam 的实时交互。该流程无需预先生成全量数据集, 可直接迭代筛选高价值样本并在线完成仿真标注, 从而适配实际工程中的低成本建模需求。

算法 1: 基于不确定性的贝叶斯深度主动学习

输入: 训练集 D_{train} 、未标记集 $D_{unlabeled}$ 、每轮查询样本数 K 、蒙特卡洛采样次数 T 、置信阈值 $\alpha = 0.85$ 、最大迭代

次数 M 。

输出：训练好的贝叶斯主动学习模型 f_{BDAL} 。

步骤：

1. 初始化：

从 D_{train} 中随机选取28组算例构建 D_{labeled} ，剩余样本构成 $D_{\text{unlabeled}}$ 。
使用 D_{labeled} 训练初始模型 f_{BDL} 。

2. for $t = 1$ to M do

3. 不确定性量化：

for each $\mathbf{x} \in D_{\text{unlabeled}}$ do

for $i = 1$ to T do

$y_i \leftarrow f_{\text{BDL}}(\mathbf{x})$ (启用 Dropout)

end for

计算预测方差 $\sigma^2(\mathbf{x})$

end for

4. 样本选择：

计算最大方差 $\sigma_{\text{max}} = \max_{\mathbf{x} \in D_{\text{unlabeled}}} \sigma^2(\mathbf{x})$

筛选候选集 $C = \{\mathbf{x} \in D_{\text{unlabeled}} \mid \sigma^2(\mathbf{x}) > \alpha \cdot \sigma_{\text{max}}^2\}$

选取方差最大的 K 个样本构成查询集 Q

5. 样本标注与更新：

对 $\mathbf{x} \in Q$ ，调用 blastFoam 仿真获取标签 y

$D_{\text{labeled}} \leftarrow D_{\text{labeled}} \cup \{(\mathbf{x}, y)\}$, $D_{\text{unlabeled}} \leftarrow D_{\text{unlabeled}} \setminus Q$

6. 模型更新：

使用 D_{labeled} 重新训练 f_{BDL}

7. 收敛判断：

if 测试集上精度变化率 $< 1\%$ or $|D_{\text{labeled}}| \geq |D_{\text{train}}|$ then

break

end if

8. end for

9. return f_{BDAL}

4 方法验证与结果分析

4.1 数据集划分与评估指标

对于通过 648 组数值模拟获得的 7776 条数据，按算例划分为训练集与测试集，比例设为 9:1。BDAL 模型在包含 583 组算例（共 6996 条数据）的训练集上训练，在包含 65 组算例（共 780 条数据）的测试集上进行性能评估。

需要指出，本文已通过自研 Python 脚本实现 BDAL 模型与 blastFoam 仿真平台的在线主动采样闭环：模型基于少量初始样本完成初步训练后，对未标注样本的预测不确定性进行量化，自动筛选高价值样本，直接调用 blastFoam 进行在线仿真标注，随后迭代更新模型。该流程无需预先生成海量数据集，可从源头减少数值仿真次数，切实降低实际建模的时间与计算成本。本文预先完成全部 648

组工况仿真，旨在受控条件下科学评估主动学习与被动学习的样本效率差异，并显性展示 BDAL 模型在降低模型构建成本方面的优越性能。

本文采用平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 与决定系数 (R^2) 评价模型预测精度，采用预测区间覆盖概率 (Prediction Interval Coverage Probability, PICP) 与归一化平均预测区间宽度 (Normalized Mean Prediction Interval Width, NMPIW) 评估不确定性量化效果。各指标定义如下：

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (14)$$

$$PICP = \frac{1}{N} \sum_{i=1}^N c_i, \quad c_i = \begin{cases} 1, & \text{if } l_i < y_i < u_i \\ 0, & \text{otherwise} \end{cases} \quad (15)$$

$$NMPIW = \frac{\frac{1}{N} \sum_{i=1}^N (u_i - l_i)}{y_{max} - y_{min}} \quad (16)$$

式中： N 为测试样本数量； y_i 、 \hat{y}_i 和 \bar{y} 分别为第 i 个样本的真实值、预测值和全体真实值的均值； l_i 和 u_i 分别为第 i 个样本 95%预测区间的下限与上限； y_{max} 和 y_{min} 分别为测试集中真实值的最大值与最小值。

MAPE 反映预测值与真实值之间的平均相对偏差，其值越小表明模型精度越高，完美预测对应 MAPE=0%。 R^2 衡量模型对数据变异的解释能力，取值范围为[0, 1]，越接近 1 表示拟合优度越高。PICP 表示真实值落在预测区间内的比例，用于评价区间估计的可靠性，理想情况下应接近预设置信水平（本文为 95%）。NMPIW 评价预测区间的平均宽度并经极差归一化，其值越小表明不确定性估计越集中，模型输出越确定。

4.2 超参数搜索与模型结构

本研究基于输入特征构建贝叶斯深度学习模型，采用 MC-Dropout 作为概率推理方法。模型主体为 3 层全连接网络（结构为 12-1000-1000-1000-1），隐藏层使用 ReLU 激活函数并施加 L2 正则化。为系统化地确定最优超参数配置以提升模型性能，采用网格搜索方法进行超参数优化。该方法通过遍历预定义的参数组合空间，并基于验证集性能（以最小化验证损失为目标）客观选择最佳参数，避免了主观选择的随意性。

