

基于 AGEP-DNN 的水下聚能装药比冲量预测模型

刘芳^{1a,2}, 郝慧敏^{1b}, 卢熹^{1c}, 郭策安^{1c}

(1. 沈阳理工大学 a. 理学院, b. 自动化与电气工程学院, c. 装备工程学院, 沈阳 110159;

2. 辽宁省兵器工业智能优化与控制重点实验室, 沈阳 110159)

摘要: 聚能装药比冲量是表征水下爆炸中冲击波对目标破坏作用的重要参数。为实现水下聚能装药比冲量智能预测, 提出一种自适应基因表达式编程(adaptive gene expression programming, AGEP)优化深度神经网络(deep neural network, DNN)的聚能装药比冲量预测模型(AGEP-DNN)。考虑装药结构与比冲量数值之间的复杂非线性关系, 通过 AUTODYN 软件建立有限元模型, 对水下爆炸过程进行仿真, 采用经验公式验证仿真数据的有效性; 基于仿真实验数据, 设计 AGEP 算法优化 DNN 超参数, 构建 AGEP-DNN 模型, 对比冲量进行智能预测。实验结果显示, AGEP-DNN 聚能装药比冲量预测模型在 9 种对比智能预测模型中具有最优的预测精度。

关键词: 聚能装药; 比冲量; 自适应基因表达式编程; 深度神经网络; 数值仿真

中图分类号: TJ65 **文献标志码:** A **DOI:** 10.3969/j.issn.1003-1251.2024.02.003

Prediction Model of Specific Impulse of Underwater Shaped Charge Based on AGEP-DNN

LIU Fang^{1,2}, HAO Huimin¹, LU Xi¹, GUO Cean¹

(1. Shenyang Ligong University, Shenyang 110159, China; 2. Liaoning Key Laboratory of

Intelligent Optimization and Control for Ordnance Industry, Shenyang 110159, China)

Abstract: The specific impulse of shaped charge is an important parameter in underwater explosions. It is used to represent the destructive effect of a shock wave on a target. In order to predict the specific impulse, a prediction model of shaped charge based on gene expression programming optimized deep neural network(AGEP-DNN) is proposed. Considering the complex nonlinear relationship between the structure and the specific impulse value of the charge, AUTODYN is applied to build finite element models. Empirical formulas are used to validate the data. Based on the simulation experimental data, an adaptive gene expression programming(AGEP) is designed to optimize deep natural network(DNN) hyperparameters. The AGEP-DNN model is constructed to intelligently predict the specific impulse. Experimental results show that among the nine prediction models, AGEP-DNN has the highest accuracy.

Key words: shaped charge; specific impulse; adaptive gene expression programming; deep natural network; numerical simulation

比冲量是爆炸过程中冲击波超压在正压作用时间上的积分,冲击波产生的峰值超压越高或正压作用时间越长,释放的能量越强大^[1-2]。比冲量是评估装药威力和爆炸能量的重要参数,智能、精准地预测比冲量数值对评估装药的作战效能具有重要意义。

目前,针对水下聚能装药比冲量预测的研究主要有仿真实验和经验公式两种方法。仿真实验法利用仿真软件研究爆炸过程,能够节省真实实验成本^[3-5],但仿真时间长,不适用于信息化、智能化、快速反应的战场需求;经验公式法通常针对文献^[6]提出的装药比冲量计算公式进行改进,采用改进公式预测不同装药质量和测距位置的比冲量^[7],但该方法不适用于装药结构参数变化的情况,算法泛化性较弱。

智能、准确地挖掘装药结构参数和比冲量数值之间的复杂非线性关系是装药结构设计和装药毁伤评估亟待解决的问题。现已有研究人员利用神经网络的非线性映射能力对装药参数与爆炸载荷数据进行预测,奠定了装药毁伤参数智能预测算法的研究基础^[8-9]。由于神经网络易陷入局部最优且存在网络结构选择多样性问题,其在预测精度方面受到局限。

