



## 基于GA-BP神经网络对控制棒水力缓冲器的性能预测和结构参数优化

张相文, 范晨光, 何安, 武闯, 杨宇静

### Performance Prediction and Structural Parameter Optimization of Control Rod Hydraulic Buffer Based on GA-BP Neural Network

Zhang Xiangwen, Fan Chenguang, He An, Wu Chuang, and Yang Yujing

在线阅读 View online: <https://doi.org/10.13832/j.jnpe.2023.06.0162>

#### 您可能感兴趣的其他文章

##### Articles you may be interested in

#### 基于改进BP神经网络的节流孔板空化特性预测

Prediction of Cavitation Characteristics of Throttle Orifice Plate Based on Improved BP Neural Network

核动力工程. 2021, 42(6): 135-140

#### 基于BP神经网络的相同几何形状等质量铀部件<sup>235</sup>U丰度判定

Determination for <sup>235</sup>U Enrichments of Same Geometry and Mass Uranium Components by BP Neural Network

核动力工程. 2019, 40(1): 48-50

#### 基于时间序列神经网络的蒸汽发生器传热管泄漏程度诊断研究

Diagnosis of Leakage Degree of Steam Generator Tube Based on Time Series Neural Network

核动力工程. 2020, 41(2): 160-167

#### 基于PSO优化神经网络响应面技术的非能动系统可靠性分析

Reliability Analysis of Passive System Based on PSO Optimized Neural Network Response Surface Method

核动力工程. 2018, 39(4): 101-106

#### 基于人工神经网络的RPV材料辐照脆化预测模型研究

Research on Prediction Model of Irradiation Embrittlement of RPV Materials Based on Artificial Neural Network

核动力工程. 2020, 41(6): 92-95

#### 基于评价函数和BP网络的CRDM滚轮状态评估方法

Evaluation Method for CRDM Roller State Based on Evaluation Function and BP Network

核动力工程. 2021, 42(1): 133-137



关注微信公众号, 获得更多资讯信息

文章编号: 0258-0926(2023)06-0162-08; DOI:10.13832/j.jnpe.2023.06.0162

# 基于 GA-BP 神经网络对控制棒水力缓冲器的性能预测和结构参数优化

张相文<sup>1</sup>, 范晨光<sup>1,2</sup>, 何安<sup>1</sup>, 武闯<sup>1</sup>, 杨宇静<sup>1</sup>

1. 西南交通大学力学与航空航天学院, 成都, 610031; 2. 应用力学与结构安全四川省重点实验室, 成都, 610031

**摘要:** 为通过遗传算法 (GA) 改进的反向传播 (BP) 神经网络模型预测控制棒组件水力缓冲器的缓冲性能, 并实现结构参数优化, 本研究对一种特定的控制棒组件水力缓冲器静水中的落棒进行模拟试验, 变换试验可调参数, 设置不同的试验工况, 获取了大量的试验数据, 通过 GA-BP 神经网络对控制棒组件落棒过程的最大冲击力进行预测, 并构建优化数学模型, 使用非线性规划函数 (fmincon) 进行求解, 获得更优的结构参数组合。结果表明: GA-BP 神经网络模型相较于 BP 神经网络模型具有更高的预测精度, 通过 fmincon 函数可以实现对控制棒组件最大冲击力优化数学模型的快速求解。因此, 本文的优化方法可为水力缓冲器的结构优化设计提供一定的参考。

**关键词:** 控制棒水力缓冲器; 缓冲性能试验; 最大冲击力; GA-BP 神经网络; 参数优化

**中图分类号:** TL334 **文献标志码:** A

## Performance Prediction and Structural Parameter Optimization of Control Rod Hydraulic Buffer Based on GA-BP Neural Network

Zhang Xiangwen<sup>1</sup>, Fan Chenguang<sup>1,2</sup>, He An<sup>1</sup>, Wu Chuang<sup>1</sup>, Yang Yujing<sup>1</sup>

1. School of Mechanics and Aerospace Engineering, Southwest Jiaotong University, Chengdu, 610031, China;

2. Applied Mechanics and Structure Safety Key Laboratory of Sichuan Province, Chengdu, 610031, China

**Abstract:** In order to predict the buffer performance of hydraulic buffers of control rod assemblies by back-propagation (BP) neural network model improved by genetic algorithm (GA) and to realize the optimization of structural parameters. In this study, we simulated the falling rod in hydrostatic water for a specific control rod assembly hydrodynamic buffer. By changing the adjustable parameters of the test and setting up different test conditions, a large number of test data were obtained. The maximum impact force of control rod assembly in the process of rod falling was predicted by GA-BP neural network, and an optimized mathematical model was constructed. The nonlinear programming function (fmincon) is used to solve the problem, and a more optimal combination of structural parameters is obtained. The results show that the GA-BP neural network model has higher prediction accuracy compared with the BP neural network model, and the fmincon function can realize fast solution of the optimal mathematical model of the maximum impact force of the control rod assembly. Therefore, the optimization method in this paper can provide some reference for the structural optimization design of hydraulic buffers.