表 2 超参数搜索范围

超参数	网格搜索范围
优化器	[SGD, Adam, RMSprop]
初始学习率	[0.0001, 0.001, 0.01, 0.1]
训练轮次	[5000, 10000, 15000]
Dropout 率	[0.1, 0.15, 0.2, 0.3, 0.5]

超参数搜索范围如表 2 所示。其中，优化器在基础优化器 SGD、能够自适应调整学习率的 Adam 以及适合非平稳目标的 RMSprop 三者中选取；初始学习率在四个数量级上搜索，以确定合适的梯度更新步长；最大训练周期设定了三个候选值，并配合早停机制防止过拟合；Dropout 率在 0.1 至 0.5 之间选取，用于平衡模型正则化强度与表达能力。

通过网格搜索，最终确定的超参数组合如下：优化器采用 Adam，其初始学习率设置为 0.001，并配合余弦退火策略进行调度，此组合在验证集上实现了最平稳且高效的收敛；最大训练周期设置为 10000 轮，同时引入早停机制（当验证损失连续 200 轮未下降时终止训练），确保了训练充分且避免了过拟合，训练批量大小固定为 1000；Dropout 率为 0.15，该值在有效控制过拟合的同时，保证了模型对预测不确定性的良好量化能力。测试阶段通过 30 次蒙特卡洛采样获得概率输出。

4.3 模型预测性能评估

4.3.1 实验平台与计算效率

本研究的数值模拟与模型训练分别依托天河二号超级计算中心与本地台式电脑完成，具体硬件配置见表 3。数值模拟采用开源软件 blastFoam 6.2.0，在天河二号平台上运行。每个计算工况分配 320 个并行核心，物理模拟时长设为 3~5 秒，单工况平均计算耗时约为 4~6 小时。BDAL 模型基于 Python 3.7 在本地台式机上构建并训练，单次训练耗时约 0.5 小时，主动学习全流程累计训练时间约为 2.5 小时。

表 3 数值模拟与模型训练平台配置

Table 3 Configuration of numerical simulation and model training platforms

平台	处理器	内存	操作系统
天河二号超级计算中心	2×12 Intel Xeon E5-2692 v2/单节点	128GB/单节点	Linux lon26 3.10.0-514.el7.x86_64
本地台式机	AMD Ryzen7 3700X 8 核	32 GB	Windows10

在上述实验平台上，BDAL 模型对包含 780 个样本的测试集进行批量预测，总耗时约 0.05 秒，单点推理时间低于 20 毫秒。作为对比，传统高保真数值模拟单工况平均需约 5 小时。据此估算，本文方法在保持可接受精度的前提下，取得了超过 10^5 倍的加速比，显著提升了爆炸载荷快速评估的工程实用性。

4.3.2 预测精度与不确定性量化

基于所构建的 BDAL 模型，在包含 780 组样本的测试集上对其预测精度及不确定性量化能力进行综合评估，结果如表 4 所示。

表 4 BDAL 模型的超压峰值预测结果

Table 4 Prediction results of peak overpressure by BDAL model

数据集	MAPE	R ²	PICP	NMPIW
训练集	0.142	0.974	0.893	0.021
测试集	0.131	0.972	0.859	0.026

在预测精度方面，模型对建筑群区域内压力场分布的预测表现出良好一致性，测试集上平均绝对百分比误差为 13.1%，反映出在场尺度上具备可靠的预测能力。且训练集与测试集的 MAPE 与 R² 高度接近，误差差异小于 1.1%，表明模型未出现过拟合，具备稳定的泛化能力。

在不确定性量化方面，模型在训练集和测试集上的 PICP 分别为 89.3%和 85.9%，其对应的 NMPIW 分别为 2.1%和 2.6%。尽管 PICP 低于理论上的 95%置信水平，但结合本研究问题的特点，该结果仍具有合理的解释力与工程适用性。爆炸冲击波在三维建筑群中传播时，受多次反射、绕射

及叠加效应影响，载荷分布呈现强非线性与非高斯特征，导致真实数据本身具有较高的固有不确定性。此外，数值仿真中采用的动态网格与自适应算法也会引入一定的数值波动。这些因素使得完全覆盖所有真实值的理想预测区间在实际中较难实现。然而，当前模型仍能提供覆盖约 86% 真实值的较窄预测区间，说明其在辨识主要不确定性来源的同时，避免了区间过度保守而丧失决策信息价值，在可靠性与紧致性之间取得了较好平衡。未来研究将进一步探索分位数回归、深度集成等概率建模方法，以在保持区间紧致性的同时，提升预测区间的覆盖稳健性。

4.3.3 预测结果可视化分析

图 6 通过预测区间分析进一步验证了模型的可靠性。图中横轴为按数值模拟实测值升序排列的样本序列，纵轴为超压峰值。其中，橙色虚线表示实测曲线，绿色实线为模型预测值，蓝色区域表示 95% 预测区间。可以看出，BDAL 模型对超压峰值的预测曲线与真实值曲线高度吻合，且预测区间范围较窄，表明模型在具备较高预测精度的同时，亦具有可控的不确定性。