针对水下聚能装药比冲量预测中存在的泛化性弱、预测精度低、智能化欠缺的问题,本文基于聚能装药水下爆炸的仿真实验数据,提出一种自适应基因表达式编程(adaptive gene expression programming, AGEP)优化深度神经网络(deep neural network, DNN)^[10]结构的比冲量预测模型,称为 AGE P-DNN 模型。使用 DNN 挖掘水下爆炸过程中装药结构与不同爆距比冲量的非线性关系;构建基因表达式编程(gene expression programming, GEP)算法,优化 DNN 的隐藏层数和隐藏层节点数;设计自适应交叉概率和自适应变异概率,智能调节 GEP 算法的搜索范围。采用包含群智能算法优化三层 BP 神经网络、卷积神经网络(CNN)、循环神经网络和 GEP 优化 DNN 的四大类 9 种智能预测模型进行对比实验,验证本文 AGE P-DNN 预测模型的有效性。

1 水下爆炸数值仿真

聚能战斗部水下爆炸产生的载荷与爆破战斗部相比,能量分配以及演化规律更加复杂^[11]。考虑到水下爆炸过程中参数获取困难,本文使用

AUTODYN 软件进行聚能装药水下爆炸仿真实验,装药材料为 B 炸药,药型罩为球缺结构,装药结构如图 1 所示。图中: R_1 和 R_2 分别为球缺药型罩的外径和内径, $R_1 = 52.5 \text{ mm}$, $R_2 = 49.6 \text{ mm}$; l 和 d 分别为装药长度和装药直径, $l = 100 \text{ mm}$, $d = 100 \text{ mm}$ 。图中数值单位为 mm。




图 1 聚能装药结构

Fig. 1 Shaped charge structure

为研究装药结构参数和比冲量数值之间的非线性关系,仿真实验中假设装药类型、壳体材料、水介质等条件均不改变,只选取装药结构参数作为可变条件参数,研究不同爆距的比冲量分布情况。为消除不同参数量纲的影响,选取无量纲化的药柱长径比 l/d 、相对轴向距离 h/d 和相对径向距离 r/d 三个结构参数对相对比冲量 I/d 进行预测研究,其中 h 和 r 分别表示测点距药柱前端的轴向距离和测点距轴线的径向距离, I 为比冲量。水下爆炸聚能装药仿真模型及 36 个测点位置如图 2 所示,仿真实验中水体(WATER)、B 炸药(COMP B)、空气(AIR)和药型罩(COPPER)部分采用欧拉算法计算。



图 2 聚能装药仿真模型及测点位置示意图

Fig. 2 Simulation model of shaped charge and schematic diagram of measurement point

为验证仿真数据的可用性,采用经验公式^[6]计算比冲量,计算结果与仿真实验所得数据相对误差不超过 15%,表明该仿真模型可靠性较高,可使用其数据对比冲量进行预测。部分仿真实验数据与经验公式计算结果的对比如表 1 所示。

表 1 部分仿真实验数据和经验公式计算结果的对比

Table 1 Comparison of partial simulation data and empirical formula results

l/d	h/d	r/d	相对比冲量/(N·s·m ⁻³)		相对误差/%
			经验公式	仿真实验	
1.5	0	3.75	135 136.32	147 583.23	9.21
1.5	0.312 5	3.75	134 720.81	144 833.78	7.51
1.5	0.625	3.75	133 498.72	142 455.56	6.71
1.25	1.25	3.75	128 946.65	122 616.13	4.91
1.25	1.875	3.75	122 362.23	113 458.00	7.28
2	2.5	1.875	158 943.72	138 562.10	12.82

2 比冲量预测模型

2.1 深度神经网络

考虑聚能装药水下爆炸比冲量预测问题涉及多种条件参数,具有高度的非线性,使用三层神经网络很难满足要求。本文利用具有强大非线性挖掘能力的 DNN 建立装药结构参数和比冲量之间的函数映射关系,提升预测精度。模型网络结构如图 3 所示,包含输入层、输出层和多个隐藏层,分为前向传播和反向传播两个过程。




