

## 基于改进BP神经网络的节流孔板空化特性预测

张宇, 孙磊, 何超, 袁少波

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

Zhang Yu, Sun Lei, He Chao, and Yuan Shaobo

在线阅读 View online: <https://doi.org/10.13832/j.jnpe.2021.06.0135>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 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

#### 波形板壁面液膜的神经网络及混沌特性分析

Neural Network and Chaotic Characteristics Analysis of Water Film on Corrugated Plate Wall

核动力工程. 2020, 41(4): 60–63

#### 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

#### 摇摆条件对船用核动力装置凝结水射流泵空化特性影响数值研究

Numerical Study on Effect of Ocean Conditions on Jet Pump Cavitation Characteristics for Marine Nuclear Power Plants

核动力工程. 2019, 40(5): 135–139

#### 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



关注微信公众号, 获得更多资讯信息

文章编号: 0258-0926(2021)06-0135-06; doi:10.13832/j.jnpe.2021.06.0135

# 基于改进 BP 神经网络的节流孔板空化特性预测

张 宇, 孙 磊\*, 何 超, 袁少波

中国核动力研究设计院, 成都, 610213

**摘要:** 为高效地获取核级管道中节流孔板附近的空化特性, 构建了可靠的改进反向传播 (BP) 神经网络预测模型。首先提取了节流孔板的几何特征参数, 并使用拉丁超立方抽样 (LHS) 方法生成了上述几何特征参数的样本库; 然后通过计算流体力学 (CFD) 方法得到了各个样本对应的最小空化数, 以该无量纲参数作为输出响应; 最后针对原始 BP 神经网络预测模型的不足, 结合遗传算法建立了节流孔板空化特性的改进预测模型。结果表明, 孔板开孔直径和前开角度对最小空化数具有较强的全局敏感度; 通过遗传算法优化后的 BP 神经网络预测模型的预测精度得到了大幅提升, 误差均方根降低约 36.4%。

**关键词:** 节流孔板; 空化; 计算流体力学 (CFD); 反向传播 (BP) 神经网络; 遗传算法

**中图分类号:** TL353<sup>+</sup>.11; O351 **文献标志码:** A

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

Zhang Yu, Sun Lei\*, He Chao, Yuan Shaobo

Nuclear Power Institute of China, Chengdu, 610213, China

**Abstract:** In order to obtain the cavitation characteristics near throttle orifice plate in nuclear pipeline efficiently, a reliable improved backpropagation (BP) neural network prediction model was constructed. Firstly, the geometric feature parameters of the throttle orifice plate were extracted, and the sample data base of these parameters was generated by using the Latin Hypercube Sampling approach. Then, the minimum cavitation number corresponding to each sample is obtained by computational fluid dynamics (CFD) method, and the dimensionless parameter is used as the output response. Finally, in view of the deficiency of the original BP neural network prediction model, an improved prediction model of throttle orifice plate cavitation characteristics is established by combining genetic algorithm. The results show that the orifice diameter and front opening angle have strong global sensitivity to the minimum cavitation number; the prediction accuracy of the BP neural network prediction model optimized by genetic algorithm has been greatly improved, and the root mean square error is reduced by about 36.4%.

**Key words:** Throttle orifice plate, Cavitation, Computational Fluid Dynamics (CFD), Backpropagation (BP) Neural network, Genetic algorithm

## 0 引 言

节流孔板是一种常见于核级管道的装置, 其主要作用是限制或调节管道流量。常见的节流孔板

具有倒角特征, 即在圆孔的锋利边缘上进行切削形成较为平滑的过渡段。但当节流孔板设计不合理时, 会出现过度节流现象, 引发孔板附近局部压

收稿日期: 2020-09-09; 修回日期: 2021-05-27

作者简介: 张 宇 (1996—), 男, 研究实习生, 现主要从事反应堆结构流致振动研究, E-mail: 1532010457@qq.com

\*通讯作者: 孙 磊, E-mail: SUNLEI\_SL1@163.com

力过低, 导致管道内流空化。空化强度一般以空化数进行量化, 空化伴随的气泡产生和湮灭, 会对管壁造成高频激励, 长期的高频激励可诱发管道结构的疲劳断裂<sup>[1]</sup>。因此对节流孔板空化特性的高效、精准预测, 对保证核级管道安全具有重要意义。

