

基于机器学习的船体舭部板架水下爆炸响应 评估与预测*

黄佑魏^{1,2}, 徐双喜^{1,2}, 吴轶钢^{2,3*}

- (1. 船舶冲击与防护湖北省重点学科实验室, 武汉理工大学, 湖北武汉 430063;
2. 船海与能源动力工程学院, 武汉理工大学, 湖北武汉 430063;
3. 绿色智能江海直达船舶与邮轮游艇研究中心, 武汉理工大学, 湖北武汉 430063)

摘要: 船体舭部板架结构是舰船抗水下爆炸的典型薄弱环节, 其动态响应与损伤的快速评估对舰船生存能力设计至关重要。为克服传统有限元方法计算成本高昂的瓶颈, 基于耦合欧拉-拉格朗日算法提出了一个融合参数化建模与机器学习的评估预测框架。首先, 建立了基于耦合欧拉-拉格朗日方法的流固耦合数值模型, 板架四边固支, 流场外围设置无反射边界, 并通过试验数据验证了其可靠性; 继而, 针对舭部板架开展参数化建模, 系统考虑了曲率半径、加筋间距与板厚等六类关键变量, 构建了 2304 组工况数据集。基于此, 开发了一种两阶段机器学习预测模型: 先采用随机森林算法对变形和破口两种损伤模式进行了分类, 再利用条件生成对抗网络建立了从设计参数到全场应力、应变及变形云图的端到端映射关系。该方法需对底层数值仿真求解方法进行基础性验证, 并在验证后的建模规则框架内, 对参数空间内的工况进行计算, 再利用所构建框架进行推广预测。研究结果表明, 该集成框架在保持高预测精度的前提下, 计算效率得到了数量级提升, 从而为船体结构水下爆炸损伤的快速评估与耐爆性能优化提供了一条高效、可靠的新途径。

关键字: 舭部板架; 参数化建模; 流固耦合; 随机森林; 条件生成对抗网络

中图分类号: U661.43; O383.1 国标学科代码: 580.30 文献标识码: A

Assessment and Prediction of Underwater Explosion Response for Ship Bilge Grillage Based on Machine Learning

HUANG Youwei^{1,2}, XU Shuangxi^{1,2}, WU Yigang^{2,3*}

(1. Ship Impact and Protection of Hubei Province Key Discipline Laboratory, Wuhan University of Technology, Wuhan 430063, China; 2. School of Naval Architecture, Ocean and Energy Power Engineering, Wuhan University of Technology, Wuhan 430063, China; 3. Green and Smart River-Sea-Going Ship Cruise and Yacht Research Center, Wuhan University of Technology, Wuhan 430063, China)

Abstract: The bilge grillage of ship hulls is a typical vulnerable component under underwater explosion loads, and rapid assessment of its dynamic response and damage is critical for ship survivability design. Traditional finite element methods suffer from prohibitive computational cost, which severely limits their application in large-scale parametric analysis and real-time

* 收稿日期: 2026-01-21 ; 修回日期: 2026-05-28 ;

基金项目: 国家自然科学基金 (52471338)

第一作者: 黄佑魏 (1997-), 男, 硕士, E-mail: hyw_0461@whut.edu.cn;

通讯作者: 吴轶钢 (1976-), 男, 博士, 助理研究员, E-mail: ewyg@whut.edu.cn。

evaluation scenarios. A coupled Eulerian-Lagrangian (CEL) fluid-structure interaction numerical method was established with four-edge clamped boundary conditions for the grillage and non-reflecting boundaries for the fluid domain, and its accuracy and reliability were validated against classical underwater explosion test data. Then, parametric modeling was performed for the bilge grillage, which systematically incorporated six key design variables: curvature radius, stiffener spacing, plate thickness, stiffener height, standoff distance and material yield strength, and a dataset of 2304 high-fidelity simulation cases was constructed. On this basis, a two-stage machine learning prediction framework was developed. In the first stage, a Random Forest (RF) classifier was employed to distinguish between two damage modes: plastic deformation and rupture. In the second stage, Conditional Generative Adversarial Network (CGAN) models were trained to establish end-to-end mappings from design parameters to full-field stress, strain and deformation contour maps. This approach requires fundamental validation of the underlying numerical simulation solver first, followed by execution of simulations for all cases within the parameter space under the validated modeling protocol, and finally generalized prediction using the constructed framework. The results show that the integrated framework maintains high prediction accuracy while delivering an order-of-magnitude improvement in computational efficiency, achieving a speedup of over 200 times compared with conventional finite element analysis. The RF classifier achieves an overall accuracy of 99% on the test set, and the CGAN models accurately capture stress concentration regions, crack propagation paths and global deformation patterns. This integrated framework provides an efficient and reliable new pathway for rapid assessment of underwater explosion damage and optimization of anti-explosion performance of ship hull structures.

Keywords: Bilge grillage; Parametric modeling; Fluid-structure interaction; Random forest; Conditional generative adversarial network

1 引言

船舶在服役过程中面临着非接触水下爆炸等极端载荷的严重威胁。爆炸产生的冲击波和气泡脉动会对船体结构造成严重的整体与局部损伤,甚至导致其丧失生命力。其中,船体舭部作为连接船底与舷侧的过渡区域,曲率大、曲面结构形式复杂,且处于水线以下,在水下爆炸载荷作用下易产生应力集中,是抗爆防护的关键部位之一。因此,开展船体舭部板架在水下爆炸载荷下的动态响应、损伤模式及快速预报方法研究,具有重要的理论意义与工程价值。

长期以来,研究者们通过试验与数值模拟等手段对爆炸载荷及结构在水下爆炸载荷下的动态响应进行了广泛研究^{[1][2]}。在试验方面,Ramajeyathilagam等^[3]开展了普通商用钢在水下爆炸载荷下的动态响应试验,为数值方法的验证提供了宝贵数据。在数值模拟方面,能够有效处理大变形和流体-结构相互作用的耦合欧拉-拉格朗日算法(Coupled Eulerian-Lagrangian, CEL)^[4]和声-固耦合方法^[5]已成为水下爆炸仿真分析的主流技术。同时,准确描述材料在高应变率下力学行为的本构模型,如约翰逊-库克本构模型(Johnson-Cook, J-C)模型^[6],以及炸药状态方程琼斯-威尔金斯-李状态方程(Jones-Wilkins-Lee equation of state, JWL)和水的状态方程冲击波速度-粒子速度状态方程(Shock velocity-Particle velocity equation of state, Us-Up)是获得可靠仿真结果的关键^[7]。尽管高保真度的有限元法(Finite Element Method, FEM)能够精确模拟结构的动态响应过程,但其建模过程复杂、计算耗时巨大,难以应用于需要大量工况分析的方案优选和快速评估场景。参数化建模技术通过将模型的关键尺寸、材料属性等定义为变量,并结合脚本驱动自动化分析,为高效生成大规模数据集提供了可能。然而,仅靠参数化仿真仍无法满足实时或近实时预测的需求。近年来,机器学习(Machine Learning, ML)的迅速发展为解决复杂的“多变量”、“非线性”工程问题提供了新的范式^[8]。在结构力学领域,随机森林(Random Forest, RF)^[9]等算法已被成功用于预测结构的力学响应。更进一步,生成对抗网络(Generative Adversarial Network, GAN)^[10]及其变体,如条件生成对抗网络(Conditional Generative Adversarial Network, CGAN)^[11],展现了从参数直接生成物理场云图的强大能力,为结构响应的可视化预测开辟了新途径。

在冲击动力学领域,已有学者尝试将 ML 用于结构抗爆响应的快速预测。He 等^[12]基于深度神经网络 (Deep Neural Network, DNN) 对近场水下爆炸下船体结构的变形进行了快速预测,揭示了变形量随爆距变化的多峰值现象。Liam G. Gannon 等^[13]利用循环神经网络 (Recurrent Neural Network, RNN) 预测浮体结构的水下冲击速度时程,通过 CEL 数值模型生成训练数据。Liang 等^[14]将科尔莫戈罗夫-阿诺德网络 (Kolmogorov-Arnold Network, KAN) 引入用于预测水下爆炸冲击谱,其输入考虑了舱室结构形式参数、冲击因子等变量。Bardiani, J.等^[15]发表的一篇系统综述全面回顾了过去二十年来人工智能 (Artificial Intelligence, AI) 和 ML 在水下爆炸预测领域的进展,指出当前研究多聚焦于节点响应值预测,对全场物理场分布的直接生成关注不足。在结构力学领域,GAN 及其变体为物理场的可视化预测开辟了新途径^[10,11]。Jiang 等^[16]提出 StressGAN,以 CGAN 预测二维实体结构中的 von Mises 应力分布,输入条件涵盖几何形状、载荷和边界条件,突破了传统深度学习模型对固定几何的依赖。Liu 等^[17]提出 SR-M-GAN,从粗网格计算中重建复合材料螺栓接头的高保真应力场,有效缓解了保真度与计算效率之间的内在矛盾。在船舶工程领域,Chen 等^[18]基于条件深度卷积生成对抗网络 (Conditional Deep Convolutional Generative Adversarial Network, CDCGAN) 开展船体曲面特征识别与生成的研究。综上,本研究的核心解决思路与创新逻辑如下:针对“无法输出全场分布信息”的缺陷,摒弃传统“节点标量预测”的范式,以全场应力、应变、变形云图为直接输出目标,实现结构响应的全景式可视化预测,完整覆盖应力集中、损伤扩展、变形分布等工程核心关注信息;针对“节点依赖、泛化能力差”的瓶颈,通过“物理参数-标准化图像”的端到端映射,将结构响应预测从离散节点空间转换至统一的图像像素空间,避免了预测模型对固定节点编号与局部网格拓扑的直接依赖,模型学习的是物理参数变化与结构响应场之间的数据驱动映射关系,而非特定节点的数值关联,提升了模型在训练参数域内对未见参数组合的预测能力;针对“艤部曲面结构相关集成化研究不足”的局限性,构建“参数化建模、高保真 CEL 仿真、RF 损伤分类、CGAN 全场云图生成”的两阶段集成框架,形成了从设计参数到抗爆响应预测的快速评估流程,拓展了船体艤部曲面结构水下爆炸响应全场快速预测的研究范畴。