**Key words:** Control rod hydraulic buffer, Buffer performance test, Maximum impact force, GA-BP neural network, Parameter optimization

收稿日期: 2023-03-05; 修回日期: 2023-08-12

基金项目: 四川省自然科学基金面上项目 (2023NSFSC0068)

作者简介: 张相文 (1997—), 男, 硕士研究生, 现主要从事结构动力学研究, E-mail: 892807999@qq.com

## 0 引言

控制棒组件作为中子吸收体，在反应堆紧急停堆时快速落棒插入堆芯，实现反应堆安全停堆，其落棒性能对于核反应堆的安全性至关重要。控制棒组件缓冲结构是影响控制棒落棒性能的关键部件，其主要功能是减小控制棒组件落棒时对燃料组件等结构的落棒冲击力<sup>[1-2]</sup>，因此缓冲结构的设计是控制棒组件及控制棒驱动线设计的关键。在实际工程中，往往会通过理论计算或者试验的手段对落棒过程进行分析。理论计算可以考虑控制棒周身压强分布、控制棒与导向筒的摩擦力和碰撞力等复杂的物理机制对落棒过程的影响。张吉斌等<sup>[3]</sup>通过理论分析对一种特定结构的控制棒组件缓冲结构建立了简化模型和控制方程，并进行数值仿真分析计算，获得了控制棒组件流水孔数量、直径对落棒冲击力的影响规律。试验可以实现落棒过程的可视化，在保证试验系统可靠性的情况下，其结果更具有说服力。Lee 等<sup>[4]</sup>对概念设计的第四代钠冷快堆控制棒组件进行了跌落试验测试，以研究其跌落时间并验证了跌落分析方法。在此基础上，Son 等<sup>[5]</sup>根据跌落分析结果设计了实际尺寸的第四代钠冷快堆控制棒组件并进行了跌落性能测试，试验结果表明其落棒性能有所改进。李恬等<sup>[6]</sup>对控制棒落棒进行了模拟实验，结合实验数据分析了控制棒尾部流出孔径和初始周向位置对控制棒落棒缓冲效果的影响。典型的核电压水堆棒束型控制棒组件主要通过燃料组件导向管下部设有有一定长度的缩颈缓冲段来实现水力缓冲<sup>[7]</sup>。对小型压水堆而言，由于堆芯尺寸较小，控制棒组件落棒行程短、控制棒柔性差，可用于设置水力缓冲段的高度空间有限，若仍采用大型商用堆中常用的导向管小间隙水力缓冲，容易引起控制棒落棒不畅的问题。

由于压水型反应堆控制棒驱动线的结构形式类似，通常采用相似法基于经验数据来确定驱动线水力缓冲器的各个参数，再通过缓冲试验进行验证，根据试验结果对相关参数进行调整及优化。但对于结构形式差异较大的水力缓冲器，则无法通过类比法确定合理参数，仅靠试验进行验证及参数优化会消耗大量的经济成本和时间成本。由于控制棒组件水力缓冲器落棒的复杂性，其落棒冲击力受到流水孔层数、孔径、缓冲杯尺寸等多

个参数共同影响，各参数间又具有复杂的耦合关系，所以可将落棒冲击力问题看作是受多因素影响的非线性问题。反向传播（BP）神经网络是一种按误差反向传播训练的多层前馈网络，拥有很强的自我学习和非线性映射的能力，很适合求解多元非线性问题<sup>[8-9]</sup>。由于 BP 神经网络模型在实际应用中往往会出现训练时间较长、易陷入局部最小值等问题<sup>[10]</sup>，可通过遗传算法（GA）的全局范围内的搜索寻优功能对其进行改进，能克服 BP 神经网络算法本身的缺陷。相关研究表明，改进的 GA-BP 神经网络模型比 BP 神经网络模型具有更好的泛化能力和预测精度<sup>[11-13]</sup>。为了高效快速地研究优化问题，根据具体的研究对象可建立相应的优化数学模型，将工程实际问题用数学语言描述，再通过 Matlab 等数值计算软件或数学方法实现结构优化的求解<sup>[14-15]</sup>。

本文针对小型堆中空间窄小条件下的控制棒组件水力缓冲结构进行落棒缓冲试验，通过变换试验可调参数，提出可行的落棒缓冲方案，获得了神经网络训练所需样本，通过 GA 改进的 BP 神经网络模型对落棒冲击力进行预测，并构建优化数学模型，最后通过非线性规划函数（fmincon）实现对优化数学模型的求解，此种优化方法可为小型堆控制棒组件的优化改进提供一定的参考。