图 3 DNN 水下聚能装药比冲量预测模型网络结构

Fig. 3 Network structure of DNN underwater shaped charge specific impulse prediction model

在前向传播中,输入装药长径比、相对轴向距离和相对径向距离,通过隐藏层传输,对复杂物理化学过程进行拟合,输出网络预测后的相对比冲量。为增加 DNN 对非线性过程的拟合能力,缓解梯度消失问题,设置激活函数为 ELU 函数,各层节点取值如式(1)所示。

$$h_l^k = \begin{cases} \omega_l h_{l-1} + b_l^k, & \omega_l h_{l-1} + b_l^k > 0 \\ \alpha \cdot (e^{\omega_l h_{l-1} + b_l^k} - 1), & \omega_l h_{l-1} + b_l^k \leq 0 \end{cases} \quad (1)$$

式中: h_l^k 和 b_l^k 分别为第 l ($l=1, 2, \dots, L$) 个隐藏层第 k ($k=1, 2, \dots, K$) 个节点的值和偏置,偏置初始值设为 0; ω_l 和 h_l 分别为第 l 个隐藏层的权值和节点值向量,权值为 $[0, 1]$ 上的均匀分布; α 用于

控制 ELU 函数负半轴的斜率,一般取值为 1。

为衡量预测值与真实值之间的误差,选取均方根误差 (RMSE) 作为网络的损失函数,其计算式为

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

式中: y_i 为真实值; \hat{y}_i 为预测值; n 为预测值个数。在反向传播中,使用梯度下降法根据 RMSE 值对层间的权重和阈值进行调整。进行正向和反向传播训练,直至满足最小误差为止。

2.2 自适应基因表达式编程

GEP 算法使用简单编码解决复杂问题,具有较大搜索范围和良好的计算精度^[12]。GEP 主要优化过程包括染色体编码与解码、适应度函数确定和种群遗传操作三个部分。由于 GEP 算法易陷入局部最优,本文设计改进的自适应遗传操作,扩大算法的搜索范围。

2.2.1 染色体编码与解码

GEP 中的染色体可含有单个或多个基因,每个基因有头部、尾部和常数 (DC) 域三部分,DC 域用于填充头部和尾部的问号,增加表达式的随机性,扩大基因的搜索范围。预设头部长度的数值,则尾部长度的计算方法如式(3)所示。

$$T = H \times (N - 1) + 1 \quad (3)$$

式中: T 和 H 分别为尾部和头部的长度; N 为函数符允许的最多参数个数。

以一个二基因的染色体为例,描述其编译过程,如图 4 所示。

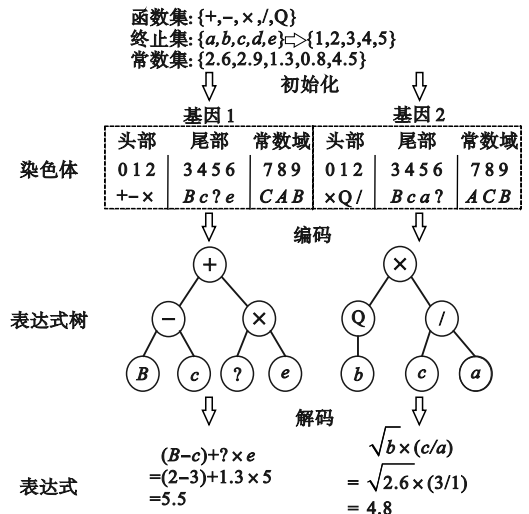



图 4 染色体编译过程

Fig. 4 Chromosome compilation process

2.2.2 适应度函数确定


适应度函数表示染色体对环境的适应能力,其设定会直接影响 GEP 的进化过程。为实现 GEP 对 DNN 结构的高效优化,本文采用 DNN 的目标函数 RMSE 作为 GEP 的适应度函数,其值越小,说明模型预测精度越高。