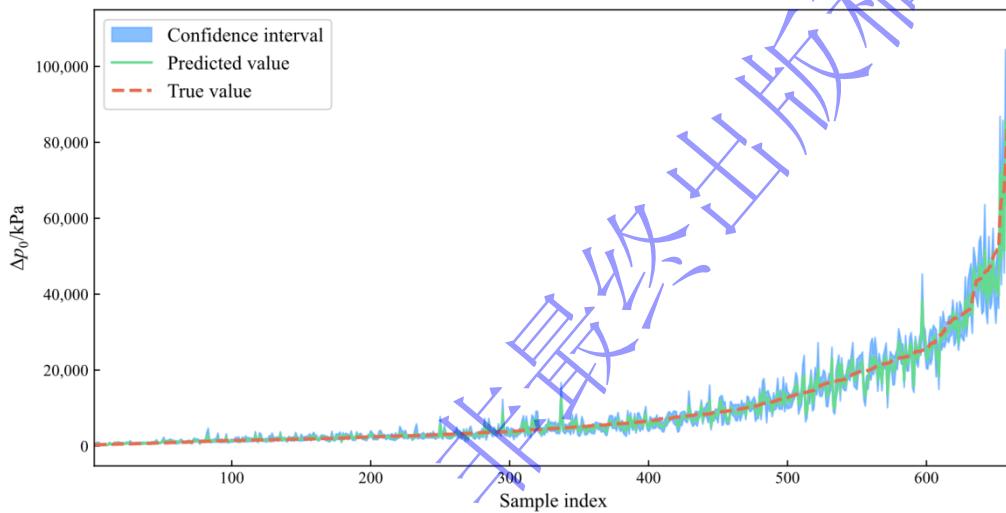


图 6 全样本模型预测区间图

Fig.6 Prediction interval graph for model prediction under full sample




图 7 数值模拟真实值与模型预测值散点图

Fig.7 Scatter plot of the real value of numerical simulation and the predicted value of model

为系统评估 BDAL 模型的预测性能，图 7 给出了数值模拟实测值与模型预测值在超压峰值上的散点对比。图中横、纵坐标分别对应实测值与模型预测值（单位：Pa），红色实线表示理想预测线（预测值与真实值相等），两条灰色虚线分别为 $\pm 30\%$ 误差边界。图中点集通过颜色深浅反映样本密度，暖色表示高密度区域。可以看出，绝大多数样本点紧密分布在理想预测线附近，且基本全部落在 $\pm 30\%$ 误差带以内，未见明显偏离趋势，表明模型在整个预测范围内均具有良好的准确性与泛化能力。

4.4 物理一致性验证

为确保所提 BDAL 模型不仅具备数值精度，而且能遵循爆炸冲击波传播的内在物理规律，本节从超压峰值随爆源参数的变化趋势与比例距离衰减规律两个层面，对模型的物理一致性进行系统验证。该分析旨在证明模型预测行为符合经典爆炸力学常识，而非对训练数据的简单拟合。

4.4.1 超压峰值随爆源参数的变化趋势

为验证所提 BDAL 模型是否遵循爆炸冲击波传播的基本物理规律，本节从空间衰减特性与能量尺度效应两个角度，分析超压峰值随起爆距离与爆源当量的变化趋势。

(1) 超压峰值随距离变化趋势验证

图 8 为从测试集中随机选取的三组工况下，爆炸冲击波在建筑群中传播时超压峰值的空间分布情况。每个案例包含两部分：上半部分为数值模拟真值，下半部分为 BDAL 模型预测结果。图中圆点颜色代表该 POI 处的超压峰值大小，颜色越深表示超压越高。整体来看，预测值与真值在空间分布形态上表现出较高的一致性，说明模型能较好地捕捉冲击波在复杂环境中的传播特性。

从数值模拟获得的超压峰值空间分布图中可以看出，距离爆源较近的观测点（如面向爆源的建筑前侧及街道入口处）超压高于较远观测点，其中位于迎爆面的建筑表面因冲击波反射作用而出现压力增强现象，超压达到最大。随着冲击波在建筑群中传播，经历绕射、反射与能量衰减，远离爆源或处于建筑背爆区的观测点超压逐渐降低，该分布特征符合冲击波在城市复杂环境中传播的物理规律。

对比 BDAL 模型预测结果与真实值可知，预测超压的空间分布形态与数值模拟结果高度吻合，表明模型能够准确捕捉冲击波随传播距离增加而衰减的趋势，并在建筑迎爆面与背爆区表现出合理的压力差异。这表明 BDAL 模型不仅在数值预测上具有较高精度，而且能够成功复现冲击波随距离衰减、迎爆面反射增强、背爆区压力降低等物理现象，具备良好的泛化能力与物理可信度。