针对节流孔板空化的核级管道超限振动问题, 袁少波等<sup>[2]</sup>结合现场可实施性, 通过计算流体力学 (CFD) 手段对十余种孔板组合进行了数值模拟并确定了改造方案, 现场结果反馈改造作用明显。节流孔板空化问题可以看成一种具有“输入-输出”的系统, “输入”为孔板的几何外形参数, “输出”为流场中的最小空化数。可以预见的是, 对于这种管道内流空化问题, 几乎不可能找出“输入”与“输出”的明确数学关系。而随着人工智能的不断发展, 有望从更底层的数据关系提炼出节流孔板外形参数与内流空化特性的联系, 从而高效准确地针对空化特性进行更进一步的改造。

本文借助反向传播 (BP) 神经网络方法搭建了对节流孔板空化特性预测的数学模型, 对于较难确定的隐含层层数、层间权值和层间阈值, 使用遗传算法进行全局优化寻值。模型所需的训练数据库和验证数据库通过拉动超立方抽样结合 CFD 方法得到。

## 1 方法介绍

本节介绍使用的 CFD 方法、拉丁超立方抽样 (LHS) 原理、BP 神经网络拓扑结构和遗传算法, 并给出本研究的计算流程。

### 1.1 流体控制方程

对于三维不可压缩的流场物理量可通过求解守恒形式的纳维-斯托克斯 (N-S) 方程得到:

$$\frac{\partial}{\partial t} \iiint_{\Omega} \rho \mathbf{Q} dV + \iint_{\partial\Omega} \mathbf{F} \cdot \mathbf{n} ds = 0 \quad (1)$$

式中,  $t$  为时间;  $\mathbf{Q}$  为包含场速度的解矢量;  $dV$  表示控制体  $\Omega$  中的微元;  $\partial\Omega$  为控制体  $\Omega$  的边界;  $\mathbf{F}$  为对流矢量通量与黏性矢量通量的差;  $\mathbf{n}$  为流体域边界的外法矢量;  $ds$  表示  $\partial\Omega$  上的微元。

要求解式 (1), 需引入湍流模型对方程进行封闭。相较于其他湍流模型, 标准  $k-\varepsilon$  模型已被证明能很好地模拟内流流动, 且对计算资源的需求较为适中<sup>[3]</sup>。湍流模型的控制方程为:

$$\begin{aligned} \frac{\partial}{\partial t} (\rho k) + \nabla \cdot (\rho k \mathbf{u}) &= \nabla \cdot \left[ \left( \mu + \frac{\mu_t}{\sigma_k} \right) \nabla \cdot k \right] + \\ G_k + G_b - \rho \varepsilon - Y_M \end{aligned} \quad (2-1)$$

$$\begin{aligned} \frac{\partial}{\partial t} (\rho \varepsilon) + \nabla \cdot (\rho \varepsilon \mathbf{u}) &= \nabla \cdot \left[ \left( \mu + \frac{\mu_t}{\sigma_\varepsilon} \right) \nabla \cdot \varepsilon \right] + \\ C_{1\varepsilon} \frac{\varepsilon}{k} (G_k + C_{3\varepsilon} G_b) - C_{2\varepsilon} \rho \frac{\varepsilon^2}{k} \end{aligned} \quad (2-2)$$

式中,  $\rho$  为密度;  $\mathbf{u}$  为速度矢量;  $\mu$  为流体黏度;  $\mu_t$  为湍流黏度;  $G_k$  表示由平均速度梯度引起的湍动能;  $G_b$  表示由浮力引起的湍动能;  $Y_M$  代表可压缩湍流中波动膨胀对总耗散率的贡献;  $\sigma_k$  和  $\sigma_\varepsilon$  分别为湍动能  $k$  和耗散率  $\varepsilon$  的湍流普朗特数;  $C_{1\varepsilon}$ 、 $C_{2\varepsilon}$ 、 $C_{3\varepsilon}$  为常数, 其取值详见文献 [4]。