(a) 交叉操作

2.2.3 种群自适应遗传操作

当染色体适应度不满足设定值时,种群将进行一系列遗传操作,主要包括选择、交叉和变异。传统 GEP 算法中选择操作使用轮盘赌法,交叉操作和变异操作如图 5 所示,图 5(a)中虚线框为交叉的部分,图 5(b)中下划线为变异的部分。



(b) 变异操作

图 5 染色体的交叉和变异

Fig. 5 Cross and variation of chromosomes

由图 5 可知:交叉操作优化染色体,产生新结构,扩展种群搜索范围;变异操作改变基因位点,保护种群多样性,收敛寻优区间的范围。传统 GEP 算法的交叉率和变异率固定,交叉操作和变异操作没有区分优良个体和劣质个体在种群进化中的作用,不考虑进化过程,不能较好满足种群进化需求。针对传统 GEP 算法的交叉率和变异率固定不变的问题,充分考虑不同时刻基因进化的不同需求,将表征进化进程的迭代次数引入公式,改进 GEP 算法的交叉率和变异率,如式(4)和式(5)所示。

$$p_c = \begin{cases} p_{c_max} - \left(\frac{p_{c_max} - p_{c_min}}{it_{max}} \right) \times iter, & f \geq f_{avg} \\ p_{c_max}, & f < f_{avg} \end{cases} \quad (4)$$

$$p_m = \begin{cases} p_{m_min} + \left(\frac{p_{m_max} - p_{m_min}}{it_{max}} \right) \times iter, & f \geq f_{avg} \\ p_{m_min}, & f < f_{avg} \end{cases} \quad (5)$$

式中: p_c 和 p_m 分别为交叉率和变异率; p_{c_max} 和 p_{m_max} 为交叉率和变异率最大值; p_{c_min} 和 p_{m_min} 为交叉率和变异率最小值; it_{max} 为设定的最大迭代次数; $iter$ 为当前迭代次数; f_{avg} 为所有染色体适应度的平均值; f' 为交叉操作中适应度更高的染色体适应度值; f 为变异操作中染色体适应度值。

改进后的计算公式使得优良个体的交叉率和变异率随着进化进程线性变化。当迭代次数增加时,交叉率逐渐降低以保留优秀解并加速收敛,变异率逐渐增加以跳出局部最优并进行全局搜索。这种进化策略能够加速收敛,利于发现优秀解,提高求解效率和质量。同时,算法使适应度较低的

个体始终拥有较高的交叉率和较低的变异率,以促进全局搜索和局部搜索。改进的公式能够更有效地控制进化过程,提升优化性能。图 6 为每代第一个选中的染色体交叉率和变异率随迭代次数的变化情况。




图 6 交叉率和变异率的变化曲线

Fig. 6 Curve of crossover rate and variability rate

2.3 AGEP-DNN 算法

DNN 中隐藏层层数和隐藏层节点数的设置决定了神经网络的拟合、预测能力与复杂度。为提高 DNN 的精度,同时缩短网络结构参数寻优时间,本文使用 AGEP 进行网络结构参数调优。

AGEP-DNN 算法将体现神经网络结构的隐藏层层数和各隐藏层节点数编码到染色体中,当染色体解码时,可将各基因编译成实数,对应于网络结构超参数的值。本文设置第 1 个基因用于表示隐藏层数量 L ,其余基因用于表示各隐藏层节点数 K_l ,AGEP-DNN 算法流程如图 7 所示。