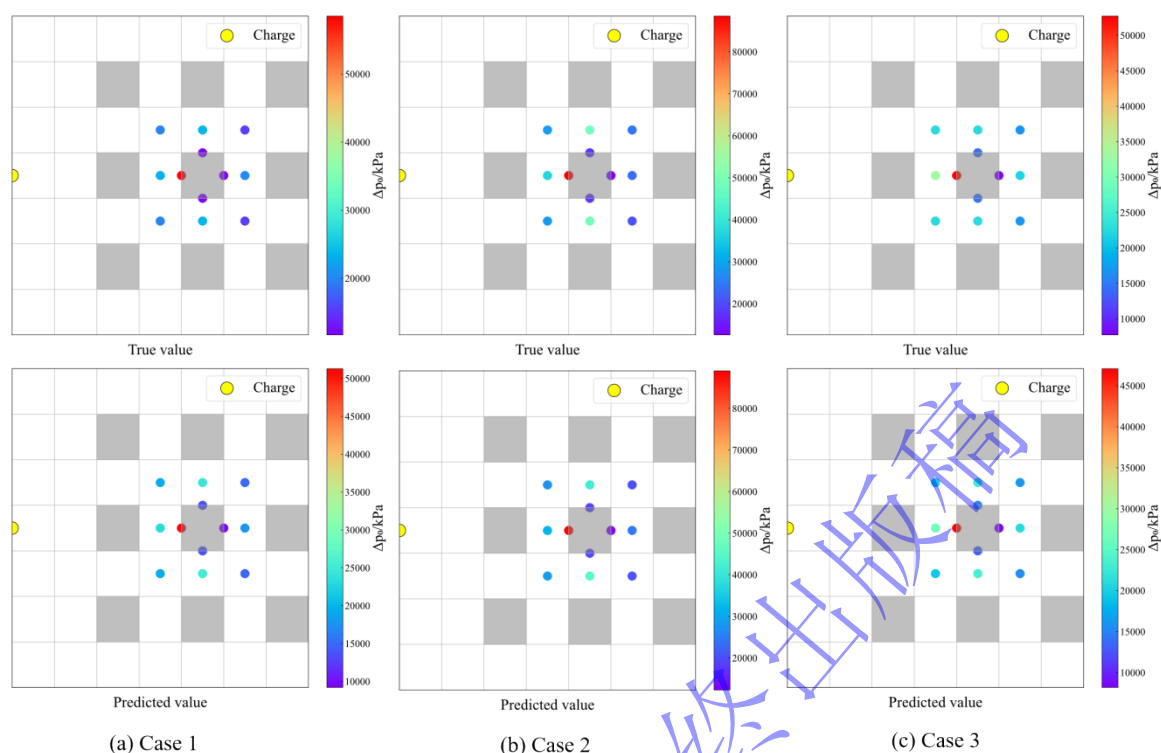


图 8 超压峰值分布热力图

Fig.8 Thermal map of peak overpressure distribution

(2) 超压峰值随当量的变化趋势验证

为验证 BDAL 模型对爆炸物理中当量-超压正相关规律的捕捉能力，从测试集中选取一组典型建筑布局，分析不同当量（1kkt、2kkt、3kkt）下各 POI 的超压响应。综合考虑对称性与位置特征，选取其中 8 个具有代表性的 POI，绘制其超压峰值随当量变化曲线如图 9 所示。图中依据位置将 POI 分为两组：街道中心点（POI 1、2、3、5、8）与建筑表面点（POI 4、6、7），其中数值模拟真值以点划线表示，模型预测值以实线表示。

为定量评估模型对物理趋势的预测一致性，进一步计算了各 POI 从 1kkt 到 3kkt 的超压增长百分比及其误差。趋势误差定义为模型预测的增长百分比与真实增长百分比之差的绝对值。图中标注了各点的计算结果，例如“POI1: 189.1% → 201.9% (Err=12.9%)”表示当量从 1kkt 增长到 3kkt 时，点 1 处超压峰值真实增长 189.1%，模型预测增长 201.9%，趋势误差为 12.9%。该分析可直接反映模型是否准确捕捉到超压随当量单调上升的物理规律。

图 9(a)和图 9(b)分别展示了街道中心点和建筑表面点处超压峰值随当量的变化趋势。可以看出，所有 POI 的超压峰值真值与预测值均随当量增加而单调上升，符合爆炸物理的基本规律。定量分析表明，各点真值在 1kkt 至 3kkt 区间内的增长百分比介于 177.7%至 190.2%之间，预测值的增长百分比介于 178.7%至 208.6%之间，趋势误差范围为 3.5%至 24.0%，所有 POI 的平均趋势误差为 15.3%。这说明模型对当量-超压关系预测较为准确，趋势一致性良好。其中点 7 处的预测增长百分比

（208.8%）高于真实增长百分比（184.6%），趋势误差最高（24.0%）。这可能是因为建筑表面点受到反射、遮挡等复杂边界效应的影响，增加了模型准确捕捉其非线性响应规律的难度。

总体而言，模型能够正确反映当量-超压正相关规律，为复杂场景下超压峰值的快速预测提供了可行工具。未来工作将着重优化模型对建筑表面等复杂边界条件下非线性效应的建模能力，以进一步提升预测精度。