## 1 水力缓冲器模型

控制棒组件水力缓冲器结构如图 1 所示，主

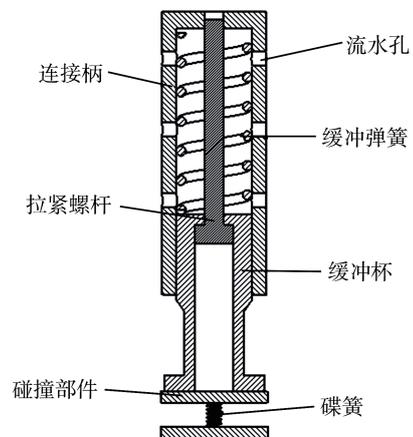


图 1 控制棒组件结构示意图

Fig. 1 Schematic Diagram of Control Rod Assembly Structure

要由连接柄、缓冲杯、拉紧螺杆、缓冲弹簧、碰撞部件组成。连接柄内部与缓冲杯之间安装有预紧缓冲弹簧,使得相对静止状态下二者紧密贴合,缓冲杯的活塞段与连接柄内壁配合形成环形缝隙,在连接柄侧面合适高度设置若干对称布置的小尺寸流水孔。其中碰撞部件包括弹性件(图1中碟簧)和碟簧底部的刚性件。

根据流体可压缩性很小的特点,利用流体被挤压所产生的压力,并结合缓冲弹簧的作用力,对构件产生运动阻力达到缓冲目的。工作时,控制棒组件结构一起从指定高度落下,碰撞时,缓冲杯底部先与碰撞部件接触,由碰撞部件底部的力传感器测得最大冲击力  $F_{\max}$ 。

## 2 试验平台搭建和数据获取

试验平台总体布置如图2所示。配重1为横梁,其套在立柱上以减少试验件上部结构的晃动并起导向作用;配重2为连接杆;配重3为减速棒,4根减速棒插入冲击板上的2×2孔洞中,辅助横梁以保证控制棒组件的落点范围;使用电磁铁(安装在落锤下端)来控制缓冲器的下落高度,试验平台在深圳万测 DIT603B 落锤冲击试验机基础上进行搭建。

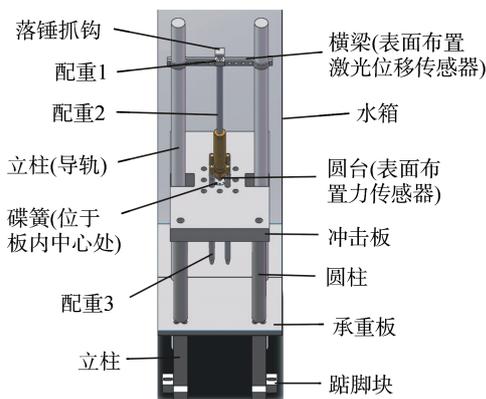


图2 试验平台搭建示意图

Fig. 2 Schematic Diagram of Test Platform Construction

所有试验均在室温常压静水中开展,每一方案至少进行3次后取均值,以避免系统误差的影响。整个试验过程中,控制棒组件可调整的参数如表1所示。

根据试验现象,大多数工况在试验过程中将经历2次较为明显的碰撞过程,第一次碰撞是缓

表1 控制棒组件可调参数

Tab. 1 Adjustable Parameters for Control Rod Assembly

参数	可调整的范围
第1层流水孔孔径/mm	0~4
第2层流水孔孔径/mm	0~4
第3层流水孔孔径/mm	0~4
第4层流水孔孔径/mm	0~4
第5层流水孔孔径/mm	0~4
连接柄与缓冲杯间隙/mm	0.15~0.30
缓冲杯行程/mm	30~70
弹簧刚度/(N·mm <sup>-1</sup> )	1.5~3.8
等效配重/kg	6.4~8.8
下落高度/mm	340~400

冲杯底部与力传感器之间的碰撞,第二次碰撞是缓冲杯与传感器接触后,连接柄继续下降到极限位置时与缓冲杯之间由于缓冲弹簧和水力缓冲作用形成的二次碰撞力,两者大小有所差异,在冲击力时程曲线中表现为双峰。在本文的研究中,选择2次碰撞之中峰值较大的冲击力作为  $F_{\max}$ 。根据可调参数,通过控制变量法提出可行性试验方案,试验测得参数变化引起的  $F_{\max}$  变化如图3所示(除流水孔层数以及位置变化对照组外,其他对照组的参数大小随试验编号增加而逐渐增大)。

图3a中,在流水孔层数对照组中发现流水孔开孔层数为3层(对应试验编号4)时,  $F_{\max}$  最小,流水孔孔径、缓冲杯的行程与间隙和  $F_{\max}$  之间不存在明显的单调关系;图3b中,随着弹簧刚度减小、等效配重以及下落高度的增大,  $F_{\max}$  呈变大趋势;图3c中,当每层流水孔的开孔孔径一致时,对比开2层流水孔与开3层流水孔位置变化的结果可以发现,当流水孔开孔层数更多时,  $F_{\max}$  更小。

## 3 预测模型研究

目前常用的建模方法主要分为机理建模和数据建模,数据建模是通过试验或生产数据来表达变量之间的相互关系。根据图3,本文选择对  $F_{\max}$  有影响的参数作为神经网络预测模型的输入变量,  $F_{\max}$  为输出目标,构建了基于BP和GA-BP神经网络的  $F_{\max}$  预测模型,并与真实的试验结果进行对比。