针对上述现有研究存在的局限与不足,本文构建了一个集参数化建模、高保真仿真与机器学习于一体的综合框架,用于船体艤部板架水下爆炸响应的快速评估。该框架将复杂的响应问题转化为“多变量输入-全场图像输出”的黑箱映射问题:首先,建立并验证了基于 CEL 方法的流固耦合模型;继而,通过参数化建模系统考虑六类关键变量,生成 2304 组工况数据集;在此基础上,构建两阶段预测模型:RF 用于损伤模式分类,CGAN 用于从设计参数到应力、应变及变形云图的端到端映射,从而有效摆脱对特定节点配置的依赖。与传统有限元法及现有主流预测模型相比,本框架在保持单次预测 10~15 秒高效性的同时,实现了节点无关的全场云图预测,精度与信息丰富度均得到明显提升。

2 有限元计算方法及其验证

2.1 模型参量

选用 Ramajeyathilagam 等^[3]进行的一项试验来研究水下爆炸下试板的响应来验证 CEL 算法,该试验是水下爆炸结构响应领域最经典的基准试验之一。其试样的基本尺寸如下:试板整体尺寸为 $0.55 \times 0.45 \times 0.002 \text{ m}^3$,试板的暴露面积为 $0.30 \times 0.25 \text{ m}^2$,使用的炸药类型为 PEK I (其当量等效于 $1.17 \times \text{TNT}$),炸药通过连接至箱模型装置的通道段固定在一定的距离上。在所有实验中,炸药均置于穿过板材中心点的法线上。实验装置包括试验板炸药被浸没在冲击水箱中,水深为 2.0 米,水箱底部和侧壁与炸药之间的距离分别为 8.0m 和 6.0m。因此,可以认为自由表面、底部和侧壁的反射对板早期响应的影响可以忽略不计。实验中使用的炸药重量范围从 0.01kg 到 0.08kg。具体的测试装置和测试对象如图 1 所示,测试条件见表 1。

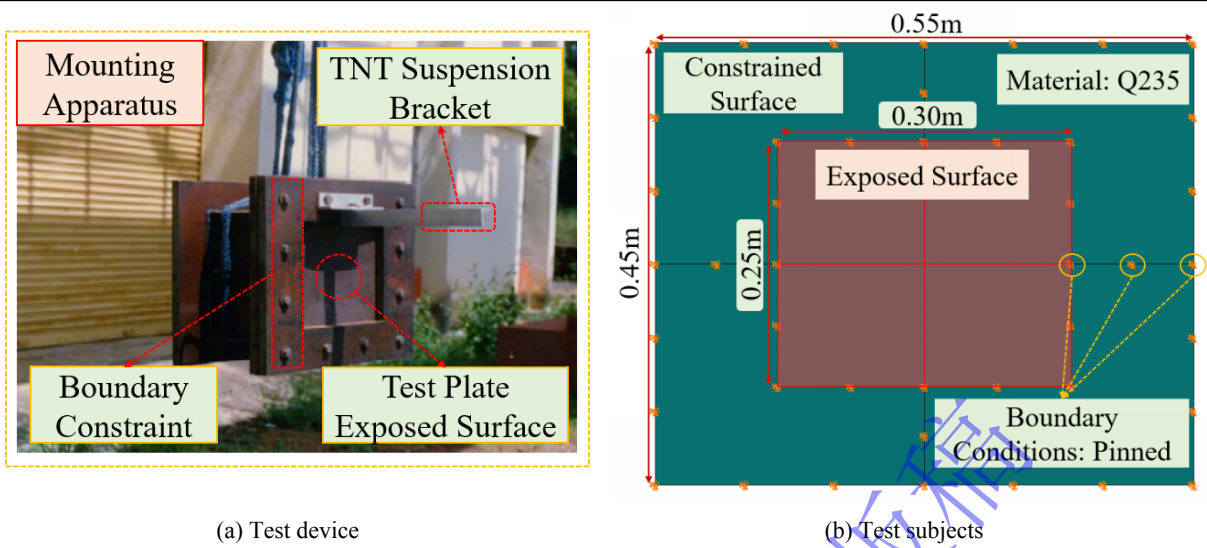


图 1 参考文献[3]所述试验安装设备及试板示意图

Fig.1 Schematic diagram of the test installation equipment and test plate described in reference [3]

表 1 平板的主要试验工况

Table 1 The main test conditions of the flat plate

工况	炸药当量 (W)/(PEK I, g)	炸药当量 (W)/(TNT, g)	爆距 (a)/(m)	冲击因子 (I) / ($0.45 \times W^{0.5} / R$)
工况 1	10	11.7	0.15	0.300
工况 2	20	23.4	0.15	0.424
工况 3	30	35.1	0.15	0.520
工况 4	40	46.8	0.15	0.600
工况 5	50	58.5	0.15	0.671
工况 6	60	70.2	0.15	0.736
工况 7	70	81.9	0.15	0.794
工况 8	80	93.6	0.15	0.849

2.2 耦合欧拉-拉格朗日方法及状态方程

本研究采用 ABAQUS 中的耦合欧拉-拉格朗日方法 (CEL) 模拟水下爆炸条件下不同材料之间的动态相互作用, CEL 方法结合了拉格朗日和欧拉公式, 使其适用于处理大变形、材料流动和空化等场景。对于固体材料, 拉格朗日公式跟踪材料的变形和失效, 而对于周围流体 (例如水), 欧拉方法跟踪固定网格上的压力和密度变化。ABAQUS 中的流固耦合 (FSI) 算法耦合了固体区和流体区, 从而能够准确模拟冲击波相互作用及结构损伤。

水采用 Mie-Grüneisen 形式的冲击波速度-粒子速度状态方程 (Shock velocity-Particle velocity equation of state, U_s-U_p), 该方程由两部分组成, 式(1)为冲击波速度与粒子速度的线性关系, 式(2)为压力-内能关系, 具体如下:

$$U_s = c_0 + S_1 U_p + S_2 U_p^2 + S_3 U_p^3 \quad (1)$$

$$p = \frac{\rho_0 c_0^2 \mu (1 + (1 - \gamma_0) \mu - \frac{\alpha}{2} \mu^2)}{(1 - (S_1 - 1) \mu - S_2 \mu^2 - S_3 \mu^3)^2} + (\gamma_0 + \alpha \mu) e_m \quad (2)$$

式中, U_s 为冲击波速度 (m/s), U_p 为粒子速度 (m/s), c_0 为常压下水中的声速 (m/s), S_1 、 S_2 、 S_3

为冲击波速度拟合系数， ρ_0 为水的初始密度 (kg/m^3)， ρ 为水的瞬时密度 (kg/m^3)， μ 为体积压缩比， $\mu = \frac{\rho}{\rho_0} - 1$ ， γ_0 为 Grüneisen 系数， α 为 Grüneisen 系数的体积修正系数， e_m 为单位质量内能 (J/kg)， p 为流体压力 (Pa) 各参数具体取值如下表 2 所示^[19]：

表 2 水域的 Us-Up 状态参数

Table 2 Us-Up status parameters for waters

ρ_0 (kg/m^3)	c_0 (m/s)	S_1	S_2	S_3	γ_0	α	e_m
1025	1480	1.921	-0.096	0	0.35	0	0.2895

TNT 炸药的 JWL 状态方程由下式给出：

$$P = A \left(1 - \frac{\omega\rho}{R_1\rho_0} \right) e^{-R_1 \frac{\rho_0}{\rho}} + B \left(1 - \frac{\omega\rho}{R_2\rho_0} \right) e^{-R_2 \frac{\rho_0}{\rho}} + \omega\rho E_m \quad (3)$$

式中， P 代表爆轰产物 A 、 B 的压力， R_1 、 R_2 、 w 是常数， ρ_0 表示炸药的密度， ρ 是爆炸产物的密度，并且 E_m 是单位质量的内能。TNT 的 JWL 状态方程参数如下表 3 所示^[19]：

表 3 TNT 的 JWL 状态方程参数

Table 3 JWL equation of state parameters for TNT

ρ (kg/m^3)	D (m/s)	P_C / GPa	A / GPa	B / GPa	R_1	R_2	w	E_m / (J/kg)
1630	6930	21	371.2	3.231	4.15	0.95	0.35	7×10^9

本研究采用基于 Von Mises 塑性改进的 Johnson-Cook 材料模型来表征目标板在高应变率下的力学行为。Johnson-Cook 模型通过其硬化定律和应变率依赖性的分析表达式描述材料特性。该模型在 ABAQUS/Explicit 中仅适用于显式动态分析，并包含一个专门的延性损伤失效准则^[20]。钢的临界失效应变 ε_f ，定义为下式：

$$\varepsilon_f = \left[D_1 + D_2 \exp(D_3 \sigma_p^*) \right] \left(1 + D_4 \ln \varepsilon_p^* \right) \left(1 + D_5 T_H \right) \quad (4)$$