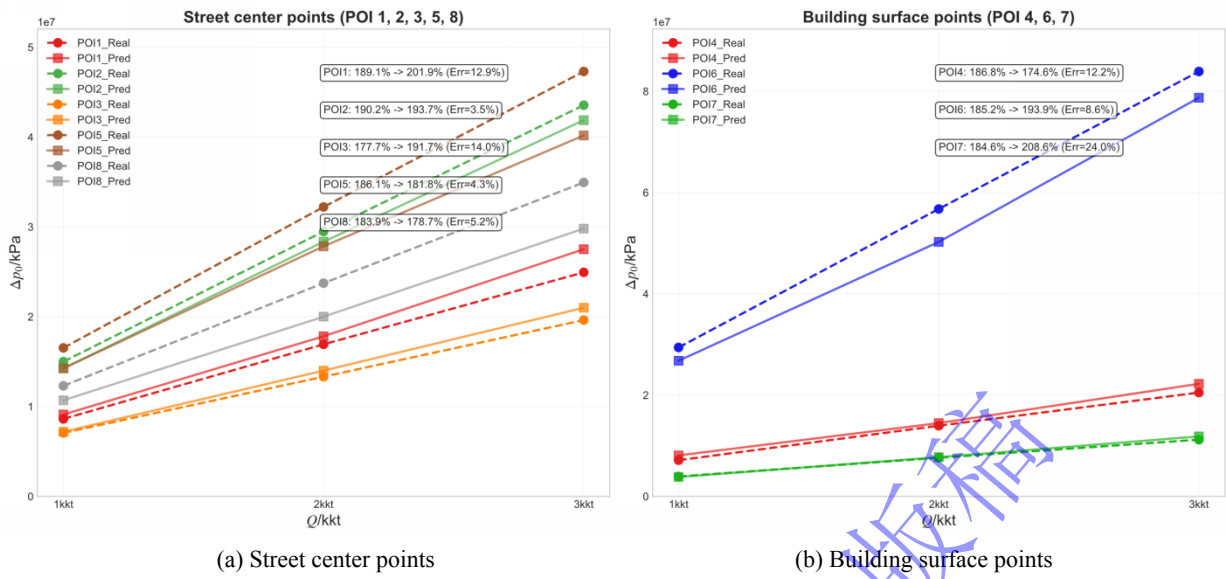


图 9 超压峰值随当量变化趋势

Fig.9 The variation trend of peak overpressure with equivalent value

4.4.2 比例距离衰减规律验证

为进一步验证模型是否内蕴经典爆炸相似律，依据式(2)定义的比例距离 d ，对测试集中所有样本进行分析。




图 10 超压峰值随比例距离变化情况

Fig.10 The variation of peak overpressure with the scaled distance

图 10 展示了超压峰值随比例距离的变化关系，其中横轴为比例距离 d ，纵轴为超压峰值 Δp_0 ，蓝色实线为根据式(17)所示的 Henrych 自由场经验公式^[26]计算得到的理论衰减曲线，绿色点为数值模拟真值，红色点为 BDAL 模型对各测试样本的预测结果。由于 POI 所处位置不同，建筑群引起的冲击波反射、绕流与叠加效应等使得比例距离相同的样本可能拥有不同的超压峰值，因此图中会出现散

点横坐标相同而纵坐标不同的情况。可以观察到，BDAL 模型的预测超压（红色点）分布与数值模拟结果（绿色点）高度吻合，且随着比例距离 d 增大，呈现明显的单调衰减趋势，整体趋势与经典 Henrych 公式（蓝色实线）所描述的自由场衰减趋势保持一致。结果表明，BDAL 模型在训练过程中自主学习到了爆炸冲击波强度随比例距离的衰减规律，具备良好的物理一致性与相似律保持能力。

$$\Delta p_0 = \begin{cases} \frac{1.40717}{d} + \frac{0.55397}{d^2} + \frac{0.03572}{d^3} + \frac{0.000625}{d^4}, & 0.05 \leq d \leq 0.35 \\ \frac{0.61938}{d} + \frac{0.03262}{d^2} + \frac{0.21329}{d^3}, & 0.35 \leq d \leq 1.0 \\ \frac{0.0662}{d} + \frac{0.405}{d^2} + \frac{0.3288}{d^3}, & 1.0 \leq d \leq 10.0 \end{cases} \quad \#(17)$$


式中： d 为比例距离， Δp_0 为超压峰值。

上述验证结果表明，BDAL 模型能够准确反映超压峰值随起爆距离增大而衰减、随爆源当量增大而增强的基本规律，其预测结果与经典比例距离经验公式的衰减趋势保持一致。这证明模型在训练过程中有效学习并内化了爆炸冲击波传播的核心物理机制，预测结果具备可靠性与物理可解释性。


4.5 数据效率与对比实验

4.5.1 主动学习策略有效性分析

为探究基于不确定性筛选策略的主动学习算法对计算资源的优化效果，本节针对基于 MC-Dropout 的 BDAL 框架进行数据需求分析。以全量数据训练的被动 BDL 模型（即不使用主动学习）在测试集上的预测精度作为基准线，比较不同训练数据量下主动采样与随机采样的性能差异；同时将基于 MC-Dropout 的 BDAL 模型与基于 VI 的 BDAL 模型进行横向对比，以验证所提 MC-Dropout 近似推断方法相较于传统 VI 方法的优越性。需要强调的是，本文所提出的 BDAL 框架具备与 blastFoam 仿真平台实时交互的能力，即在实际工程应用中无需预先计算全量数据集。本文之所以预先计算全部 648 组工况，是为了在受控条件下系统评估主动学习策略的样本效率与收敛行为，避免因仿真顺序、随机性等因素对结论产生干扰。实际部署时，可依托所开发的自动化脚本实现“采样-仿真-训练”的闭环在线主动学习，无需完成全部工况仿真。



