

doi: 10.7690/bgzd.2024.11.017

基于改进遗传算法优化 BP 网络的密度预测

史慧芳, 郭进勇, 伍凌川, 杨治林, 袁 申, 李全俊, 王 勇, 黄 荔
(中国兵器装备集团自动化研究所有限公司智能制造事业部, 四川 绵阳 621000)

摘要: 为了能利用工艺参数实时预测药柱密度并提高密度预测精度, 提出采用改进遗传算法优化 BP 网络(improved genetic algorithm backpropagation neural network, IGA-BPNN)的炸药密度预测模型。通过动态调整 GA 的交叉概率和变异概率, 确定 BPNN 权重和阈值的最优值, 构建 IGA-BP 预测模型, 利用采集的工艺参数, 基于所构建模型进行炸药密度预测。实验结果表明: 改进的 GA 对交叉率和变异率做出了更好的调整, 能快速搜寻 BPNN 的最优权重和阈值, 提高炸药压制密度的预测精度。

关键词: 炸药密度; 改进遗传算法; 交叉率; 变异率; BP 神经网络

中图分类号: TJ55; TP391 **文献标志码:** A

Density Prediction of BP Networks Based on Improved Genetic Algorithm Optimization

Shi Huifang, GuoJinyong, Wu Lingchuan, Yang Zhilin, Yuan Shen, Li Quanjun, Wang Yong, Huang Li
(Department of Intelligent Manufacture, Automation Research Institute Co., Ltd. of
China South Industries Group Corporation, Mianyang 621000, China)

Abstract: In order to predict the density of explosive column in real time and improve the prediction accuracy, an improved genetic algorithm was used to optimize the BP network (improved genetic algorithm backpropagation neural network, IGA-BPNN) model for predicting explosive density. By dynamically adjusting the crossover probability and mutation probability of GA, the optimal values of BPNN weights and thresholds were determined, and the IGA-BP prediction model was constructed to predict the explosive density based on the collected process parameters. The experimental results show that the improved GA makes a better adjustment to the crossover rate and mutation rate, can quickly search the optimal weight and threshold of BPNN, and improve the prediction accuracy of explosive pressing density.

Keywords: explosive density; improved genetic algorithm; crossover rate; mutation rate; BP neural network

0 引言

炸药理论压制密度是炸药爆轰性能估计、相对密度计算、晶体空隙率计算的重要参数^[1], 不仅对炸药压制工艺参数的调整有着重要影响, 而且还影响着炸药毁伤效能, 对于保证产品性能和外观质量具有重要意义。常用检测方法有切片法、排水法和 CT 检测等方法, 但存在破坏性、随机性和检测效率低等缺点, 不能适用于压制过程中实时密度检测; 因此, 建立高效准确的实时炸药密度预测模型具有极大的研究意义。

遗传算法改进的反向传播神经网络 (genetic algorithm-improved backpropagation neural network, GA-BPNN) 作为一种融合了 GA 和神经网络的方法, 能够通过 GA 优化 BPNN 的权重和阈值, 提高了预测模型的预测性能和准确性。

随着 AI 技术的快速发展, 越来越多的研究者开始关注 BPNN 模型在成型密度预测中的应用。王

峰等^[2]提出一种基于 PSO-BPNN 的电驱质量预测模型, 利用粒子群 (particle swarm optimization, PSO) 对 BPNN 的参数进行寻优, 将测试集上的平均绝对百分比误差降为 11%, 提高了模型的预测精度。周萍等^[3]构建了使用标准粒子群算法优化 BPNN 中各层神经元之间连接权重以及阈值, 进而构建 BPNN 织机工艺质量预测模型, 使用该预测模型对实验数据预测, 证明了该预测模型具有较高的泛化能力。曹兴^[4]构建了基于 BPNN 的成型炸药药柱质量预测, 但未优化的 BPNN 容易陷入局部最优解, 使得预测的误差值偏大, 达不到预测的精度要求, 且训练预测时间也相对较长, 不利于实际工程中对炸药密度的实时预测。文献[5]提出了 PSO-RBF 网络预测模型并运用于药柱密度预测, 改进的 RBF 网络模型预测结果更优于传统预测方法, 但当历史样本随着生产不断更新, 训练样本规模增大, RBF 网络隐藏层神经元数量增加, 网络结构变得庞大和复杂,