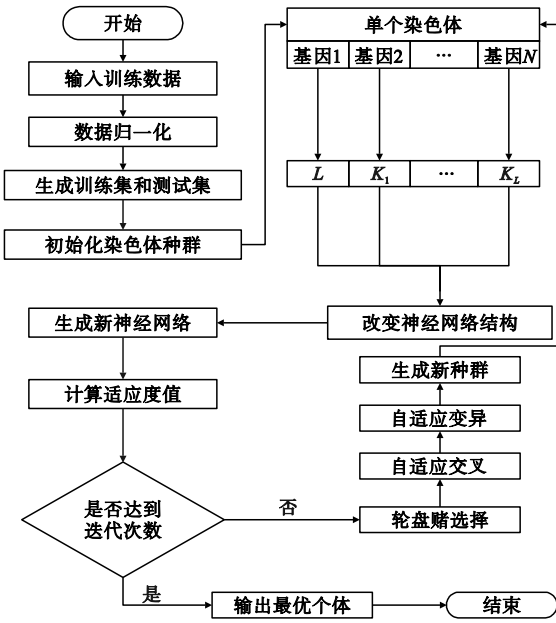


图 7 AGEP-DNN 算法流程图

Fig.7 Flow chart of AGEP-DNN network

3 算法验证实验

3.1 数据集的建立

聚能炸药水下爆炸仿真实验中设置不同装药结构和爆距; l/d 分别取为 0.75、1、1.25、1.5、2; h/d 分别取为 0、0.3125、0.625、1.25、1.875、2.5、3.75; r/d 分别取为 0.5625、0.75、1.25、1.875、2.5、3.75。共组成 180 组相对比冲量数据,部分原始数据如表 2 所示,训练集和测试集的比例为 8:2。为解决各变量间数量级相差过大的问题,对数据进行归一化处理,提高相对比冲量数值的预测精度。

3.2 实验环境与评价指标

实验环境:CPU 型号为 AMD Ryzen7 5800H,主频 3.2 GHz;GPU 型号为 NVIDIA GeForce RTX 3050。算法基于 Python 语言实现,使用软件 Jupyter Notebook 运行程序。

表 3 GEP 和 AGEP 初始参数

Table 3 GEP and AGEP initial parameters

算法	适应度函数	种群大小	进化代数	函数集	基因个数	头部长度	变异率	交叉率
GEP	RMSE	50	20	+ - × /	9	3	0.1	0.3
AGEP	RMSE	50	20	+ - × /	9	3	[0.05,0.1]	[0,0.6]

9 种智能模型的比冲量预测结果如表 5 所示。与 BP 神经网络相比较,根据经验设置的 DNN 模型获得的 MAE、MSE、RMSE、MAPE 分别提高了

表 2 部分原始数据

Table 2 Partial original data

l/d	h/d	r/d	相对比冲量 / ($N \cdot s \cdot m^{-3}$)
0.75	0	0.5625	88 655.176 8
0.75	0	0.75	131 422.985 2
0.75	0	1.25	132 631.108 1
0.75	0	1.875	122 882.482 4
0.75	0	2.5	114 267.366 3
...
2	2.5	2.5	140 885.874 3
2	2.5	3.75	131 854.512 1

算法及对比算法的评价指标分别为 RMSE、平均绝对误差(MAE)、均方误差(MSE)和平均绝对百分比误差(MAPE)。四种指标计算方法分别如式(2)及式(6)~(8)所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n | \hat{y}_i - y_i | \quad (6)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (7)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (8)$$

3.3 实验及结果分析

为验证 AGEP-DNN 比冲量预测模型的有效性,选用 BP 神经网络、CNN、循环神经网络和 DNN 四类对比算法,包含 BP 神经网络、遗传算法(GA)优化 BP 神经网络(GA-BP)、人工蜂群(ABC)优化 BP 神经网络(ABC-BP)、粒子群(PSO)优化 BP 神经网络(PSO-BP)、CNN、长短期记忆网络(LSTM)、DNN、GEP 优化 DNN(GEP-DNN)和 AGEP 优化 DNN(AGEP-DNN)共 9 种算法进行实验对比,在保证参数及初始条件一致的前提下,验证 AGEP-DNN 在比冲量预测方面的可行性。GEP 和 AGEP 初始参数设置如表 3 所示,BP、DNN、GEP-DNN 和 AGEP-DNN 4 种网络的参数设置如表 4 所示。