(a) Take MAPE as the evaluation index



(b) Take R^2 as the evaluation index

图 11 主动学习性能评估

Fig.11 Active learning performance evaluation

图 11 展示了不同采样策略与推断方法下模型预测精度随训练样本规模变化的演进规律，其中横坐标为实际使用的训练样本占全部训练数据的比例，纵坐标为模型在测试集上的性能指标；图 11(a)和(b)分别以 MAPE 和 R^2 作为评估指标。图中，红色点划线表示被动 BDL 模型在全量数据下的预测精度（即基准线），蓝色实线与绿色实线分别代表采用主动学习的 MC-Dropout 模型和 VI 模型的精度演变轨迹，黄色虚线代表采用随机采样的 MC-Dropout 模型的精度演变轨迹。

从图 11 中可以得出以下结论：

(1) 基于 MC-Dropout 的 BDAL 模型性能显著优于基于 VI 的 BDAL 模型。随着训练样本量的增加，两类主动学习模型的预测误差均呈现递减趋势并逐渐收敛至稳定状态。在训练数据量较少时，VI 模型（绿色曲线）的精度较低且出现阶段性跳跃，这是因为变分推断在小样本条件下难以获得稳定的后验近似；而 MC-Dropout 模型（蓝色曲线）在小样本时即可具备较好的预测能力。当使用全部训练数据时，MC-Dropout 模型的 MAPE 和 R^2 均明显优于 VI 模型，充分验证了所提方法在爆炸载荷预测任务中的技术优势。

(2) 主动采样策略优于随机采样策略。随着训练样本增加，采用主动采样的 MC-Dropout 模型（蓝色曲线）的预测误差快速下降，而采用随机采样的 MC-Dropout 模型（黄色虚线）预测误差下降相对较为缓慢。具体而言，主动采样模型仅需约 50% 的训练数据即可达到被动 BDL 全量模型的精度水平，而随机采样模型需要超过 70% 的训练数据才可以达到相当的精度。这直接证明了基于预测方差的高价值样本筛选策略的有效性，性能提升来源于主动学习本身，而非模型结构的差异。

综合图 11 可知，基于 MC-Dropout 的 BDAL 模型在 MAPE 指标上仅需约 50% 的训练样本即可达到被动 BDL 全量模型的精度，在 R^2 指标上仅需约 40% 的数据量即可实现等效预测性能，样本效率提升率达到 50% 以上。上述结果有力地证明了本文提出的主动学习框架能够有效降低深度学习模型对大规模训练数据的依赖，在保证爆炸载荷预测精度的前提下提高样本效率、减少模型构建成本。

4.5.2 与其他方法的对比

为验证所提 BDAL 方法的性能优势，本文将其与城市爆炸载荷快速预测领域两类代表性方法进行对比——经典的 FCNN^[9-11]和先进的 3D-DeBNN^[20]。其中经实验确定的性能最优的 FCNN 基本架构为包含 3 个隐藏层（每层包含 300 个神经元）的全连接神经网络；3D-DeBNN 为包含 3 个隐藏层的贝叶斯神经网络（每层包含 600 个神经元，Dropout 率为 15%），所有模型在相同的输入输出设置下进行训练与测试。

三种模型在完整训练集及 50%随机子集上训练，并在同一测试集上评估，性能对比如表 5 所示。分析可知：

(1) 在完整训练数据下，BDAL 的预测精度最高（MAPE=13.1%），优于 FCNN

（MAPE=16.0%）与 3D-DeBNN（MAPE=13.7%），说明其在三维建筑群爆炸载荷预测中具有更优的拟合能力。

(2) 在训练数据减半时，FCNN 与 3D-DeBNN 的预测误差显著上升（MAPE 分别增至 52.9%与 22.6%），而 BDAL 的误差仍接近全量训练时的水平（MAPE=17.2%）。这表明 BDAL 通过主动学习策略，能有效选取信息量丰富的样本，大幅降低模型对训练数据规模的依赖，具备突出的样本效率优势。

(3) 在不确定性量化方面，FCNN 仅提供点预测，无法评估置信度；3D-DeBNN 虽可输出不确定性，但在数据减半时其区间覆盖率由 85.4%降至 62.0%，区间宽度由 2.5%增至 7.8%，表明其不确定性估计对数据量较为敏感。相比之下，BDAL 在数据受限时仍保持较稳定的不确定性量化性能（PICP=72.2%，NMPIW=6.0%），说明其在少量数据下也能提供较为可靠的预测置信度信息。

表 5 不同方法的性能对比

Table 5 Performance comparison of different methods

方法	50%训练样本				100%训练样本			
	MAPE	R ²	PICP	NMPIW	MAPE	R ²	PICP	NMPIW
BDAL	0.172	0.945	0.722	0.060	0.131	0.972	0.859	0.026
FCNN	0.529	0.388	-	-	0.160	0.967	-	-
3D-DeBNN	0.226	0.875	0.620	0.078	0.137	0.971	0.854	0.025