对于管内流动, 一般根据基于管道直径的雷诺数 ( $Re$ ) 判断其是否为湍流状态,  $Re$  定义为:

$$Re = \frac{\rho U D_p}{\mu} \quad (3)$$

式中,  $U$  为管道来流速度;  $D_p$  为管道直径。

在获取流场内的压力和速度等物理量之后, 即可求得空化数 ( $\sigma$ ),  $\sigma$  定义为:

$$\sigma = \frac{p - p_v}{0.5 \rho v^2} \quad (4)$$

式中,  $p$  为当地绝对压力;  $p_v$  为饱和蒸汽压;  $v$  为当地流体速度。可见空化数越小则越容易出现空化, 因此需要着重关注流场中最小空化数  $\sigma_{\min}$ 。

### 1.2 LHS

LHS 是一种分层随机抽样方法, 其基本原理是将每个参数区间均匀等分成  $N$  个小区间, 再从每个小区间里随机生成一个值, 并保证在每个小区间内有且只有一个值, 这样可以避免产生样本聚集现象, 最大程度地覆盖参数区间边缘, 使样本更具代表性。

如假设有 2 个变量  $x_1$  和  $x_2$ , 其区间范围分别为  $[0, 0.6]$  和  $[0, 1]$ , 现从这 2 个变量区间中取出 3 组 ( $N=3$ ) 随机数, 图 1a 显示了上述情况取样原理。图 1b 中令  $N=200$ , 可以看到使用 LHS 方法得到的随机数组合具有良好的覆盖率。

### 1.3 BP 神经网络结构

BP 神经网络具有前馈特点, 信号从后向前传递, 误差从后向前传递。BP 神经网络的拓扑结构如图 2 所示, 原始信号从输入层经过隐含层传递至输出层, 在层与层之间存在权重和阈值, 根据预测值和真实值间的差距不断调整权重和阈值, 使得 BP 神经网络模型的精度得到提升。

上述 BP 神经网络拓扑结构的运行原理如下:

(1) 初始化拓扑结构。由于输入参数和输出参数的个数依赖所研究的问题, 因此输入层神经

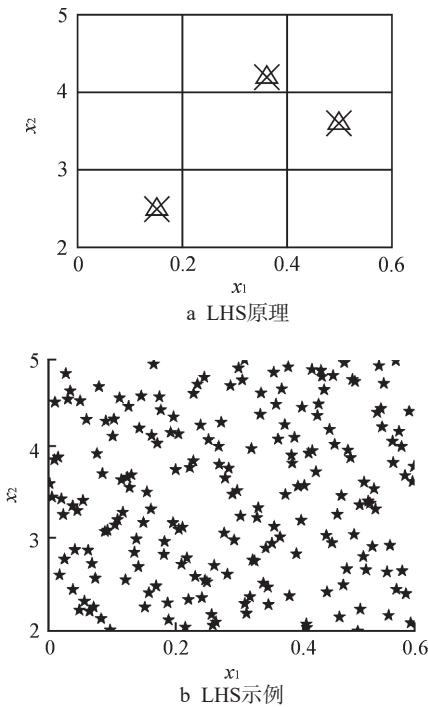


图 1 LHS 原理及示例

Fig. 1 Principle and Example of LHS

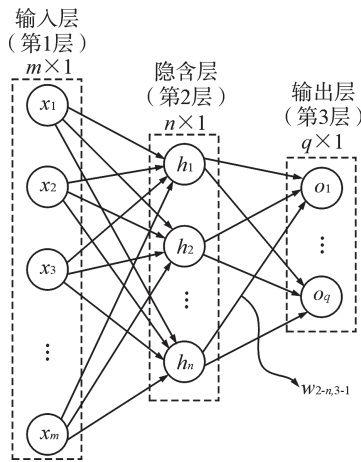


图 2 BP 神经网络拓扑结构

Fig. 2 Topology Structure of BP Neural Network

$m$ —输入层神经元数，即输入参数的个数； $n$ —隐含层神经元数； $q$ —输出层神经元数； $w_{2-n,3-1}$ —从第 2 层的第  $n$  个神经元到第 3 层的第 1 个神经元的权值； $x_1, \dots, x_m$ —输入层输入量的分量； $h_1, \dots, h_n$ —隐含层输出量的分量； $o_1, \dots, o_q$ —输出层输出量的分量