收稿日期: 2024-06-18; 修回日期: 2024-07-26

第一作者: 史慧芳(1984—), 男, 河南人, 硕士。

无法保证预测实时性。为实现对炸药密度实时预测，提高炸药密度模型的准确性，笔者提出 IGA-BPNN 炸药密度预测模型，将实验数据带入模型进行训练得到密度预测模型，将预测结果与 BPNN、GA-BPNN 模型的预测结果比较。实验结果表明：该模型提高了炸药密度预测精度，同时预测炸药密度均匀性。

1 相关研究方法

1.1 遗传算法

GA 是一种随机全局搜索算法，通过模拟种群的遗传操作(选择、交叉和变异)来搜索问题的解空间^[6-7]。GA 以种群的形式表示一组候选解，每个候选解用染色体表示，通过不断迭代更新种群，GA 使得种群向着搜索空间中更优解的区域进行搜索。随着迭代的进行，种群中适应度值较高的个体逐渐被淘汰，适应度值较低的个体被保留与积累，从而到种群中最适应环境的个体或近似最优解^[8]。GA 被广泛运用于各种优化问题，如函数最小化或最大化优化、机器学习中特征选择和参数调优、旅行商与背包等组合优化、PID 控制器参数优化等控制、神经网络结构权重优化、调度等排队及多目标优化问题等。GA 的流程如图 1 所示。

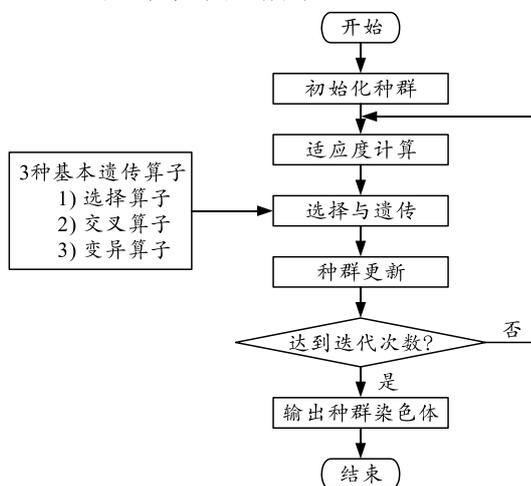


图 1 遗传算法搜索流程

上图中，选择算子的作用是从上一代群体中按一定概率选择优良个体组合成新一代种群；交叉算子的作用是从当前种群中随机选取 2 个个体的染色体进行交换与组合，将上一代的优秀特征遗传给下一代，从而完成染色体的交叉；变异算子的作用是对种群个体进行变异操作，在实际应用中主要采用单点变异方式，防止算法在迭代优化时陷入局部最优解^[9]。

1.2 GA 交叉率和变异率的改进

交叉率 pc 和变异率 pm 控制着 GA 的全局搜索能力。其中， pc 控制着交叉操作的频率， pc 过大会增加算法的搜索强度但也会降低算法的整体搜索效率， pc 过小则会导致算法的搜索停滞不前； pm 是增大种群多样性的第二个因素， pm 过大，会破坏有用的模式而使解远离最优解，使 GA 变成完全随机搜索， pm 过小，则不会产生新的基因块，无法使陷于超平面的解摆脱超平面^[10]。为提高 GA 的搜索效率并有效防止其陷于局部解，按下式动态调整 pc 和 pm ：

$$pc = \begin{cases} 0.1, & i=1 \\ 1/(1+e^{(-1 \times af/(|bf(i)-wf(i)|))}), & i>1 \end{cases}; \quad (1)$$

$$af = \sum_{i=1}^{num} (f(i) - bf(i)) / gn. \quad (2)$$

式中： $bf(i)$ 为上一代第 i 个种群中的最优适应度值； $wf(i)$ 为上一代第 i 个种群中的最大适应度值； num 为总迭代数； af 为种群平均适应度差值； gn 为种群数，当 $i=1$ 时， pc 为 0.1。

$$pm = \begin{cases} 0.01, & i=1 \\ 1/(1+e^{(-0.1 \times af/(|bf(i)-wf(i)|))}) - 0.5, & i>1 \end{cases}. \quad (3)$$

式中当 $i=1$ 时， pm 为 0.01。

通过上述公式使种群在迭代寻优中，交叉率和变异率随着种群的适应度值改变而自动调节，避免了在迭代过程中陷入局部最优解。将改进的交叉率和变异率输入到 GA 中，得到改进的优化算法 IGA。