式中， D_1 - D_5 是失效参数， σ_p^* 是无量纲的压力-应力比。ABAQUS 中的 Johnson-Cook 材料模型还可以在分析过程中激活此功能时删除单元。

试验中的试板使用 Q235 钢，其 Johnson-Cook 模型参数如表 4 所示^[21]。

表 4 Q235 钢 J-C 本构参数

Table 4 Constitutive parameters of Q235 steel J-C

A (MPa)	B (MPa)	C	n	m	D_1	D_2	D_3	D_4	D_5
590	451	0.006	0.496	1	0.16	0	0	0	0

2.3 计算方法验证与结果对比

利用上述已知参量进行有限元建模，其中水域采用 $3\text{m} \times 3\text{m} \times 3\text{m}$ (长×宽×高)，采用实体单元进行建模，试板则采用壳单元进行建模，整体模型如下图 2 所示，试板的网格尺寸设置为 5mm ，其中水域整体采用 50mm 的网格尺寸，在试板与水域接触处采用 5mm 的水域网格。试板的有限元模型如图 1 所示，电荷位于板中心节点的正下方。加筋板的四个边缘设定为固支，并且在流场的边界处设置了非反射边界条件。在计算完成后分析计算结果分别如下表 5、图 3 所示，表中数值结果为最大外凸深度：

表 5 计算结果对比

Table 5 Comparison of calculated results

工况	失效模式	实验结果	仿真计算结果	误差
工况 1	大变形	0.0400m	0.038m	5.0%
工况 2	大变形	0.0578m	0.056m	3.1%
工况 3	大变形	0.0677m	0.064m	5.5%
工况 4	拉伸撕裂	0.0864m	0.087m	0.7%
工况 5	拉伸撕裂	0.1078m	0.112m	3.9%
工况 6	中心区域破坏		破口形式与区域一致	
工况 7	中心区域破坏		破口形式与区域一致	
工况 8	剪切与拉伸撕裂共同破坏		破口形式与区域一致	

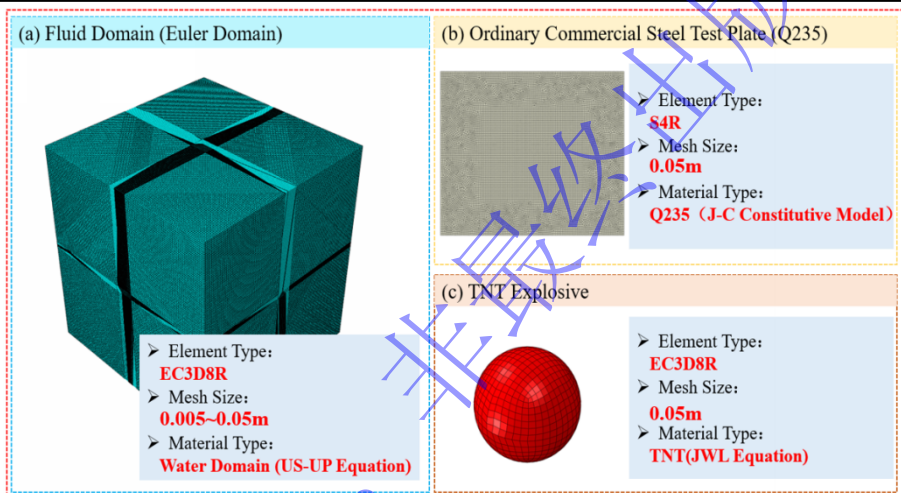


图 2 试板和流场的有限元模型

Fig 2 Finite element model of test plate and flow field

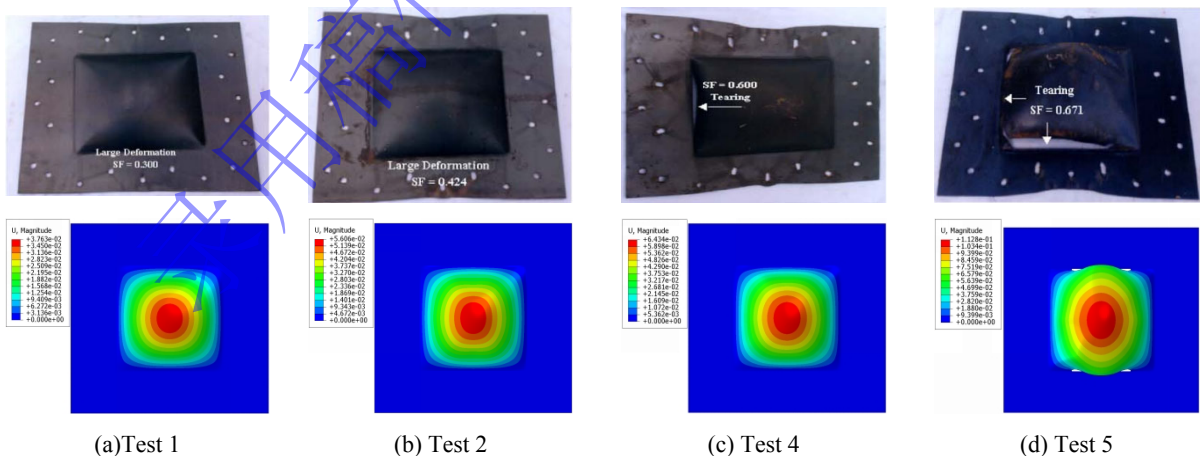


图 3 试验结果与仿真计算结果对比

Fig 3 The test results are compared with the simulation results

由上述验证分析可知，对比计算结果与试验结果，对于塑性变形，二者数值误差最大为 5.5%，对于破口发生的试板，二者破口形式与破坏区域吻合较好，说明了流固耦合计算方法能够有效复现试验的现象及失效形式。本次验证针对 CEL 流固耦合求解方法、材料本构与状态方程的普适可靠性开

展, 验证通过的全套求解规则与网格收敛准则, 可直接应用于后续舭部曲面板架的数值模拟。

3 参数化建模与数据集生成

计算选自某集装箱船的舭部板架, 其具体的结构形式如下图 4 所示。图 4 (a) 为该集装箱船的典型横剖面, 由于球扁钢的参数化建模较为困难, 在此将其转化为角钢, 图 4 (b) 展示了球扁钢与角钢的相关参数转化对应关系。转化的相关计算方程如下:

$$\left\{ \begin{array}{l} h_w = h'_w - \frac{h_w}{9.2} + 2 \\ bf = \alpha(t'_w + \frac{h'_w}{6.7} - 2) \\ tf = \frac{h'_w}{9.2} - 2 \\ t_w = t'_w \end{array} \right\} \rightarrow \left\{ \begin{array}{l} \alpha = 1.1 + \frac{(120 - h'_w)^2}{3000} \quad h'_w \leq 120 \\ \alpha = 1.0 \quad h'_w > 120 \end{array} \right. \quad (5)$$

式中: h'_w , t'_w 分别为球扁钢的高度和净厚度, 单位 mm; α 为系数, 图 4 (c) 则表示船体的舭部板架结构, 其中 d 代表了加筋间距, R 代表曲率半径。




图 4 集装箱船典型舭部板架结构示意图

Fig 4 Schematic diagram of the structure of a typical container ship

对上述舭部板架进行建模, 取板架长边的八倍为正方体水域的边长。整体模型采用三个部件进行创建, 其中水域采用三维欧拉单元进行建模, 板架则采用三维壳单元, TNT 采用三维体单元进行建模。依据第 2.2 节所述的状态方程参数分别定义其属性, 之后装配好三个部件。具体的建模形式如下图所示。图 5 (a) 表示板架与水域的边界条件, 其中板架边界与水域边界均设置为铰接, 且水域表面被设置为无反射边界, 采用第 2.3 节述的网格划分方法对其进行网格划分, 如图 5(b)所示为水域、TNT、板架的几何分布形式, 图 5 (c) (d) (e)分别为板架、水域、TNT 的网格划分形式。