综上，BDAL 通过不确定性驱动的主动学习机制，在训练样本有限时仍能高效学习关键数据分布，在保证预测精度的同时显著提升数据利用效率。这一特点使其尤其适用于数据获取成本高、场景复杂的城市爆炸载荷快速预测任务，兼具预测可靠性与经济性。

5 总结与讨论

5.1 主要工作与结论

针对典型规则化三维城市爆炸载荷快速预测面临的模型构建成本高、样本效率低的问题，本文提出了一种基于贝叶斯深度主动学习的高效建模方法。主要工作和结论如下：

(1) 构建面向三维城市冲击波传播的多维参数数据库。设计了涵盖多维度能量源参数和环境参数的 648 组典型工况，基于开源软件 blastFoam 开展三维建筑群爆炸载荷模拟。通过实施网格灵敏度分析与自适应网格细化技术，在保证计算精度的前提下缩短单工况的计算时间，最终建立包含 7776 组超压峰值数据的多维特征数据库。

(2) 引入贝叶斯深度学习实现不确定性量化。将贝叶斯原理与深度学习相结合，在快速给出城市载荷预测的同时输出预测不确定性，以提升方法的工程可信性，并为主动样本选择与风险评估提

供依据。所提方法预测城市超压峰值的平均绝对百分比误差为 13.1%，预测区间覆盖真实值的概率达 85.9%，单点预测响应时间小于 20ms，一定程度上能够满足可靠性和实时性需求。

(3) 提出 BDAL 训练策略以提升样本效率。利用基于不确定性的主动学习准则评估样本的边际价值，主动选择高价值数据用于训练，使模型在减少 50% 训练样本的条件下达到与被动深度学习相当的预测精度，为典型城市场景下的爆炸载荷快速预测提供兼具可靠性与经济性的解决方案。

5.2 局限性与展望

本研究通过将贝叶斯原理与主动学习引入城市爆炸载荷预测，在提升预测效率与降低数据依赖方面取得了进展，但仍存在一定局限性，未来可在以下方向继续深化：

(1) 提升模型对复杂真实场景的适应能力。当前模型基于规整建筑群构建，难以充分反映真实城市中建筑形态异构、街道布局不规则及地形多变等特点。后续可构建真实城市场景模型，并引入几何编码、物理信息嵌入及迁移学习等方法，增强模型在非结构化环境中的泛化性能，推动从典型场景到实际应用的过渡。

(2) 从离散点预测向连续场预测拓展。目前研究主要针对关键点位的超压峰值进行预测，尚不能反映冲击波在三维空间中的连续分布。未来可结合图神经网络、三维卷积网络等架构，实现对建筑表面或空间网格节点的载荷分布建模，从而更好地支持整体毁伤评估与工程设计。

(3) 推进主动学习在爆炸领域的系统化应用。当前工作初步验证了主动学习在降低数据标注成本方面的潜力，但其样本选择策略仍依赖预测不确定性，未充分考虑样本多样性与代表性。未来可探索融合多样性搜索、聚类预选或物理约束的主动学习策略，进一步提升样本筛选的智能性与效率，推动其在爆炸仿真、风险评估等场景中的系统化部署。

参考文献

- [1] SMITH P D, ROSE T A. Blast wave propagation in city streets—an overview[J]. *Progress in Structural Engineering and Materials*, 2006, 8(1): 16-28.
- [2] RATCLIFF A, RIGBY S, CLARKE S, et al. A review of blast loading in the urban environment[J]. *Applied Sciences*, 2023, 13(9): 5349.
- [3] 张大明, 张昆, 汤文辉, 等. 剪力墙建筑物在强爆炸作用下的动响应研究[J]. *现代应用物理*, 2022, 13(4): 196-204.
ZHANG D M, ZHANG K, TANG W H, et al. Dynamic response of shear wall buildings under strong blast loading[J]. *Modern Applied Physics*, 2022, 13(4): 196-204.
- [4] 柏准, 胡玉涛, 钱秉文, 等. 爆炸作用下浅埋直墙拱结构的毁伤评估方法与毁伤判据选择[J]. *现代应用物理*, 2024, 15(3): 141-149.
BAI Z, HU Y T, QIAN B W, et al. Damage assessment methods and damage criterion selection for shallow buried straight-wall arch structures under blast loading[J]. *Modern Applied Physics*, 2024, 15(3): 141-149.
- [5] 王澍霏, 钟巍, 王智环, 等. 爆炸荷载作用下单层钢化玻璃破坏状态的理论预测方法[J]. *现代应用物理*, 2020, 11(3): 87-93.
WANG S F, ZHONG W, WANG Z H, et al. Theoretical prediction method for the failure state of single-layer tempered glass under blast loading[J]. *Modern Applied Physics*, 2020, 11(3): 87-93.
- [6] REMENNIKOV A M. A review of methods for predicting bomb blast effects on buildings[J]. *Journal of Battlefield Technology*, 2003, 6(3): 5-10.
- [7] REMENNIKOV A M, ROSE T A. Modelling blast loads on buildings in complex city geometries[J]. *Computers & Structures*, 2005, 83(27): 2197-2205.