元数  $m$  和输出层神经元数  $q$  为已知量。待初始化的参数有输入层到隐含层的权值  $w_{ij,2}$  和阈值  $b_{j,2}$ 、 $n$ 、隐含层到输出层的权值  $w_{jl,3}$  和阈值  $b_{l,3}$ 、学习率  $\lambda$  和隐含层激活函数  $\delta$ ，其中  $i, j$  和  $l$  均表示计数变量。

(2) 计算隐含层输出量。通过步骤 (1) 中确定的参数，由下式可得：

$$h_j = \delta \left( \sum_{i=1}^m w_{ij,2} x_i - b_{j,2} \right), j = 1, 2, \dots, n \quad (5)$$

隐含层激活函数的形式为：

$$\delta(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

(3) 计算输出层输出量。通过步骤 (2) 得到的隐含层输出量与相关权值和阈值，输出层输出量由下式获得：

$$o_l = \sum_{j=1}^n w_{jl,3} h_j - b_{l,3}, l = 1, 2, \dots, q \quad (7)$$

(4) 计算误差。由步骤 (3) 所得预测值  $o_l$  与真实值  $r_l$  进行比较，获得预测误差  $e_l$  为：

$$e_l = r_l - o_l \quad (8)$$

(5) 更新权值与阈值。根据所得预测误差校正各层权值，更新格式采取 Levenberg-Marquardt 算法。

(6) 收敛判断。一般通过误差均方根值  $e_{rms}$  或更新次数进行收敛判断，当误差均方根值小于规定值或更新次数达到上限则认为拓扑结构搭建完成，否则返回步骤 (2)。

从以上步骤可知，得到 BP 神经网络拓扑结构的难点在于确定合适的权值、阈值、隐含层神经元数和学习率。传统的 BP 神经网络模型只对权值和阈值进行更新，而相关研究表明隐含层层数及学习率对预测精度有较大影响<sup>[5]</sup>。因此本文结合遗传算法对上述重要参数先进行全局优化，在此基础上建立 BP 神经网络拓扑结构。

### 1.4 遗传算法

遗传算法借鉴自然界中生物的遗传进化过程，通过选择、遗传和变异等机制对目标函数进行优化。遗传算法的基本步骤是：①将待优化的输入参数（基因）的集合视为染色体（个体）并对其编码，个体对应的目标函数值称为适应度，并随机生成多个个体（称为种群）；②通过选择、交叉和变异操作对个体进行筛选，适应度较高的个体被保留，适应度较低的个体被淘汰，该过程称为“进化”；③经过有限次数的“进化”，适应度达到收敛状态，提取对应的个体即可获得最优参数。

假设存在一具有  $N$  个输入参数的系统  $f(\mathbf{z})=\mathbf{z}$ ， $\mathbf{z}=[z_1, z_2, \dots, z_N]$ ，其个体即为  $\mathbf{z}$ ， $z_i (i=1, 2, \dots, N)$  即为基因，种群数记为  $M$ ，个体构成的种群记为  $P$ 。使用遗传算法对该系统进行优化的步骤为：

(1) 初始化。设置初始优化迭代步数  $g=0$ ，

根据系统特点设置最大优化次数  $G$ ，由编码规则随机生成  $M$  个个体作为初始种群  $P(0)$ 。

(2) 适应度评价。通过系统输出量  $f$  与个体  $z$  之间的关系，计算种群  $P(g)$  中各个个体的适应度。

(3) 选择操作。根据步骤 (2) 中的适应度选择表现良好的个体保留在种群中。

(4) 交叉操作。对被保留的个体，以一定概率将成对个体的基因进行交换，以产生新的个体。

(5) 变异操作。对被保留的个体，以一定概率改变某一个或几个基因，这也将产生新的个体。

(6) 种群重构。经过步骤 (3)~(5) 的操作后，产生新的种群  $P(g)$ ，重新计算适应度并根据适应度对个体进行排序。

(7) 收敛判断。若  $g < G$ ，则  $g = g + 1$ ，并转至步骤 (2)；若  $g = G$ ，则选择步骤 (6) 种群中适应度最大的个体输出，优化结束。