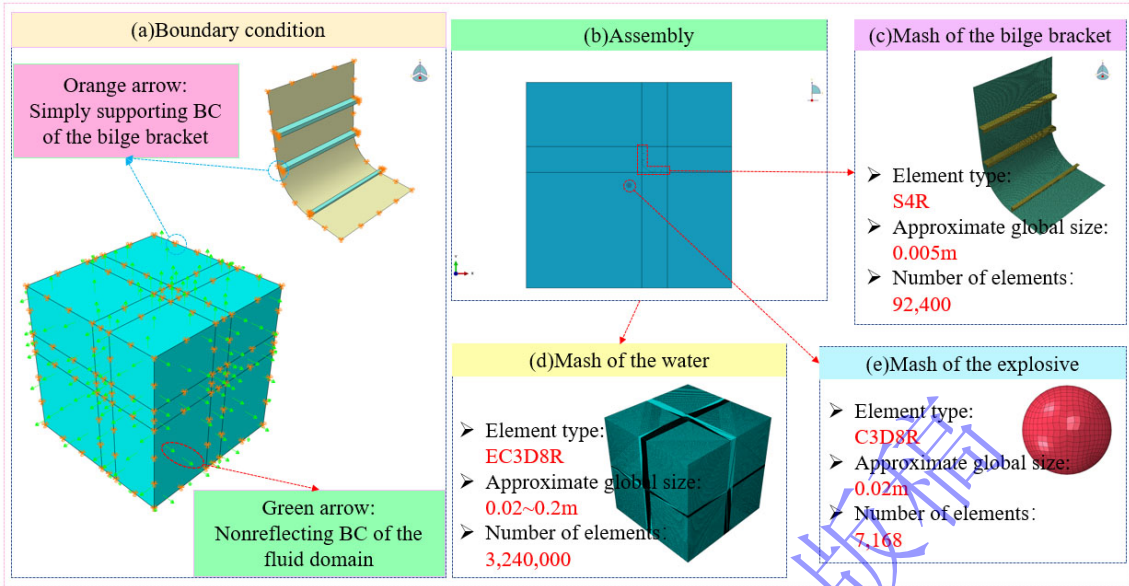


图 5 基准有限元模型

Fig 5 Benchmark finite element model

在基准模型的基础上修改几何变量、材料参数、爆源参数的取值范围如表 6 所示。根据各参数的变化次数组合，共建立 1（当量 2kg）×4（曲率）×2（加筋间距）×4（板厚）×4（加筋类型）×6（爆炸距离）×3（材料屈服强度）=2304 组有限元模型，其中由于舳部板架具备曲率半径这一曲面特性，爆源位置通过控制其空间坐标（ x, y, z ）进行设定，并将炸药中心到板架表面的最近距离定义为爆距 d_s 。上述参数化建模流程如图 6 所示。基于此，构建的参数矩阵如下表 6 所示。2304 组工况的边界条件、环境载荷、求解规则均与第 2 章经试验验证的基准模型一致。为解决传统手动建模效率低、每次修改模型参数均需更新模型的问题，本文基于 Python 语言对 Abaqus 有限元软件进行二次开发，构建了集“参数化建模-批量计算-自动结果”后处理于一体的高效建模方法，可在有限时间内高效、自动生成机器学习预测所需的足量数据集。

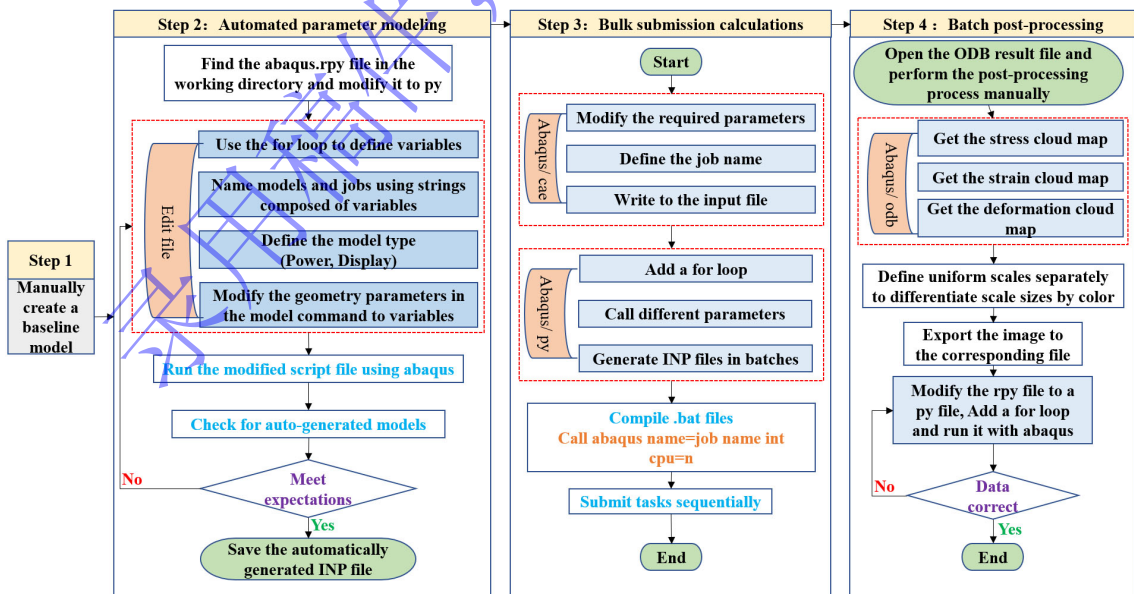


图 6 参数化建模与后处理基本流程

Fig 6 Parametric modeling and post-processing basic processes

表 6 参数化矩阵

Table 6 Parametric matrix

变量	加筋间距	曲率半径	加筋高度	面板厚度	爆距	材料屈服强度
符号	d	R	h	t_p	d_s	f_y
单位	mm	mm	mm	mm	mm	MPa
变换次数	2	4	4	4	6	3
取值	550, 650	2500, 2000, 1500, 1000	140, 160, 180, 200	10, 12, 14, 16	50, 193, 303, 415, 541, 662	235, 315, 355

表 7 展示了典型参数组合下的加筋板几何模型，板架结构在典型参数组合下的变形云图如表 8 所示。从图 8 可以看出，不同曲率下的最大变形位置不同，这种差异源于曲率半径 R 与爆源空间坐标的联合作用，体现了参数组合对响应分布的多变量耦合影响。定义图 7 (a) 所示的节点路径，可得到板中心截面变形随各输入参数的变化关系如图 7 (b~g) 所示。可见，在本文考虑的六个参数中，爆距对结构响应的影响最为显著，这是由于水下爆炸冲击波峰值压力与爆距平方成反比，如图 7(e) 所示，当爆距从 50 mm 增大至 662 mm 时，板架中心最大变形从约 80 mm 急剧下降至 10 mm 以下，降幅接近 88%。相比之下，加筋间距 d 、加筋高度 h 、曲率半径 R 、屈服强度 f_y 和面板厚度 t_p 等几何参数的影响相对较小。以加筋间距为例，如图 7 (a) 所示，加筋间距从 550 mm 增大至 650 mm 时，变形量仅增加约 5%，这是因为加筋主要提供局部弯曲刚度，而在强冲击载荷下板架的整体变形主要受面板膜力控制，加筋对整体刚度的贡献有限。如图 7 (f) 所示，曲率半径通过改变板壳的初始几何刚度影响抗弯能力，但变化梯度较为平缓，表明曲率对刚度的贡献被材料非线性和冲击载荷的局部特性部分削弱。如图 7 (g) 所示，变形量随屈服强度增加而减小，随着屈服强度增加时，弹性极限和塑性耗散能力均有所提高。类似地，面板厚度和加筋高度的敏感性分析结果也表明 (图 7 (c)和(d))，其影响程度显著低于爆距。

表 7 典型参数组合下的几何模型示意图

Table 7 Schematic diagram of the geometric model under typical parameter combinations

参数组合	$R=2500\text{mm}, d=650\text{mm}, h=160\text{mm}, t_p=10\text{mm}, d_s=541\text{mm}, f_y=235\text{MPa}$	$R=2000\text{mm}, d=550\text{mm}, h=160\text{mm}, t_p=10\text{mm}, d_s=541\text{mm}, f_y=235\text{MPa}$	$R=1500\text{mm}, d=650\text{mm}, h=160\text{mm}, t_p=10\text{mm}, d_s=541\text{mm}, f_y=235\text{MPa}$	$R=1000\text{mm}, d=550\text{mm}, h=160\text{mm}, t_p=10\text{mm}, d_s=541\text{mm}, f_y=235\text{MPa}$
几何模型				

表 8 典型参数组合下的变形云图

Table 8 Deformation cloud diagram under typical parameter combinations

参数组合	$R=2500\text{mm}, d=650\text{mm}, h=140\text{mm}, t_p=10\text{mm}, d_s=662\text{mm}, f_y=235\text{MPa}$	$R=2000\text{mm}, d=650\text{mm}, h=140\text{mm}, t_p=10\text{mm}, d_s=303\text{mm}, f_y=355\text{MPa}$	$R=1500\text{mm}, d=550\text{mm}, h=160\text{mm}, t_p=10\text{mm}, d_s=303\text{mm}, f_y=315\text{MPa}$	$R=1000\text{mm}, d=550\text{mm}, h=160\text{mm}, t_p=10\text{mm}, d_s=193\text{mm}, f_y=315\text{MPa}$
变形云图				

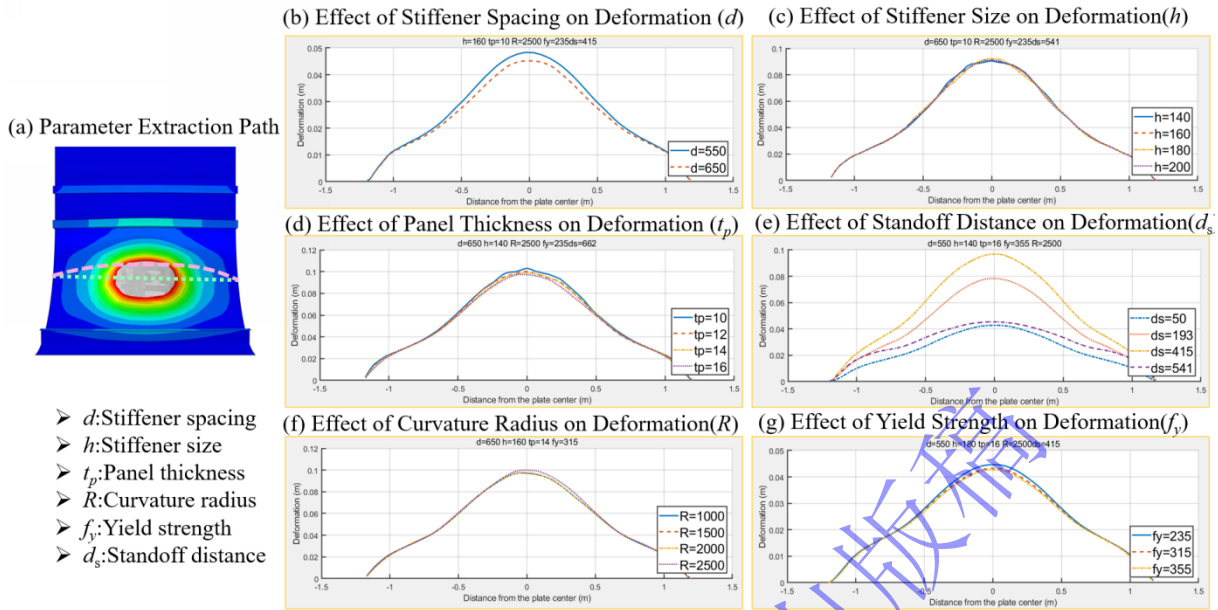


图 7 板架中段变形随关键参数的变化特性

Fig 7 The deformation of the middle section of the plate frame changes with key parameters