### 3.1 GA-BP神经网络的构建

本文取120组试验数据,用其中100组数据

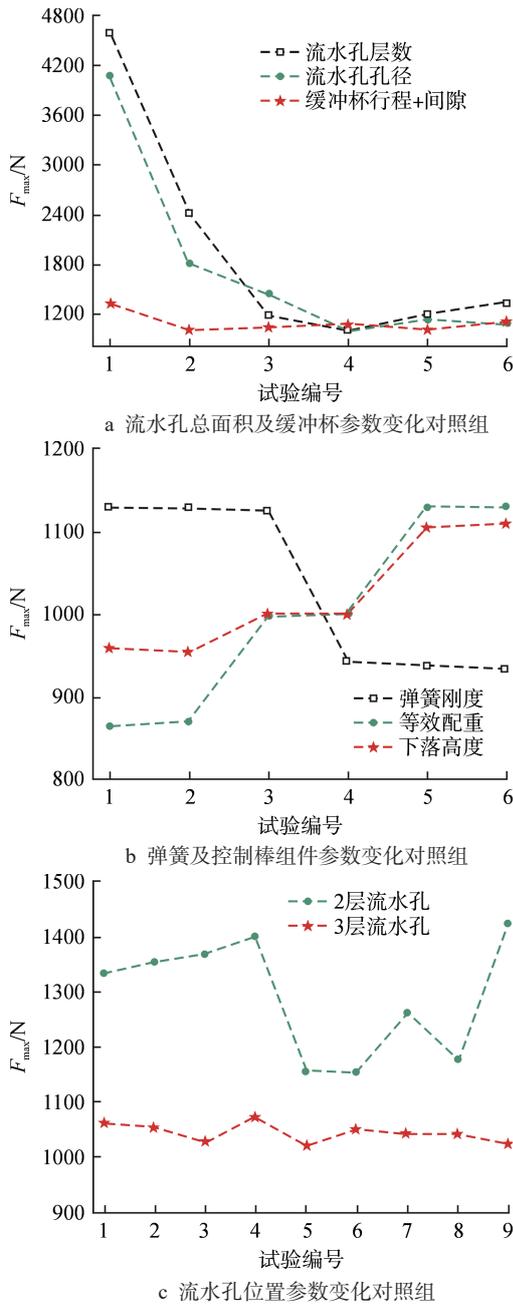


图3 参数改变对应的  $F_{max}$  变化图

Fig. 3 Plot of  $F_{max}$  Variation Corresponding to Parameter Change

集来拟合 GA-BP 神经网络，其中训练集、测试集、验证集占比为 70%、15%、15%，剩下 20 组数据集作为预测集，该预测集专门用来对比 BP 与 GA-BP 神经网络的预测误差。BP 神经网络相关参数设置为：训练函数采用 L-M 优化算法 trainlm，节点传递函数采用双极性 S 函数 tansig 和线函数 purelin，训练循环迭代次数为

1000，学习速率为 0.01，训练目标为 0.0001，归一化函数为 mapminmax，性能函数采用均方误差 (MSE)，隐含层节点数通过经验式 (1) 确定。

$$h = \sqrt{m+n} + a \quad (1)$$

式中， $h$  为隐含层节点的数目； $m$  和  $n$  分别是输入层和输出层节点的数目； $a$  为 1~10 之间的调节常数。

由于只要隐含层节点数量足够多，即可模拟任意非线性系统，本文选择单隐含层结构。通过计算，隐含层节点数对应训练集 MSE 如图 4 所示。

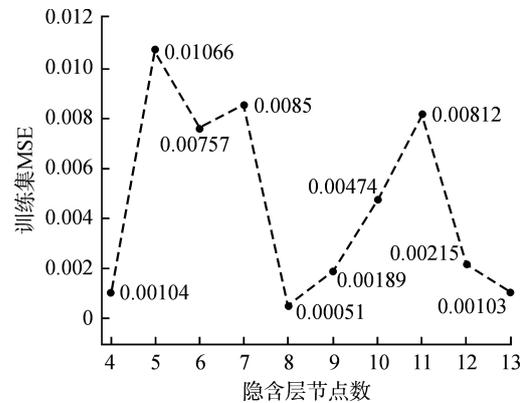


图4 隐含层节点数对应训练集 MSE 变化图

Fig. 4 MSE Variation Diagram of Training Set Corresponding to the Number of Hidden Layer Nodes

根据表 1 和图 4 可最终确定出 BP 和 GA-BP 神经网络的拓扑结构：输入层个数为 10，隐含层个数为 8，输出层个数为 1，输出为  $F_{max}$ 。