### 1.5 计算流程

文中的流场计算在 ANSYS Fluent 平台上进行，BP 神经网络拓扑结构和遗传算法通过 Matlab 脚本语言构建，本文计算流程见图 3。

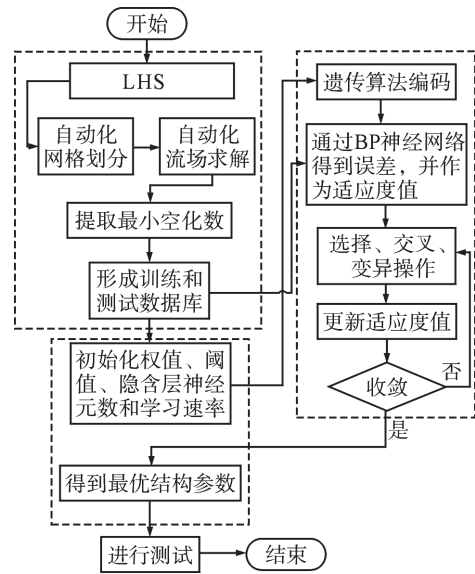


图 3 计算流程

Fig. 3 Calculation Process




图 4 节流孔板结构

Fig. 4 Structure of Throttle Orifice Plate

$D_p$ —孔直径； $t_s$ —孔板厚度； $t_f$ —孔板平直段厚度； $\alpha$ 和 $\beta$ —孔板前、后开角

## 2 CFD 方法验证

### 2.1 几何及网格

节流孔板的剖面结构见图 4，孔板被插入 2 段管道之间，然后通过法兰和紧固螺栓进行连接。

固定  $D_p$  和  $t_s$ ，由此可提取如下几何特征参数：

$$\begin{cases} \xi_1 = D_f/D_p \\ \xi_2 = t_f/t_s \\ \xi_3 = \alpha/\pi \\ \xi_4 = \beta/\pi \end{cases} \quad (9)$$

上述几何和特征参数的取值及范围见表 1。

由于节流孔板具有轴对称几何特点，故只需建立如图 5 所示的二维轴对称模型。其中上游长度为  $8D_p$ ，下游长度为  $20D_p$ ，入口边界为速度入口，出口边界为压力出口（表压为 0 Pa），节流孔板与管壁均被视为无滑移壁面。经网格无关性验证后，某一形状节流孔板附近的流体域网格见图 6，此时的网格单元总量为 31200，最小正交质量为 0.753。

### 2.2 可靠性验证

为验证本文计算方法的可靠性，与文献 [6] 中的算例结果进行了对比。其  $D_p=12.3$  mm， $t_s=2.0$  mm，孔板几何特征参数为  $\xi_i=[0.407, 0.5, 0,$

表 1 参数信息

Tab. 1 Parameters Information

参数名	参数值范围	均值	初始值
$D_p/\text{mm}$	180.3	180.3	180.3
$t_s/\text{mm}$	10	10	10
$\xi_1$	0.1~0.7	0.4	0.407
$\xi_2$	0.2~0.8	0.5	0.5
$\xi_3$	0.1~0.4	0.25	0
$\xi_4$	0.1~0.4	0.25	0

0],  $U=0.75$  m/s。

计算得到孔板下游截面 A、B 和 C 处的轴向速度分布，并与文献 [6] 中的结果进行对比，其中截面 A 距离原点 2.0 mm，截面 B 距离原点 12.0 mm，截面 C 距离原点 22.0 mm。如图 7 所示，由本文计算方法所得的轴向速度分布与文献 [6] 十分接近，最大相对误差为 4.3%。因此文