- [8] SHI Y C, LIU S Z, LI Z X, et al. Review on quick safety assessment of building structures in complex urban environment after extreme explosion events[J]. *International Journal of Protective Structures*, 2023, 14(3): 438-458.
- [9] REMENNIKOV A M, MENDIS P A. Prediction of airblast loads in complex environments using artificial neural networks[M]. Southampton, UK: WIT Press, 2006.
- [10] 黄沛吉, 彭卫文, 冷春江, 等. 基于神经网络的密集城市建筑群爆炸载荷快速预测[J]. *兵工学报*, 2025, 46(8): 278-288.
HUANG P J, PENG W W, LENG C J, et al. Rapid prediction of blast loading in dense urban building clusters based on neural networks[J]. *Acta Armamentarii*, 2025, 46(8): 278-288.
- [11] SI D D, PAN Z F, ZHANG H P. Distribution characteristics and prediction of blast load on building surfaces in urban blocks[J]. *Structures*, 2025, 78: 109396. DOI: 10.1016/j.istruc.2025.109396.
- [12] DENNIS A A, RIGBY S E. Prediction of blast loads using machine learning approaches[C]//*Earthquake Engineering and Dynamics for a Sustainable Future*. Society for Earthquake and Civil Engineering Dynamics (SECED), 2023.
- [13] DENNIS A A, RIGBY S E. The direction-encoded neural network: A machine learning approach to rapidly predict blast loading in obstructed environments[J]. *International Journal of Protective Structures*, 2024, 15(3): 455-483.
- [14] WANG Z Q, WANG M Y, PENG J Z, 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. DOI: 10.1016/j.eng.2025.03.007.
- [15] DENNIS A A, SMYD D J, STIRLING C G, et al. A branching algorithm to reduce computational time of batch models: Application for blast analyses[J]. *International Journal of Protective Structures*, 2023, 14(2): 135-167.
- [16] DENNIS A A, STIRLING C, RIGBY S E. Towards the development of machine learning tools for blast load prediction[C]//*Proceedings of the 6th International Conference on Protective Structures (ICPS6)*. International Association of Protective Structures, 2023.
- [17] PANNELL J J, RIGBY S E, PANOUTSOS G. Application of transfer learning for the prediction of blast impulse[J]. *International Journal of Protective Structures*, 2023, 14(2): 242-262.
- [18] HUANG Y, ZHU S J, CHEN S W. Deep learning-driven super-resolution reconstruction of two-dimensional explosion pressure fields[J]. *Journal of Building Engineering*, 2023, 78: 107620.
- [19] KANG M A, PARK C H. Prediction of peak pressure by blast wave propagation between buildings using a conditional 3D convolutional neural network[J]. *IEEE Access*, 2023, 11: 26114-26124.
- [20] PENG W W, HUANG P J, LENG C J, et al. Blast loading prediction in a typical urban environment based on 3D direction-encoded Bayesian neural network[J]. *Reliability Engineering & System Safety*, 2025, 264: 111415. DOI: 10.1016/j.res.2025.111415.
- [21] 黄阳, 罗定坤, 陈素文. 基于物理信息及数据融合驱动的复杂街区爆炸荷载快速计算方法[J/OL]. *爆炸与冲击*. DOI: 10.11883/bzycj-2025-0238.
HUANG Y, LUO D K, CHEN S W. A physics-information and data fusion-driven method for rapid prediction of blast loads in complex urban environments[J/OL]. *Explosion and Shock Waves*. DOI: 10.11883/bzycj-2025-0238.
- [22] 刘竟飞, 姜潮, 倪冰雨, 等. 基于主动学习与贝叶斯深度神经网络的高维多输出不确定性传播方法[J]. *中国机械工程*, 2024, 35(5): 792-801.
LIU J F, JIANG C, NI B Y, et al. High-dimensional multi-output uncertainty propagation method based on active learning and Bayesian deep neural network[J]. *China Mechanical Engineering*, 2024, 35(5): 792-801.
- [23] LIU S Y, CHEN K, HU T L, et al. Uncertainty-aware label query completion based on active learning[J]. *Frontiers of Information Technology & Electronic Engineering*, 2023, 24(10): 1497-1504.
- [24] 陈博, 仵可, 张云峰, 等. 基于模型验证与确认方法的空爆自由场网格敏感性分析[J]. *现代应用物理*, 2024, 15(3): 150-159.

- CHEN B, WU K, ZHANG Y F, et al. Mesh sensitivity analysis of free-field airburst based on model verification and validation methods[J]. Modern Applied Physics, 2024, 15(3): 150-159.
- [25] PSAROS A F, MENG X, ZOU Z, et al. Uncertainty quantification in scientific machine learning: Methods, metrics, and comparisons[J]. Journal of Computational Physics, 2023, 477: 111902.
- [26] FILICE A, MYNARZ M, ZINNO R. Experimental and empirical study for prediction of blast loads [J/OL]. Applied Sciences, 2022, 12(5): 2691-2709[2022-02-28]. <https://doi.org/10.3390/app12052691>. DOI: 10.3390/app12052691.

(责任编辑 爆炸与冲击)

录用稿件，
非最终出版稿