4 基于机器学习的舳部板水下爆炸响应预测

数值模拟后，有必要对加筋板的水下爆炸响应进行数学建模。然而，由于结构响应受多个变量控制，且响应与每个变量之间存在高度非线性，因此几乎不可能拟合一个闭式公式来表征结构响应。随着人工智能的发展，机器学习（ML）提供了一种替代解决方案。这些算法非常适用于“多变量”和“非线性”问题。为此，本节将构建一个针对加筋板水下爆炸损伤的集成预测框架。该框架通过两阶段协同方法克服了经验公式的传统局限性，如图 8 所示。

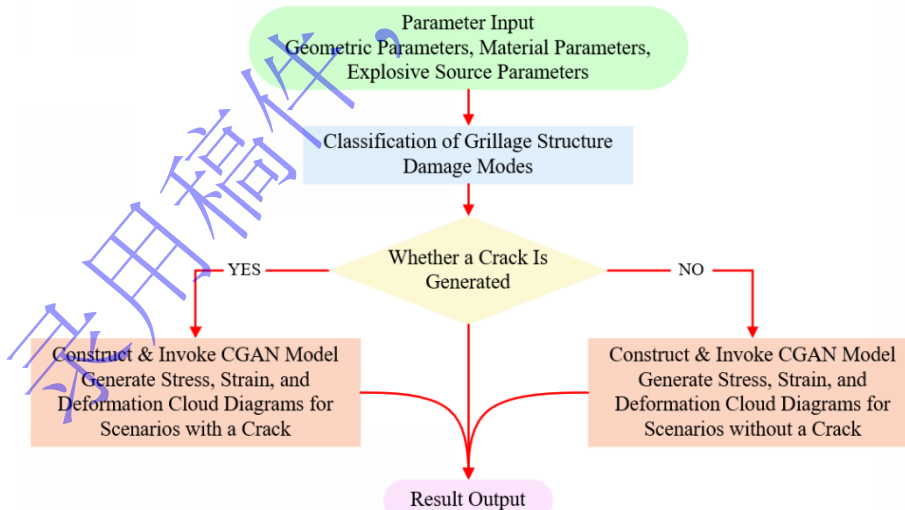


图 8 预测框架的整体示意图

Fig 8 Overall schematic diagram of the forecasting framework

在第一阶段，随机森林（RF）分类器对损伤模式进行预筛选。它利用特征随机化和基尼不纯度优化，基于六维输入参数将结果分类为变形或开裂。这种预筛选为后续的并行处理创造了条件。在第二阶段，构建并实现了条件生成对抗网络（CGAN），以从参数化输入中直接合成 256×256 像素的损伤轮廓图。通过整合这些阶段，形成了一个涵盖分类、视觉轮廓生成的端到端工作流程。这种统一架构同时实现了直观的损伤可视化和严谨的定量评估，显著提升了在不同爆炸场景下的预测泛化能力。

4.1 损伤模式二分类

4.1.1 随机森林 RF

加筋板在水下爆炸下的损伤模式根本上分为变形或开裂，这由结构承载能力和爆炸强度所控制。这些不同的失效机制需要单独的预测模型。为此，本文构建了一个随机森林分类器来执行这种二分类，为后续的特定制分析提供关键基础。该算法采用决策树集成，通过特征随机化和基尼不纯度优化来增强泛化性能。针对开裂样本与完好样本数量不平衡的问题，本研究采用类别权重平衡策略。随机森林的树数量设置为 100，这是因为当树数量超过 80 后验证集准确率已趋于稳定，故选取 100 可在保证性能的同时控制计算成本。最大深度设置为 5，则是通过对 3、5、7、10 这四组候选取值进行对比确定，该深度在测试集上取得最佳泛化效果，而更深或更浅的取值均会导致过拟合或欠拟合问题。故此关键参数设置如下：树的数量 $T=100$ ，最大深度 $d_{\max}=5$ ，以处理数据不平衡问题。核心工作流程如图 9 所示。关于随机森林分类过程和机制的更多细节可见参考文献[9]。

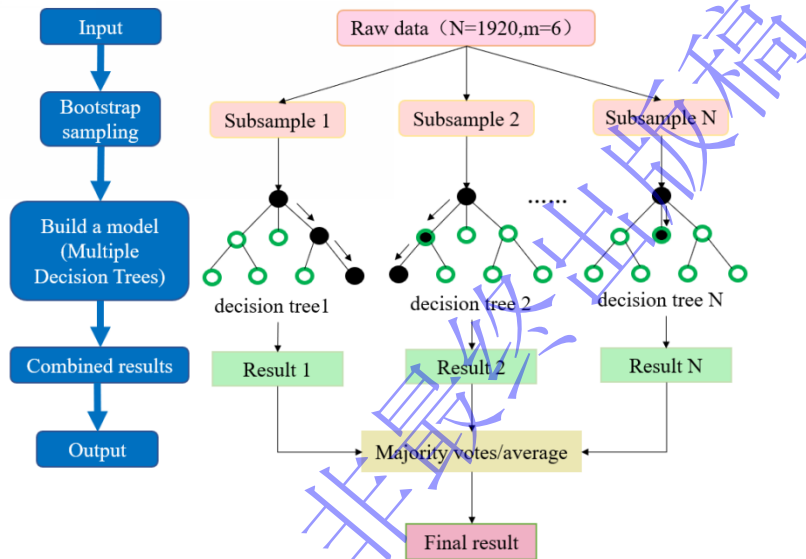


图 9 随机森林算法的核心工作流程

Fig 9 Core workflow of random forest algorithms

4.1.2 损伤模式二分类预测结果

计算完成后，通过检测结果中的状态变量对损伤模式进行分类：根据 Abaqus 输出区分有破口和无破口的板，其中失效单元的状态变量被赋值为 0，完好单元的状态变量为 1。在 2304 个模拟工况中，547 个加筋板发生了单元失效（开裂），而 1757 个表现出变形但无裂纹。根据状态变量，有裂纹的板标记为 0，而完好的板标记为 1。数据集由第 4.1.1 小节描述的随机森林分类器进行处理。完整数据集（2304 个样本）被随机分为 70%（1612 个样本）用于训练和 30%（692 个样本）用于测试。

由图 10 (a) 所示的混淆矩阵显示，测试准确率达到 99%，开裂类别的召回率为 100%（164/164），完好类别的召回率为 99.2%（524/528）。校准曲线与理想对角线紧密对齐（图 10 (b)），以此验证了概率可靠性。图 10 (b) 中的接收者操作特征曲线描绘了在不同分类阈值下真阳性率与假阳性率之间的关系，概率分布分析（图 10 (c)）显示了一个双峰模式：完好类别在 0.85~0.95 处达到峰值，而开裂类别聚集在 0.05~0.15，几乎无样本落在 0.5 的决策阈值附近。通过基尼不纯度减少度量的特征重要性排序（图 10 (d)）确定 d_s 是贡献最高的因素， d 是最低的因素，其中 d_s 和 R 的累积影响超过 97%。