图 5 二维轴对称计算域

Fig. 5 Computational Domain with 2D Axis-Symmetry




图 6 计算域网格

Fig. 6 Grid of Computational Domain




图 7 不同截面处的轴向速度曲线

Fig. 7 Axial Velocity Curves at Different Cross Sections

中 CFD 模型是合理且可靠的，可以进行后续研究。

### 3 结果和讨论

以 40℃ 的水作为流体介质，其密度  $\rho=992 \text{ kg/m}^3$ ，运动黏度  $\mu=0.000673 \text{ Pa}\cdot\text{s}$ ，饱和蒸汽压  $p_v=7380 \text{ Pa}$ 。取来流  $Re=1.0\times 10^5$ ，由式 (3) 可知，对应的管道来流速度  $U=0.3763 \text{ m/s}$ ，管道入口湍流强度为 3.8%。设置 LHS 样本总数为 1000，随机选取其中 900 组样本作为训练数据库，余下 100 组样本作为验证数据库。

#### 3.1 特征参数与空化数关系

经 LHS 和 CFD 计算得到 1000 组样本数据，本节首先对这 1000 组样本进行分析。图 8 显示了几何特征参数  $\xi_i$  关于最小空化数  $\sigma_{\min}$  的敏感度情况，敏感度反映了“输入”与“输出”之间的关联强度。图中的敏感度分为局部和全局敏感度，全局敏感度包含了“输入”参数之间的耦合效应对“输出”的影响。对全局敏感度而言， $\xi_1$  和  $\xi_3$  (对

应开孔直径和孔板前开角度) 对最小空化数  $\sigma_{\min}$  影响程度较高，其全局敏感度分别为 75.6% 和 15.4%。其余参数对最小空化数  $\sigma_{\min}$  具有相对弱的影响。




图 8 几何特征参数的敏感度

Fig. 8 Sensitivities of Geometric Feature Parameters

#### 3.2 未改进预测模型

对于未改进的预测模型，BP 神经网络拓扑结构中的隐含层神经元数  $n$  和学习率  $\lambda$  只能人为指定，在此指定  $n=5$ ， $\lambda=0.40$ 。设定更新次数上限为 100。未改进预测模型关于拓扑结构中的权值和阈值如下：

$$w_2 = \begin{bmatrix} 0.062 & 0.695 & -4.105 & 2.209 \\ -0.550 & 0.954 & -4.011 & 0.035 \\ -2.944 & 0.042 & 0.034 & 0.002 \\ -0.329 & -0.927 & 4.278 & -0.078 \\ -0.459 & 1.205 & 0.289 & 4.280 \end{bmatrix}$$

$$b_2 = \begin{bmatrix} 3.377 \\ -1.263 \\ 3.161 \\ 0.823 \\ 2.663 \end{bmatrix}, w_3 = \begin{bmatrix} 0.021 \\ -0.594 \\ -3.909 \\ -0.570 \\ -0.012 \end{bmatrix}, b_3 = [3.479]$$

式中， $w_2$  为输入层到隐含层大小为  $5\times 4$  的权值矩阵； $b_2$  为输入层到隐含层大小为  $5\times 1$  的阈值矩阵； $w_3$  为隐含层到输出层大小为  $5\times 1$  的权值矩阵； $b_3$  为隐含层到输出层大小为  $1\times 1$  的阈值矩阵。

图 9 展示了由未改进预测模型得到的结果和样本的实际输出值。由图 9 可知，预测值和实际值在整体上能保持较高的重合度，但在实际值较小的样本上，预测值往往偏小，甚至会预测出负的  $\sigma_{\min}$ ，这类预测结果在物理上是错误的。经统计可得未改进预测模型的误差均方根为 0.33。

#### 3.3 改进后预测模型

对于改进后的预测模型，可以利用遗传算法优化 BP 神经网络拓扑结构中的隐含层神经元数  $n$  和学习率  $\lambda$ ，依照 3.2 节指定初始的  $n=5$ ， $\lambda=$