由于 BP 神经网络的初始权值和阈值是随机选取的，导致训练易陷入局部极小值，造成神经网络拟合能力和泛化能力不强，本研究采用 GA 将其改进，目的在于实现 BP 神经网络各层连接权值和阈值的最优值，摆脱 BP 神经网络对梯度信息的过度依赖。具体思路为：首先，将原 BP 神经网络的初始权重和阈值进行种群的初始化；然后，利用 GA 的选择、交叉和变异操作对种群不断进行淘汰选优；最后，获得 BP 神经网络的最佳连接权值和阈值。GA 相关参数中的初始种群规模为 100，最大进化代数 100，交叉概率为 0.8，变异概率为 0.2，自变量上限为 3，下限为 -3。

图 5 为控制棒组件 GA-BP 神经网络  $F_{max}$  误

差迭代曲线。从图中可以看出：该预测模型在训练进行了 13 次迭代后，训练误差和测试误差均达到目标值 0.0001，且曲线光滑，训练停止，说明训练的模型具有较好的拟合能力和泛化能力，虽然验证集没有达到误差目标值，但也非常接近，说明模型已接近全局最优。

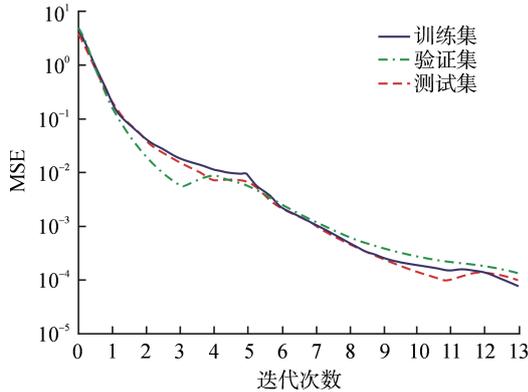


图 5 控制棒组件 GA-BP 神经网络  $F_{max}$  预测模型误差迭代曲线  
Fig. 5 Error Iteration Curves of Control Rod Assembly GA-BP Neural Network  $F_{max}$  Prediction Model

为了验证模型的稳定性和精度，本文采用平均绝对误差（MAE）、均方根误差（RMSE）、平均绝对百分比误差（MAPE）这 3 个指标对模型进行评价。模型的 MAE、MAPE 和 RMSE 值越小，说明模型的预测精度越高。相关公式如下：

$$MAE = \frac{\sum_{i=1}^p |y_i - \hat{y}_i|}{p} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^p (y_i - \hat{y}_i)^2}{p}} \quad (3)$$

$$MAPE = \sum_{i=1}^p \frac{|y_i - \hat{y}_i|}{y_i} \times \frac{100\%}{p} \quad (4)$$

式中， $y_i$  和  $\hat{y}_i$  分别为第  $i$  个点的实测值和预测值； $\bar{y}_i$  为实测值的平均值； $p$  为样本数。

### 3.2 预测结果与对比分析

图 6、图 7 分别展示了  $F_{max}$  预测值与真实值的对比及 GA-BP 与 BP 神经网络模型的误差对比情况。不难看出，GA-BP 的预测效果比 BP 更好，GA-BP 的预测误差多集中在  $\pm 4\%$  以内，而 BP 的预测误差多集中在  $\pm 8\%$  以内。

表 2 中列出了 MAE、MAPE 和 RMSE 的数

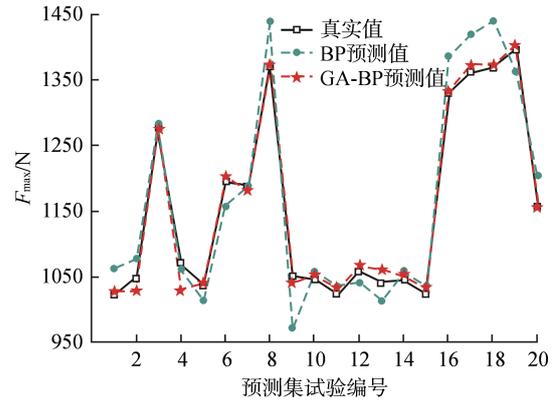


图 6 预测值与真实值的对比图  
Fig. 6 Comparison between Predicted and Actual Values

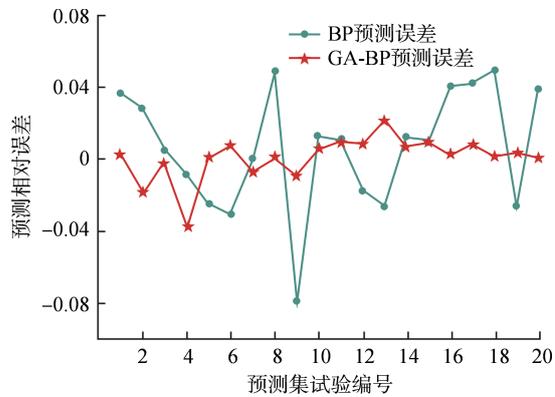


图 7 GA-BP 与 BP 神经网络的预测误差对比图  
Fig. 7 Comparison of Prediction Errors between GA-BP and BP Neural Network

值大小，可直观地发现 GA-BP 神经网络模型各类误差相对于 BP 神经网络模型都能大幅降低，提高了神经网络模型的预测精度。

表 2 BP 与 GA-BP 神经网络模型的预测结果误差  
Tab. 2 Errors in Prediction Results of BP and GA-BP Models