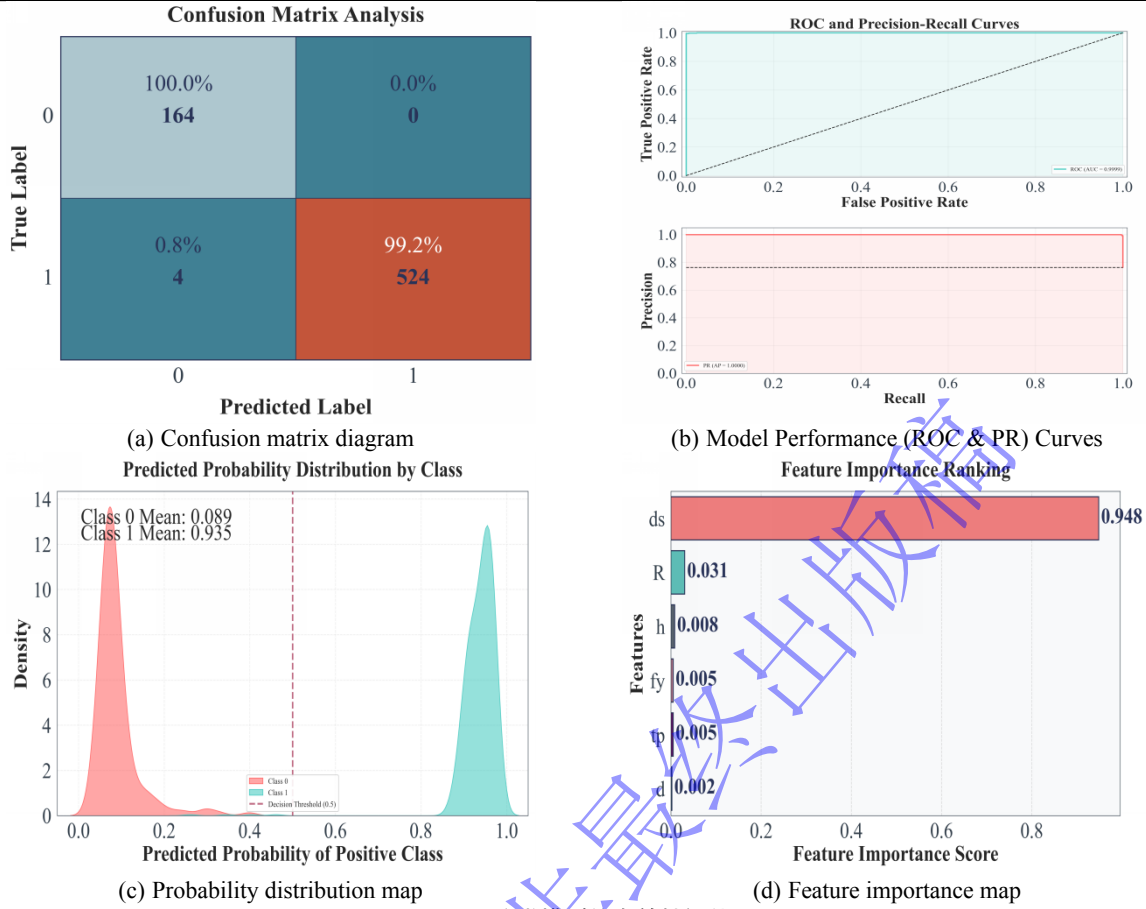


图 10 分类模型的有效性评估

Fig 10 Evaluation of the effectiveness of the classification model

这些结果证明了随机森林分类器在此任务上的优异性能（总体准确率=99%）。此外，分析进一步揭示，在考虑的六个参数中，爆距（ d_s ）和曲率半径（ R ）对加筋板损伤模式的影响最为显著。关于加筋板的内在参数，损伤模式对曲率半径（ R ）、材料属性（ f_y ）以及舭部板厚度（ t_p ）表现出更高的敏感性，而加筋间距（ d ）对水下爆炸响应的影响相对较小。

4.2 图像预测

4.2.1 CGAN 模型

传统的损伤轮廓预测方法依赖于节点损伤值，需要在构建云图之前先预测各个节点的指标。这种方法存在一个关键局限：它要求训练数据集与预测数据集之间具有严格的节点对应关系。任何几何尺寸（如板长、板宽或形状）的改变，都不可避免地会改变节点的数量、编号和空间坐标，从而使基于原始节点数据训练的模型失效。

为克服这些几何约束，本研究提出了一种新颖的基于条件生成对抗网络（CGAN）的框架，该框架建立了从物理参数空间到损伤轮廓空间的端到端映射，基本独立于特定的节点配置。该框架将预测目标从传统的离散节点力学标量，转换为标准化的全场云图图像，降低了预测结果对特定有限元节点配置的依赖性；模型以 6 个独立物理设计参数为条件输入，学习的是参数变化与结构响应分布之间的映射关系，而非特定节点的数值拟合，提高了模型对训练参数域内未见组合的预测稳定性。该框架六个物理参数作为条件变量 c ，同时输入到生成器（G）和判别器（D）中。其对抗目标函数定义如下：

$$\min_{\theta_G} \max_{\theta_D} V(\theta_D, \theta_G) = E_{x \sim P_{data}} [\log D(x | c)] + E_{z \sim P_z} [\log(1 - D(G(z | c)))] \quad (6)$$

式中 $V(\theta_D, \theta_G)$ 为生成对抗网络的博弈目标函数，该极小极大博弈过程使生成器与判别器在对抗中共同提升， θ_G 与 θ_D 分别表示生成器和判别器的超参数。 x 是真实图像样本， z 是潜在噪声向量， c 表示条件变量， P_{data} 表示真实数据分布， P_z 是噪声分布。

生成器 G 采用 U-Net 风格的架构，并通过一个多层感知机（MLP）进行条件控制。U-Net 架构包含两层编码器和六层解码器。编码器部分，第一层使用卷积核数量为 64、尺寸为 4×4 、步长为 2 的卷积层，其后接批量归一化层和泄漏修正线性单元激活函数；第二层卷积核数量增至 128，其余参数不变。解码器部分，第一至第三层使用卷积核数量依次为 256、128、64 的转置卷积层，每层后接批量归一化层和修正线性单元激活函数；第四至第六层逐步降低通道数，最终输出三通道（红绿蓝）的 256×256 像素图像。在编码器与解码器之间，特征图尺寸经逐层下采样从 256×256 缩减至 32×32 ，再将此 $32 \times 32 \times 256$ 的特征图展平，得到 $32 \times 32 \times 256 = 262144$ 维特征向量。该向量与 6 个物理参数条件变量拼接后，通过多层感知机映射并重组为解码器所需的特征图。判别器采用 6 层卷积的 Patch-GAN 结构，每层卷积核尺寸为 4×4 、步长为 2，卷积核数量从 64 逐层递增至 512，激活函数统一使用泄漏修正线性单元；最后一层输出一个大小为 $30 \times 30 \times 1$ 的特征图，用于对输入图像的每个局部块进行真假判别，同时 6 个条件变量通过嵌入层与中间特征图拼接以参与判别。G 和 D 的网络结构如图 11 所示。关于 CGAN 模型的更多细节可见参考文献[22]~[25]。




图 11 生成器与判别器的网络架构图

Fig 11 Network architecture diagram of generator and discriminator

4.2.2 图像训练结果

针对全部 2304 组计算结果，提取并可视化了应力、应变与变形云图，作为 CGAN 的训练目标。本研究训练了六个独立的 CGAN 模型，分别建立六个输入参数到三类云图的映射。生成器采用 2 层编码器与 6 层解码器的 U-Net 结构，判别器为 6 层卷积网络（Patch-GAN）。输入为六维物理参数（曲率半径、加筋间距、加筋高度、面板厚度、爆距、屈服强度）及随机噪声向量，输出 256×256 像素的 RGB 云图。模型采用 Adam 优化器（学习率 0.0001， $\beta_1=0.5$ ， $\beta_2=0.999$ ）训练 500 轮，每 100 轮保存中间结果以监控收敛。训练过程中，判别器损失与生成器损失均在前 100 轮波动较大，随后逐渐下降并趋于稳定；在训练结束时，判别器损失收敛至约 0.2~0.4，生成器损失收敛至约 2~3，整体未出现发散或模式崩溃现象。从图 12 所示的训练损失曲线可以看出，在迭代过程中生成的图像逐渐接近真实图像。具体来说，训练初期（前 100 轮），判别器和生成器的损失都波动显著，表明模型处于激烈竞争阶段。这种现象符合 GAN 训练的预期行为：判别器试图提高区分真假样本的能力，而生成器则努力生成更逼真的样本来误导判别器。随着训练的进行（200~300 轮之后），两条损失曲线均逐渐下降并趋于稳定，波动幅度显著减小，表明模型逐渐接近纳什均衡状态。此时，生成器能够持续生成具有欺骗性的样本，而判别器也表现出稳定且有限的区分真伪能力，整体训练达到了动态平衡。从收敛性来看，损失曲线最终收敛到一个较低的数值范围，没有出现发散或持续振荡，表明训练过程是稳定和收敛的，也说明超参数（如学习率）设置合理。此外，在曲线中未发现模式崩溃的典型特征（例如生成器损失突然急剧下降或判别器损失出现大幅反复波动）。生成器损失的平滑收敛表明其并未陷入局部最优，而是很好地学习了真实数据分布的多样性。总之，该 CGAN 训练在对抗平衡、收敛性和模式覆盖方面表现出良好的特性，符合成功 GAN 训练的典型特征，表明训练过程是有效的，并且模型已达到较为理想的状态。与二分类的训练划分策略一样，CGAN 模型仅使用 70% 的数据集进行模型训练，剩余 30% 作为测试集工况，测试工况的预测结果与有限元参考云图在损伤分布、应力集中区域等核心特征上高度一致。具体可见表 9 至表 11。该模型在测试集未见工况上表现出良好的预测能力，能够为未见过的、但合理的参数组合生成具有物理意义的预测。