86.33%、83.64%、76.96%、67.06%,说明 DNN 神经网络能够解决浅层神经网络对水下爆炸过程中的复杂非线性关系处理能力不足的问题。与

DNN 相比,GEP-DNN 模型获得的 MAE、MSE、RMSE、MAPE 分别提升了 28.97%、56.16%、33.79%、30.25%,表明 GEP 通过对网络的拓扑结构进行进化搜索,获得了更优的网络结构。与

GEP-DNN 相比,AGEP-DNN 模型的 MAE、MSE、RMSE、MAPE 分别提升了 15.31%、0.87%、0.44%、24.39%,验证了调整遗传操作交叉率和变异率的有效性。

表4 神经网络参数设置

Table 4 Neural network parameters settings

算法	隐藏层层数	隐藏层节点数	学习率	迭代次数
BP	1	6	0.08	4 000
DNN	6	8,16,32,32,16,8	0.08	4 000
GEP-DNN	8	20,2,9,2,1,20,2,4	0.08	4 000
AGEP-DNN	8	14,4,6,5,12,3,5,4	0.08	4 000

表5 9种智能模型比冲量预测结果对比


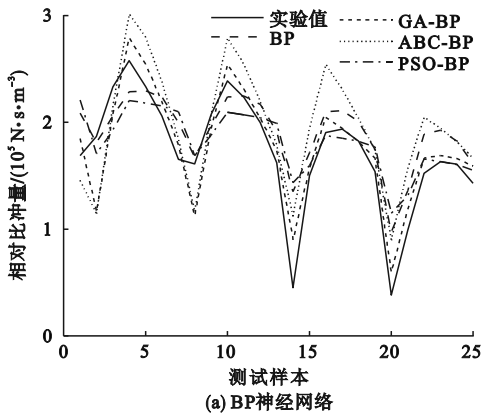
Table 5 Comparison of nine intelligent models for predicting specific impulse

算法类型	算法	MAE	MSE	RMSE	MAPE/%
BP 神经网络	BP	27 652.919 9	175 159 575.315 2	23 234.786 5	16.06
	GA-BP	29 440.490 4	372 856 428.467 2	19 309.490 6	13.04
	ABC-BP	14 028.362 5	356 907 976.247 0	18 892.008 2	14.72
	PSO-BP	10 217.814 5	227 654 740.902 5	15 088.231 8	19.37
卷积神经网络	CNN	7 685.063 5	195 150 920.881 7	13 672.905 2	7.09
循环神经网络	LSTM	4 280.709 7	46 458 779.666 9	6 737.279 3	7.77
深度神经网络	DNN	3 780.675 2	28 656 340.528 9	5 353.161 7	5.29
	GEP-DNN	2 685.579 0	12 563 529.908 4	3 544.507 0	3.69
	AGEP-DNN	2 274.319 4	12 453 712.544 7	3 528.981 8	2.79