图9 未改进预测模型的预测结果

Fig. 9 Prediction Results of Unimproved Prediction Model

0.40。设定遗传优化代数为 100 代。改进预测模型关于拓扑结构中的权值和阈值如下：

$$w_2 = \begin{bmatrix} 1.012 & 1.744 & 2.344 & 3.537 \\ 4.175 & -1.108 & 2.847 & -0.082 \\ 0.509 & -4.756 & 0.264 & -2.568 \\ 2.343 & 1.340 & -1.238 & -0.542 \\ -2.761 & 0.047 & 0.024 & 0.013 \\ 1.052 & -0.597 & 2.817 & -0.063 \\ 2.869 & -1.326 & -3.060 & 0.405 \\ -0.597 & 0.501 & -2.750 & 0.058 \\ -4.699 & -1.221 & 2.252 & -0.204 \end{bmatrix}$$

$$b_2 = \begin{bmatrix} -4.859 \\ -2.621 \\ -2.036 \\ -0.422 \\ 3.473 \\ 0.506 \\ 2.957 \\ -0.148 \\ -3.743 \end{bmatrix}, w_3 = \begin{bmatrix} 0.032 \\ 0.181 \\ -0.019 \\ 0.039 \\ -4.963 \\ 1.399 \\ -0.067 \\ 1.538 \\ 0.074 \end{bmatrix}, b_3 = [2.474]$$

经过遗传算法优化后得到最优的隐含层神经元数  $n=9$ ，学习率  $\lambda=0.30$ 。如表 2 所示，相较于未改进的预测模型，改进预测模型的误差均方根  $e_{rms}$  降低约 36.4%。

图 10 展示了由改进预测模型得到的结果和样本的实际输出值，可见整体上的预测精度与未改进的预测模型相比有较大提升，基本上能与实际值一一对应，而且对小空化数的预测更为准确。

#### 4 结论

本文针对节流孔板的空化特性问题，首先通过 CFD 方法计算得到了流场中的最小空化数，并借助 LHS 积累了可信的数据库；然后据此建立了原始的 BP 神经网络预测模型；最后面向原始模型的不足提出了以遗传算法优化相关参数的改进办法。基于本文工作，得出以下结论：

(1) 孔板开孔直径和前开角度对最小空化数

表 2 误差均方根对比

Tab. 2 Comparison of Error Root Mean Square

对比量	未改进预测模型	改进预测模型	相对偏差/%
$e_{rms}$	0.33	0.21	36.4




图 10 改进预测模型的预测结果

Fig. 10 Prediction Results of Improved Prediction Model

具有较强的全局敏感度。

(2) 原始的 BP 神经网络预测模型由于需人为指定相关参数，导致对于最小空化数的预测不准。

(3) 改进后的 BP 神经网络预测模型大幅提高了预测精度，误差均方根值减小约 36.4%。

#### 参考文献：

- [1] TANG T F, GAO L L, LI B R, et al. Cavitation optimization of the throttle orifice plate based on three-dimensional genetic algorithm and topology optimization[J]. Structural and Multidisciplinary Optimization, 2019(60): 1227-1244.
- [2] 袁少波, 李振, 徐伟祖, 等. 核电厂小支管裂纹泄漏原因分析和改造[J]. 核动力工程, 2019, 40(S1): 97-99.
- [3] FILHO J A B, SANTOS A A C, NAVARRO M A, et al. Effect of chamfer geometry on the pressure drop of perforated plates with thin orifices[J]. Nuclear Engineering and Design, 2015(284): 74-79.
- [4] MENTER F R. Two-equation eddy-viscosity turbulence models for engineering applications[J]. AIAA Journal, 1994, 32(8): 1598-1605.
- [5] 林名润, 王杰, 闫大鹏, 等. 改进BP神经网络的滚珠丝杆故障诊断研究[J]. 机械设计与制造, 2020(6): 173-176.
- [6] MOOSA M, HEKMAT M H. Numerical investigation of turbulence characteristics and upstream disturbance of flow through standard and multi-hole orifice flowmeters[J]. Flow Measurement and Instrumentation, 2019(65): 203-218.

(责任编辑: 马 蓉)