爆炸与冲击
Explosion and Shock Waves

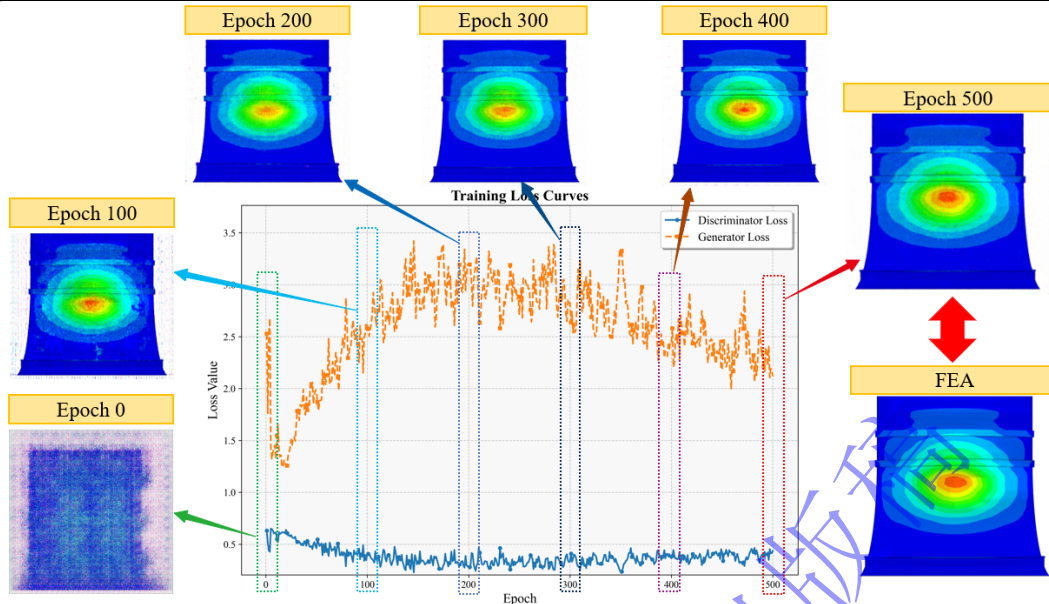


图 12 训练损失函数曲线

Fig 12 Training loss function curves

表 9 至表 11 展示了合成图像与 ABAQUS 参考图像在关键区域（如裂纹位置、应力梯度）的精确空间对应关系，表中所示结果均包含训练集工况与测试集工况。有限元和 CGAN 方法都清晰地揭示了破口区域、裂纹边界处显著的应力集中、一致的高应力分布模式以及板中心的最大变形，从而证实了 CGAN 捕捉开裂附近复杂应力梯度的能力。计算效率分析展示了 CGAN 的明显优势：生成单个应力、应变或变形云图仅需 10~15 秒，远短于在相同条件下进行高保真瞬态非线性有限元分析所需的数小时，即实现了超过 200 倍的加速。这一速度的显著提升有助于快速评估各种设计方案或爆炸场景。对训练好的 CGAN 模型进行的系统测试显示，其在预测船体板架响应方面表现优异。在定性上，合成云图在分布特征上与 ABAQUS 结果高度一致，尤其是在关键区域。对于典型工况，预测能准确定位高应力区，复现塑性应变扩展路径，并重建整体变形模式。对于开裂工况，裂纹的位置、几何形状和尺寸均显示出令人满意的精度，边缘处的应力梯度与参考数据相符。参数研究表明，通过单独调整单个变量，物理行为的变化是一致的。增加装药量会逐步扩大高应力区，加剧结构变形，并引发裂纹的萌生和扩展。这一结果验证了模型准确捕捉输入与响应之间关系的能力。

表 9 有限元分析与 CGAN 预测变形云图结果对比

Table 9 Comparison of finite element analysis and CGAN predictive deformation cloud map

参数组合	$R=1500\text{mm}, d=550\text{mm}, t_p=14\text{mm}, d_s=662\text{mm}, f_y=235\text{MPa}$	$R=2500\text{mm}, d=550\text{mm}, t_p=12\text{mm}, d_s=193\text{mm}, f_y=235\text{MPa}$	$R=1000\text{mm}, d=550\text{mm}, t_p=10\text{mm}, d_s=415\text{mm}, f_y=235\text{MPa}$	$R=1500\text{mm}, d=550\text{mm}, t_p=10\text{mm}, d_s=303\text{mm}, f_y=235\text{MPa}$
有限元计算结果				
CGAN 预测结果				

表 10 有限元分析与 CGAN 预测应变场结果对比

Table 10 Comparison of finite element analysis and CGAN predicted strain field results

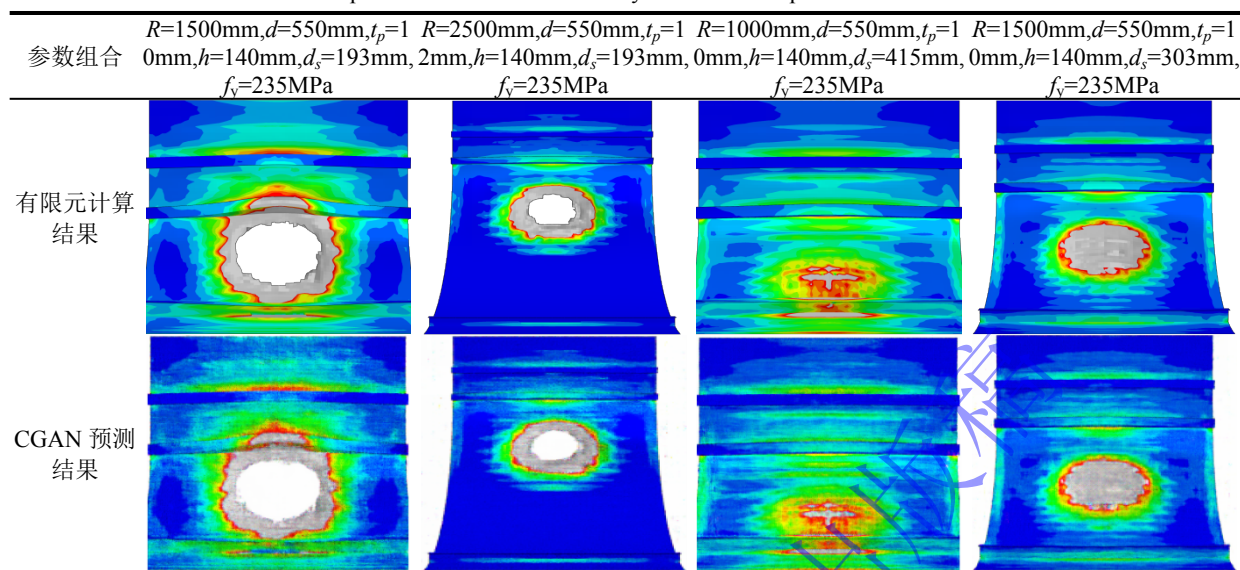
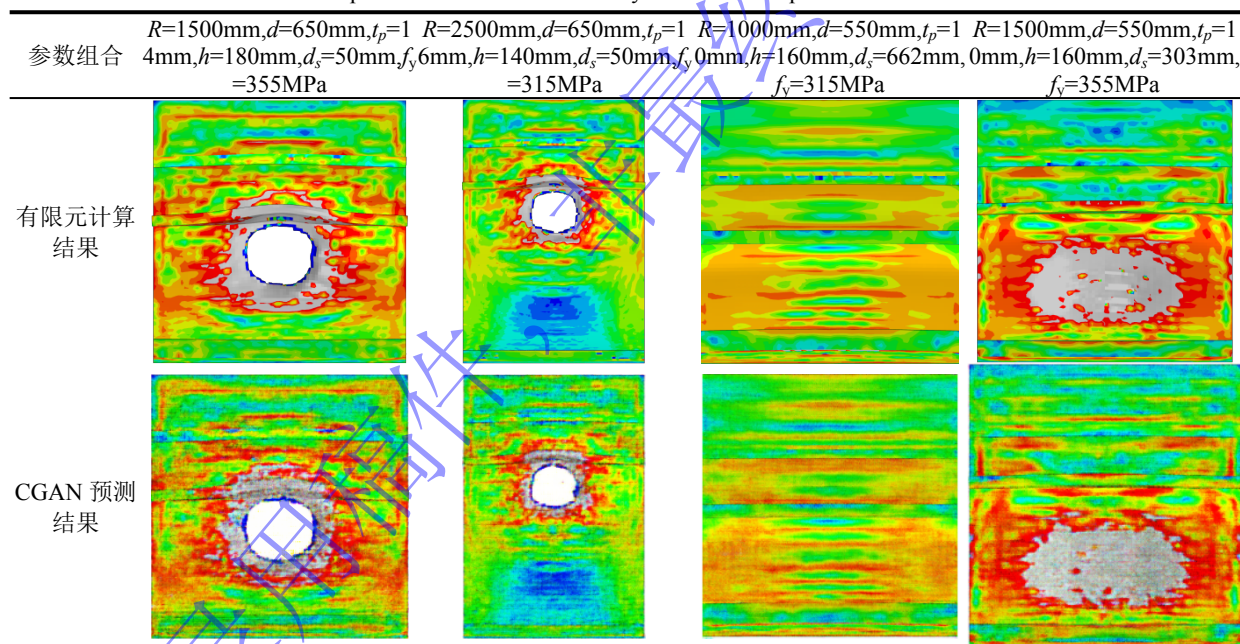


表 11 有限元分析与 CGAN 预测应力场结果对比

Table 11 Comparison of finite element analysis and CGAN predicted stress field results



4.3 方法使用条件与适用性

本研究以经试验验证的耦合欧拉-拉格朗日 (CEL) 流固耦合数值模型为物理基础, 并将机器学习作为提升预测效率的辅助工具。整个预测框架的适用范围与精度边界由底层物理模型的可靠性所决定, 从而形成“试验验证—数值建模—数据驱动预测”的分层建模体系。具体而言, 方法构建遵循统一的物理一致性约束流程: 首先基于公开试验数据对 CEL 流固耦合方法、材料本构关系、状态方程及关键求解设置进行统一验证, 使数值模型能够在网格无关性与时间步收敛性条件下, 稳定复现典型水下爆炸载荷作用下结构的变形与破坏模式。该步骤确保后续所有仿真数据均来源于已验证的物理一致数值求解体系, 从源头保证数据生成过程的可信性与一致性。