神经网络模型	MAE/N	MAPE/%	RMSE/N
BP	39.51	3.35	55.10
GA-BP	9.29	0.82	11.58

图 8 所表示的是在保证流水孔的总过流面积一致的情况下，改变流水孔的开孔层数所代表的工况，可见无论是 BP 还是 GA-BP 神经网络模型，二者的预测趋势是一致的，只不过 GA-BP 神经网络模型的预测效果要稍优于 BP 神经网络模型。

图 9、图 10 表示的是在保证流水孔的开孔尺寸大小和数量一致的情况下，在 5 层流水孔中

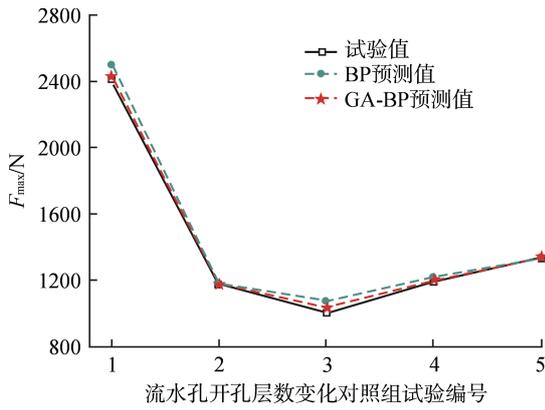


图 8 流水孔开孔层数变化预测对比图

Fig. 8 Comparison of Predicted Change in the Number of Layers of Running Water Hole

调整流水孔的开孔位置所代表的工况，可见除了部分工况的 BP 预测结果有较大的差异外，其余工况的 BP 及 GA-BP 的预测结果都与真实的试验

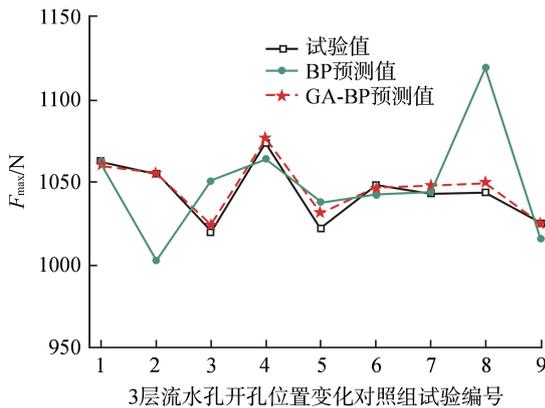


图 9 3层流水孔位置变化对照组预测对比图

Fig. 9 Prediction Comparison of 3 Layers of Running Water Hole Position Change Control Group

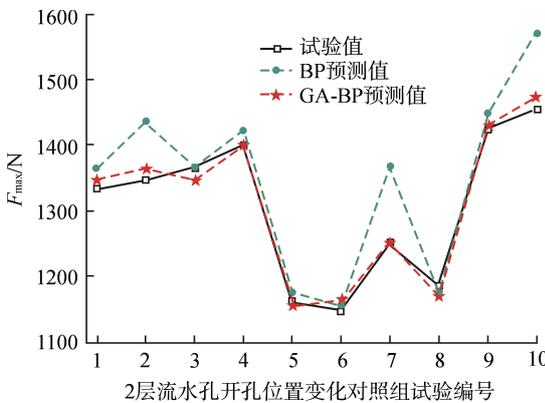


图 10 2层流水孔位置变化对照组预测对比图

Fig. 10 Prediction Comparison of 2 Layers of Running Water Hole Position Change Control Group

结果对应较好，但是从整体上来看，GA-BP 神经网络模型的预测效果还是优于 BP 神经网络模型。

图 11 所表示的是在只开 3 层流水孔的情况下，改变这 3 层流水孔的开孔尺寸所对应的工况，可见 BP 和 GA-BP 神经网络模型对多数工况的预测还是较为准确的，只在少部分工况下，GA-BP 模型的预测效果要优于 BP 模型。

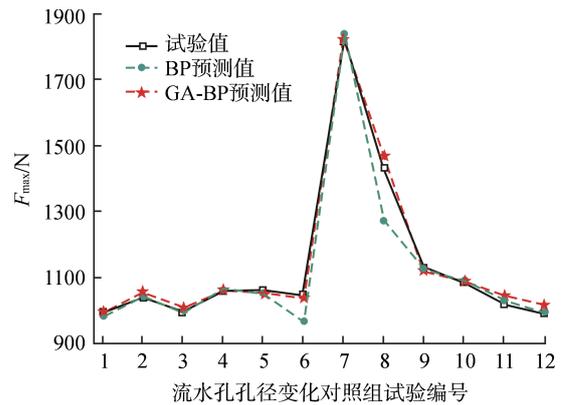


图 11 流水孔孔径变化预测对比图

Fig. 11 Prediction Comparison of Running Water Hole Diameter Change

#### 4 基于 GA-BP 神经网络模型的参数优化

长期以来，结构设计和优化往往是根据设计者的经验完成。考虑到优化方案的准确性和优化效率，本文通过 GA 改进的 BP 神经网络模型来近似表达控制棒结构参数与性能参数间的关系，利用其构建了控制棒组件  $F_{max}$  优化数学模型的目标函数，求解后获得更优的控制棒组件结构参数组合。