9种预测模型在包含25组样本的测试集中得到的预测值与真实值偏差如图8所示,可见,本文算法的预测值在各样本中均最接近真实值。

图9反映了 AGEP-DNN 与 GEP-DNN 种群

适应度(RMSE)的变化过程。可见,与 GEP-DNN 相比,AGEP-DNN 的适应度曲线后期收敛速度更快,说明自适应遗传算法可更好地完成寻优任务。






图 8 对比算法预测结果

Fig. 8 Prediction results of comparative algorithms

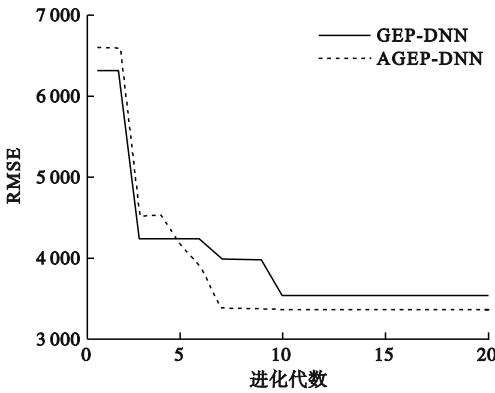


图 9 AGEP-DNN 与 GEP-DNN 的 RMSE 比较

Fig. 9 Comparison of RMSE between AGEP-DNN and GEP-DNN

4 结论

本文基于 AUTODYN 的数值仿真数据,建立了水下聚能装药比冲量预测模型(AGEP-DNN)。利用 DNN 挖掘了装药药柱长径比、相对轴向距离、相对径向距离和比冲量之间的复杂非线性关系,采用 AGEP 算法优化了 DNN 的结构参数,提升了网络的预测效果。在包含 9 种智能算法的仿真实验中,AGEP-DNN 模型在 MAE、MSE、RMSE、MAPE 四个精度评价指标中均具有最小值,验证了模型的有效性。

AGEP-DNN 水下聚能装药比冲量预测模型的构建为确定聚能战斗部装药载荷分布规律提供了算法和理论依据,有助于评估聚能战斗部在水下环境中的毁伤效应,可用于军事和爆炸物研究领域。

参考文献 (References):

- [1] 张阿漫,王诗平,彭玉祥,等. 水下爆炸与舰船毁伤研究进展[J]. 中国舰船研究,2019,14(3):1-13.
ZHANG A M, WANG S P, PENG Y X, et al. Research progress in underwater explosion and its damage to ship structures [J]. Chinese Journal of Ship Research, 2019, 14(3): 1-13. (in Chinese)
- [2] 毛致远,段超伟,刘刚伟,等. 圆柱壳结构水下爆炸冲击波毁伤的吸收冲量准则[J]. 火炸药学报,2023,46(3):245-251.
MAO Z Y, DUAN C W, LIU G W, et al. Damage criterion of cylindrical shell structure under underwater explosion shock wave: absorbed impulse criterion [J]. Chinese Journal of Explosives & Propellants, 2023, 46(3): 245-251. (in Chinese)
- [3] 李旭,焦志刚,李帅孝,等. 舱室结构对炸药内爆响应特性的数值模拟研究[J]. 沈阳理工大学学报,2022,41(2):88-94.
LI X, JIAO Z G, LI S X, et al. Numerical simulation of response of cabin structure to explosive implosion [J]. Journal of Shenyang Ligong University, 2022, 41(2): 88-94. (in Chinese)
- [4] 张羽翔,陈放. 边界尺寸对爆炸冲击载荷作用下薄板响应影响仿真研究[J]. 舰船科学技术,2018,40(5):26-29,75.
ZHANG Y X, CHEN F. Simulation study on the effect of boundary size of the thin plate under explosive impact load [J]. Ship Science and Technology, 2018, 40(5): 26-29, 75. (in Chinese)
- [5] GERASIMOV S I, KUZNETSOV P G, KUZ'MIN V A, et al. Detonation velocity of the VS-2 pyrotechnic composition and the Jones-Wilkins-Lee equation-of-state parameters of its explosion products [J]. Combustion, Explosion, and Shock Waves, 2022, 58(2): 217-225.
- [6] COLE R H. Underwater explosions [M]. Princeton: Princeton University Press, 1948.
- [7] 郑监,卢芳云,陈荣. 柱形装药条件下锥形水中爆炸激波管内的冲击波特性[J]. 爆炸与冲击,2021,41(10):78-89.
ZHENG J, LU F Y, CHEN R. Shock wave characteristics in a conical water explosion shock tube under cylindrical charge condition [J]. Explosion and Shock Waves, 2021, 41(10): 78-89. (in Chinese)