需要说明的是, 本研究的输入条件基于典型工程场景构建, 包括四边固支边界条件、流场无反射边界设置, 以及舱部板架结构拓扑形式。所有数值样本均在统一物理假设与建模流程下生成, 从而保证数据的一致性与可比性。在此参数空间内, 模型学习的是结构参数—响应场的高维非线性映

射关系，而非依赖特定有限元节点或局部网格拓扑信息，因此具备从离散数值场到统一分辨率响应图像空间的映射能力。

在适用性方面，当输入参数位于训练数据覆盖范围内时，模型能够实现稳定且高效的响应预测；当输入超出当前参数空间时，可通过引入新增高保真仿真样本对模型进行增量更新，从而扩展其参数适用范围。此外，当边界条件或结构形式发生变化时，可基于相同参数化建模流程重构数据集并对模型进行再训练，以保证物理一致性与预测可靠性。因此，本研究提出的框架具有良好的工程扩展性，其优势不仅体现在特定结构的快速预测能力上，更体现在其作为一种面向冲击动力学问题的数据驱动建模方法框架，为类似冲击载荷作用下的结构响应建模与快速预测提供方法借鉴。

5 结论

本研究通过集成参数化数值模拟与机器学习算法，构建了一个能够快速准确预测船体舭部板架水下爆炸响应的综合框架。经验证的高保真流固耦合有限元方法为结构响应分析提供了可靠基础。系统性的参数化建模技术高效生成了涵盖多设计变量的大规模数据集，为机器学习建模提供了充分的数据支持。在此基础上，所构建的机器学习预测框架展现出优异性能：随机森林模型实现了损伤模式的高精度分类；条件生成对抗网络突破了传统节点依赖型预测的几何限制，实现了从参数空间到场分布图像的端到端映射，大幅提升了预测效率与泛化能力。该框架有效整合了定性判断、定量评估与全场可视化能力，为船舶结构在爆炸冲击载荷下的快速安全评估与耐爆设计的智能化发展提供了切实可行的技术路径。本研究的局限性在于现有模型重点考虑本文限定的边界条件与环境场景，后续可基于本文提出的可迁移框架，拓展复杂边界约束、浅水环境等工程场景的应用，进一步提升方法的普适性。

参考文献

- [1] 王天召,孙远翔,陈岩武.水下接触爆炸气泡脉动特性的理论研究[J].爆炸与冲击,2026,46(1):011104. DOI: 10.11883/bzycj-2025-0092.
WANG T Z, SUN Y X, CHEN Y W. Theoretical study of bubble pulsation characteristics in underwater contact explosions[J]. Explosion And Shock Waves, 2026, 46(1): 011104. DOI: 10.11883/bzycj-2025-0092.
- [2] 杜青松, 刘云龙. 深海水下爆炸冲击波载荷及气泡脉动特性研究[J]. 爆炸与冲击, 2026, 46(1): 011106. DOI: 10.11883/bzycj-2024-0515.
DU Q S, LIU Y L. Research on the shock wave load and bubble pulsation characteristics of deep-sea underwater explosions[J]. Explosion And Shock Waves, 2026, 46(1): 011106. DOI: 10.11883/bzycj-2024-0515.
- [3] RAMAJEYATHILAGAM K, VENDHAN C P. Deformation and rupture of thin rectangular plates subjected to underwater shock. International Journal of Impact Engineering, 2004, 30 (6), 699-719. DOI: 10.1016/j.ijimpeng.2003.01.001.
- [4] DONEA J, GIULIANI S, HALLEUX J P. An arbitrary lagrangian-eulerian finite element method for transient dynamic fluid-structure interactions. Computer Methods in Applied Mechanics and Engineering, 1982, 33(1-3), 689-723. DOI: 10.1016/0045-7825(82)90128-1.
- [5] ZONG Z, ZHAO Y J, LI H T. A numerical study of whole ship structural damage resulting from close-in underwater explosion shock. Marine Structures, 2013, 31: 24-43. DOI: 10.1016/j.marstruc.2013.01.004.
- [6] JOHNSON G R, COOK W H. A constitutive model and data for metals subjected to large strains, high strain rates and high temperatures[J]. Engineering Fracture Mechanics, 1983, 21: 541-548. DOI: 10.1016/0013-7944(83)90051-4.
- [7] KOLI S, CHELLAPANDI P, RAO L B. Study on JWL equation of state for the numerical simulation of near-field and far-field effects in underwater explosion scenario. Engineering Science and Technology, an International Journal. 2020, 23(4): 758-768. DOI: 10.1016/j.jestch.2020.01.007.
- [8] BRUNTON S L, NOACK B R, KOUMOUTSAKOS P. Machine Learning for Fluid Mechanics. Annual Review of Fluid Mechanics, 2020,52: 477-508. DOI: 10.1146/annurev-fluid-010719-060214.
- [9] BREIMAN L. Random forests. Machine Learning, 2001, 45(1):5-32. DOI: 10.1023/A:1010933404324.
- [10] KRICHEN M. Generative adversarial networks[C]//2023 14th International Conference on Computing

- Communication and Networking Technologies (ICCCNT). Delhi, India: IEEE, 2023: 1-7. DOI: 10.1109/ICCCNT56998.2023.10306417.
- [11] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J/OL]. arXiv preprint arXiv:1411.1784, 2014[2026-05-22]. <https://arxiv.org/abs/1411.1784> . DOI: 10.48550/arXiv.1411.1784.
- [12] HE Z H, CHEN X Q, ZHANG X Q. Damage prediction of hull structure under near-field underwater explosion based on machine learning[J]. Applied Ocean Research. 2025, 154, 104329. DOI: 10.1016/j.apor.2024.104329.
- [13] GANNON L G, MARSHALL C R. Marshall. A recurrent neural network model for structural response to underwater shock[J]. Ocean Engineering. 2023, 287(2), 115898. DOI: 10.1016/j.oceaneng.2023.115898.
- [14] LIANG X D, LIU Y D, WANG S Q. A Kolmogorov-Arnold network-based method for predicting underwater explosion shock spectrum considering cabin structural characteristics[J]. International Journal of Naval Architecture and Ocean Engineering. 2025, 17, 100671, DOI: 10.1016/j.ijnaoe.2025.100671.
- [15] BARDIANI J, SBARUFATTI C, MANES A. Machine Learning for Underwater Explosion Prediction: A Comprehensive Review of Methods, Challenges and Future Directions[J]. Archives of Computational Methods in Engineering, 2026, 33, 645–686. DOI:10.1007/s11831-025-10318-4.
- [16] JIANG H L, NIE Z G, YEO R.. StressGAN: A Generative Deep Learning Model for 2D Stress Distribution Prediction[J]. Journal of Applied Mechanics, 2021, 88(5): 051005. DOI: 10.1115/1.4049805.
- [17] LIU Y M, LIN Q Y, PAN W. SR-M-GAN: A generative model for high-fidelity stress fields prediction of the composite bolted joints[J]. Advanced Engineering Informatics. 2024, 61, 102537. DOI: 10.1016/j.aei.2024.102537
- [18] KHAN S, GOUCHER-LAMBERT K, KOSTAS K, et al. ShipHullGAN: A generic parametric modeller for ship hull design using deep convolutional generative model[J]. Computer Methods in Applied Mechanics and Engineering, 2023, 411: 116051. DOI: 10.1016/j.cma.2023.116051.
- [19] ZHANG Y F, LIU L T, WANG J X. Characteristics of multiple cavitations near plate structures in underwater explosions. International Journal of Mechanical Sciences, 2025, 288: 110047. DOI: 10.1016/j.ijmecsci.2025.110047.
- [20] JOHNSON G R, COOK W H. Fracture characteristics of three metals subjected to various strains, strain rates, temperatures and pressures. Engineering Fracture Mechanics, 1985, 21(1): 31-48. DOI: 10.1016/0013-7944(85)90052-9.
- [21] 梁潇帝,刘寅东. 基于舱室结构特征的水下爆炸冲击响应快速预报方法[J]. 振动与冲击, 2025, 44(4): 207-216. DOI: 10.13465/j.cnki.jvs.2025.04.022.
- LIANG X D, LIU Y D. A rapid prediction method for underwater explosion impact response based on compartment structural characteristics[J]. Journal of Vibration and Shock, 2025, 44(4): 207-216. DOI: 10.13465/j.cnki.jvs.2025.04.022.
- [22] WANG H T, LIU B, LEI J. Improved deep neural network for predicting structural response of stiffened cylindrical shells to far-field underwater explosion. Ocean Engineering, 2024, 298: 117258. DOI: 10.1016/j.oceaneng.2024.117258.
- [23] LIU Y, CHEN J, HOU J A. Learning position information from attention: End-to-end weakly supervised crack segmentation with GANs. Computers in Industry, 2023, 149: 103921. DOI: 10.1016/j.compind.2023.103921.
- [24] KIM S, JANG H, YOON B. Developing a data-driven technology roadmapping method using generative adversarial network (GAN). Computers in Industry, 2023, 145: 103835. DOI: 10.1016/j.compind.2022.103835.
- [25] MILLA-VAL J, MONTAÑÉS C, FUEYO N. An image-to-image adversarial network to generate high resolution wind data over complex terrains from weather predictions. Engineering Applications of Artificial Intelligence, 2025, 139(B) 109533. DOI: 10.1016/j.engappai.2024.109533.