##### 4.1 设计变量

由于优化数学模型中的目标函数会用到神经网络模型，故优化设计变量需和神经网络数据集的输入样本保持一致。选取 5 层流水孔大小 ( $x_1 \sim x_5$ )、缓冲杯行程 ( $x_6$ )、间隙 ( $x_7$ )、控制棒组件的配重 ( $x_8$ )、下落高度 ( $x_9$ ) 和缓冲弹簧刚度 ( $x_{10}$ ) 作为优化数学模型的设计变量，可表示为：

$$x = (x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}) \quad (5)$$

##### 4.2 目标函数

在控制棒组件落棒时需减小对燃料组件的落棒冲击力，因此，在满足控制棒组件物理参数的

尺寸条件下,选择  $F_{\max}$  作为目标函数,其中  $F_{\max}$  由 GA-BP 神经网络的  $F_{\max}$  预测模型预测得出。

$$f(x) = F_{\max} \quad (6)$$

#### 4.3 约束条件

控制棒组件优化数学模型的约束条件为:

$$\begin{cases} 0 \text{ mm} \leq x_1, x_2, x_3, x_4, x_5 \leq 4 \text{ mm} \\ 30 \text{ mm} \leq x_6 \leq 70 \text{ mm} \\ 0.15 \text{ mm} \leq x_7 \leq 0.3 \text{ mm} \\ 6.4 \text{ kg} \leq x_8 \leq 8.8 \text{ kg} \\ 340 \text{ mm} \leq x_9 \leq 400 \text{ mm} \\ 1.5 \text{ N/mm} \leq x_{10} \leq 3.8 \text{ N/mm} \end{cases} \quad (7)$$

综上,本文的优化问题是在满足相关约束条件的前提下,通过调整设计变量,使得控制棒组件的  $F_{\max}$  最小。因此,控制棒组件的优化数学模型为:

$$\begin{cases} \text{find} & x = (x_1, x_2, \dots, x_{10}) \\ \text{min} & f(x) = F_{\max} \\ \text{s.t.} & 0 \text{ mm} \leq x_1, x_2, x_3, x_4, x_5 \leq 4 \text{ mm} \\ & 30 \text{ mm} \leq x_6 \leq 70 \text{ mm} \\ & 0.15 \text{ mm} \leq x_7 \leq 0.3 \text{ mm} \\ & 6.4 \text{ kg} \leq x_8 \leq 8.8 \text{ kg} \\ & 340 \text{ mm} \leq x_9 \leq 400 \text{ mm} \\ & 1.5 \text{ N/mm} \leq x_{10} \leq 3.8 \text{ N/mm} \end{cases} \quad (8)$$

#### 4.4 控制棒组件水力缓冲器结构参数优化结果

该优化问题属于单目标有约束的非线性规划问题,采用 fmincon 函数对控制棒组件优化数学模型进行求解,该函数的调用形式为<sup>[16]</sup>:

$$\begin{aligned} & [x, fval, \text{exitflag}] \\ & = \text{fmincon}(\text{fun}, x_0, \mathbf{A}, \mathbf{b}, \mathbf{A}_{\text{eq}}, \mathbf{b}_{\text{eq}}, \mathbf{l}_b, \mathbf{u}_b) \end{aligned} \quad (9)$$

式中,  $x$  为优化的最优解;  $fval$  为  $x$  点处的目标函数值;  $\text{exitflag}$  为判断程序终止的原因;  $\text{fun}$  为目标函数;  $x_0$  为优化的初始点,本文选择基准工况;  $\mathbf{A}$  为不等式约束的系数矩阵;  $\mathbf{b}$  为不等式约束的右侧向量;  $\mathbf{A}_{\text{eq}}$  为等式约束的系数矩阵;  $\mathbf{b}_{\text{eq}}$  为等式约束的右侧向量;  $\mathbf{l}_b$  为设计变量  $x$  的下边界;  $\mathbf{u}_b$  为设计变量  $x$  的上边界。

本文的  $\mathbf{A}$ 、 $\mathbf{b}$ 、 $\mathbf{A}_{\text{eq}}$  均为空阵,  $x$ 、 $x_0$ 、 $\mathbf{l}_b$ 、 $\mathbf{u}_b$  为向量,  $\text{fun}=F_{\max}$  (由 GA-BP 神经网络模型预测得出)。通过调用 GA-BP 神经网络模型的 .mat 文件构建优化数学模型,利用 fmincon 函数进行求解,可求得优化结果为:

$$x = (2.44, 2.32, 2.41, 2.67, 2.86, 49.72, 0.23, 6.4, 340, 2.14)$$

$$fval = 682.47 \text{ N}$$

如果需要实现控制棒组件在特定条件下的优化,可对某一约束条件进行限定。比如限定下落高度为 370 mm,保持其他条件不变,将式(8)中的  $340 \text{ mm} \leq x_9 \leq 400 \text{ mm}$  改为  $x_9=370 \text{ mm}$ ,再利用函数对修改后的控制棒组件优化数学模型进行求解,可得优化结果为:

$$x = (2.32, 2.29, 2.47, 2.66, 2.96, 49.79, 0.25, 6.4, 370, 2.46)$$

$$fval = 818.62 \text{ N}$$

针对该优化结果,需再次通过试验验证,在一定程度上能提高优化方案的准确性和优化效率。

## 5 结论

本文通过控制棒组件水力缓冲器落棒试验获得了落棒冲击力试验数据,以试验数据为样本,通过神经网络预测该水力缓冲器的落棒冲击力,利用 GA-BP 神经网络构建其优化数学模型,并通过优化算法进行求解,实现了对控制棒组件水力缓冲器缓冲性能的快速优化,得到以下结论:

(1) 利用 GA 对 BP 神经网络进行改进,分别用 BP 及 GA-BP 神经网络模型对控制棒组件的  $F_{\max}$  进行预测,发现 GA-BP 神经网络模型预测误差多集中在  $\pm 4\%$  以内, BP 神经网络模型的预测误差多集中在  $\pm 8\%$  以内,因此,GA-BP 神经网络模型的预测精度更高,更能满足实际需求。

(2) 利用训练好的 GA-BP 神经网络模型来构建控制棒组件水力缓冲器的  $F_{\max}$  优化数学模型,通过 fmincon 函数实现了对该水力缓冲器的快速求解,为实际工程上的控制棒组件水力缓冲器优化问题提供了一定的理论参考依据。

#### 参考文献:

- [1] 颜达鹏,杜华,刘佳,等.控制棒驱动线缓冲结构碰撞缓冲过程分析方法[J].核动力工程,2017,38(S2):64-69.
- [2] 段春辉,王留兵,杜华,等.控制棒驱动线水力缓冲特性仿真研究[J].机床与液压,2015,43(22):73-76,90.
- [3] 张吉斌,李垣明,黄春兰,等.控制棒组件缓冲结构缓冲设计方法研究[J].中国核电,2021,14(1):35-39.

- [4] LEE Y K, LEE J H, KIM H W, et al. Drop performance test of conceptually designed control rod assembly for prototype generation IV sodium-cooled fast reactor[J]. *Nuclear Engineering and Technology*, 2017, 49(4): 855-864.
- [5] SON J G, LEE J H, KIM H W, et al. Influence of design modification of control rod assembly for prototype generation IV sodium-cooled Fast Reactor on drop performance[J]. *Nuclear Engineering and Technology*, 2019, 51(3): 922-929.
- [6] 李恬, 魏炳乾, 黎闫, 等. 控制棒下行运动特性影响因素分析[J]. *核动力工程*, 2022, 43(1): 127-132.
- [7] 肖忠, 马超, 郭晓明. 燃料组件结构参数对于控制棒组件落棒缓冲效果的敏感性分析[J]. *核动力工程*, 2016, 37(5): 111-114.
- [8] SIMPSON T W, POPLINSKI J D, KOCH P N, et al. Metamodels for computer-based engineering design: survey and recommendations[J]. *Engineering With Computers*, 2001, 17(2): 129-150.
- [9] SIMPSON T W, BOOKER A J, GHOSH D, et al. Approximation methods in multidisciplinary analysis and optimization: a panel discussion[J]. *Structural and Multidisciplinary Optimization*, 2004, 27(5): 302-313.
- [10] 余本国. BP神经网络局限性及其改进的研究[J]. *山西农业大学学报: 自然科学版*, 2009, 29(1): 89-93.
- [11] 吴天山, 于鸿彬, 李小青, 等. 基于遗传算法的BP神经网络熔融沉积成型翘曲变形预测研究[J]. *热加工工艺*, 2019, 48(22): 48-52.
- [12] XING Y H, LI F F. Research on the influence of hidden layers on the prediction accuracy of GA-BP neural network[J]. *Journal of Physics:Conference Series*, 2020, 1486(2): 022010.
- [13] 魏雨晨, 李旭东, 刘治国, 等. 基于GA-BP神经网络的航空铝合金预腐蚀疲劳寿命预测[J]. *环境技术*, 2022, 40(5): 178-182,205.
- [14] 熊伟. 基于改进BP神经网络的车床主轴优化设计的研究[D]. 镇江: 江苏大学, 2016.
- [15] 郭春艳. 基于改进BP神经网络的板弹簧优化设计[D]. 成都: 西南交通大学, 2021.
- [16] 曹保金, 秦小屿. MATLAB优化工具箱在机械优化设计中的应用[J]. *现代机械*, 2009(6): 11-13.

(责任编辑: 梁超)