1.3 BP 神经网络

BPNN 是一种采用基于梯度下降和误差反向传播的前馈型神经网络，网络通过调整权重和阈值使预测输出与训练样本的均方误差最小，适用于求解内部参数关系复杂的非线性问题^[11]。但未优化的 BPNN 存在易陷入局部最优解，网络稳定性差，收敛缓慢甚至不能收敛等缺点^[12-13]，为此许多学者将智能优化算法运用于 BPNN 中，以达到改进 BPNN 的目的^[14]。笔者采用动态自适应函数改进 GA 中的交叉率和变异率，再使用优化后的 IGA 优化 BPNN 的权重和阈值，从而得到改进模型 IGA-BPNN，然后将该模型应用于炸药密度预测。

BPNN 一般由 3 层或 3 层以上的网络结构组成，其主要包括输入层、输出层和隐藏层，具体网络结构如图 2 所示。

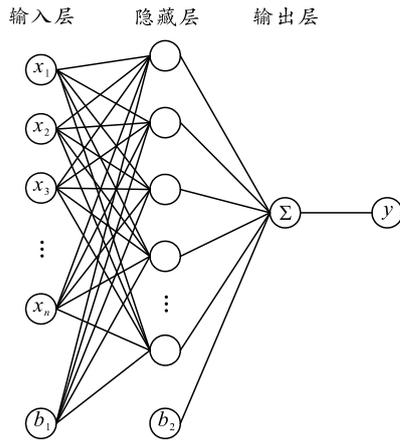


图 2 BPNN 结构

上图中, b_1 、 b_2 分别为输入层和隐藏层的阈值。第一层是输入层, 其输入维数等于输入特征个数, 输入层的输出为 O_{in} :

$$O_{in} = f_1(w_{ij}x_i + b_1) \quad (4)$$

中间层为隐藏层, 该层的神经元节点数决定神经元的复杂程度, 该层的输出为 O_m :

$$O_m = \sum_{k=1}^m (w_k o_k + b_2) \quad (5)$$

最后一层是输出层, 节点个数是输出数据的维数, 该层的输出为 O_k :

$$y = f_2(o_m) \quad (6)$$

2 IGA-BPNN 模型

在构建 BPNN 模型中, 隐藏层神经元的确定如式(7)所示:

$$n_o = \sqrt{m + p} + d \quad (7)$$

式中: n_o 为隐含层节点数; m 为输入层节点数; p 为输出层节点数; m 、 p 分别为 6、1; d 为预设的常数其取值范围为 $[0 \sim 10]$, 取 $d=8$, 对式(7)取整, 即 $n_o=10$ 。笔者建立 3 层 BPNN, 即输入层、输出层和隐藏层, 均为一层, 隐藏层的激活函数为双曲正切 sigmoid 函数 Tansig, 输出层的激活函数为线性函数 Purelin^[15]。

笔者利用 IGA 对 BPNN 的权重和阈值进行寻优, 将寻优得到的最优解输入 BPNN 得到改进模型 IGA-BPNN, 利用 IGA-BPNN 模型进行炸药密度预测。IGA 优化 BPNN 模型的具体流程如图 3 所示。

在迭代过程中通过比较当前适应度值与上次迭代的最优适应度值, 达到反向传播的作用或效果, 完成“染色体”的变异更新, 进而选出最优的“染色体”。在本文中, 适应度是预测值与真实值的方差, 其具体计算方法如式(8)所示:

$$f(\varepsilon_i) = \sum_{k=1}^n (y_k - y_k^*)^2 / n \quad (8)$$

式中: $f(\varepsilon_i)$ 为第 i 个染色体的适应度; y_k 为第 i 个粒子在第 k 组样本的预测值; y_k^* 为第 i 个染色体在第 k 组样本的真实值; n 为样本容量。

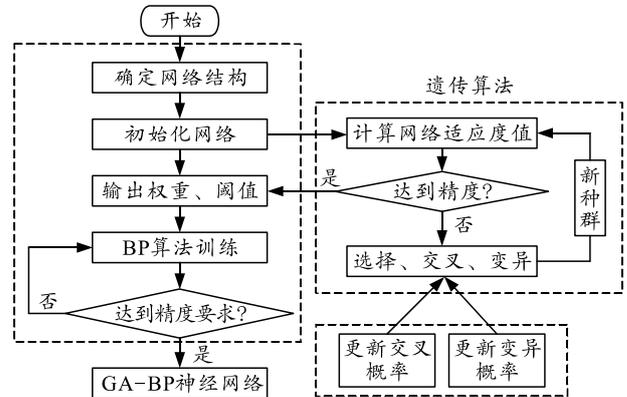


图 3 IGA 优化 BPNN 模型流程

利用 IGA 优化 BPNN 模型的流程如下:

- 1) 将输入样本归一化处理后划分为训练集和测试集。
- 2) 确定 BPNN 结构中输入层节点数、隐含层节点数、以及输出层节点数。
- 3) 初始化 GA, 初始化染色体组, 确定染色体组的个数、迭代次数以及“染色体”取值范围, 并随机产生“染色体”。
- 4) 根据式(8)计算每个粒子当前适应度 $f(\varepsilon_i)$ 。
- 5) 按照上述自适应法更新交叉率和变异率。
- 6) 完成染色体的选择、交叉与变异操作, 更新染色体。其中交叉操作采用实数交叉法^[16], 即第 k 个染色体 c_k 和第 l 个染色体 c_l 在第 i 位的交叉操作如式(9)所示:

$$\left. \begin{aligned} c_{ki} &= c_{ki}(1-cr) + c_{li}cy \\ c_{li} &= c_{li}(1-cr) + c_{ki}cy \end{aligned} \right\} \quad (9)$$

式中: cy 为交叉概率, 变异操作, 选取第 i 个染色体的第 j 个基因进行变异, 如式(10)所示:

$$c_{ij} = \begin{cases} c_{ij} + (c_{ij} - c_{\max}) \times fg, & r > 0.5 \\ c_{ij} + (c_{\min} - c_{ij}) \times fg, & r \leq 0.5 \end{cases} \quad (10)$$

式中: $fg = mu \cdot (1 - g/G_{\max})^2$; mu 为变异概率; g 为当代迭代次数; G_{\max} 为最大迭代次数; c_{\min} 为基因下界; c_{\max} 为基因上界; r 为随机数且 $r \in [0, 1]$ 。

7) 更新全局最优种群, 如果当前种群的适应度值优于随机产生的全局最优种群适应度值, 则将当前种群当作新的全局最优种群。

8) 判断是否达到最大迭代次数, 若达到迭代次

数则进行下一步，否则返回步骤 e)。

9) 将训练集样带入 IGA-BPNN 模型进行训练，得到 BPNN 的最优参数，并将其赋值给 BPNN，完成 BPNN 模型优化。

10) 使用优化好的 BPNN 模型预测测试集，得到炸药压制密度和均匀性预测结果，并对结果进行分析。

3 实验验证与结果分析

3.1 实验数据

为验证所改进模型的可行性，笔者使用 MARC 软件模拟仿真炸药压制过程，并采集压制过程中多种变化的工艺参数和压制成品密度，共采集 700 组压制工艺参数，然后对其进行预处理。笔者使用 Matlab 模拟抽样密度均匀性检测，具体处理过程如下：

1) 使用软件将每块模型划分 453 块网格单元，并对每块单元的成品密度进行矩阵处理，以模拟实验取样截面；

2) 从矩阵随机取出 5 块 3×3 的矩阵，模拟对样本密度的抽样检测；

3) 分别计算每个矩阵的平均密度，两两相减取绝对误差；

4) 用每组的最大差值代表改组样本的密度均匀性，并计算每组样本的平均密度；

5) 用该组样本的平均密度代表该样本的成品密度。

由于样本中炸药压制摩擦力、压制压力、真空度、压制速度、预热温度以及保压时间的单位各不相同，为避免参数之间的量纲相互影响，确保实验模型的预测精确性，对样本数据进行归一化处理：

$$y = (y_{\max} - y_{\min}) * (x - x_{\min}) / (x_{\max} - x_{\min}) + y_{\min} \quad (11)$$

式中： x 为样本参数； x_{\min} 和 x_{\max} 分别为实验数据的

最小值和最大值； y_{\max} 为 1； y_{\min} 为 -1。

3.2 密度预测实验

确定 BPNN 的结构模型，将 BPNN 的待优化参数(隐藏层权重、隐藏层阈值、输出层权重以及输出层阈值)编码成以实数码串表示的染色体个体，同时随机产生一定规模的染色体，组成初始化种群。由于输出节点为 1，所以此网络的输出权重个数与隐藏层神经元数相同，输入层节点数为 in ，隐藏层节点数为 hn ，每一个输入层节点都要和所有隐藏层神经元发生一次激励，因此数据中心参数个数为 $hn * in$ ，染色体维数为 Ln ，具体如式(12)所示：

$$Ln = hn * in + hn + hn * 1 + 1 \quad (12)$$

基于上述利用动态自适应法改进 GA 中的交叉率和变异率，嵌入 GA 中，并在 Matlab 软件中构建改进模型 IGA。模型的初始化参数设置如表 1 所示。

表 1 GA 初始化参数设置

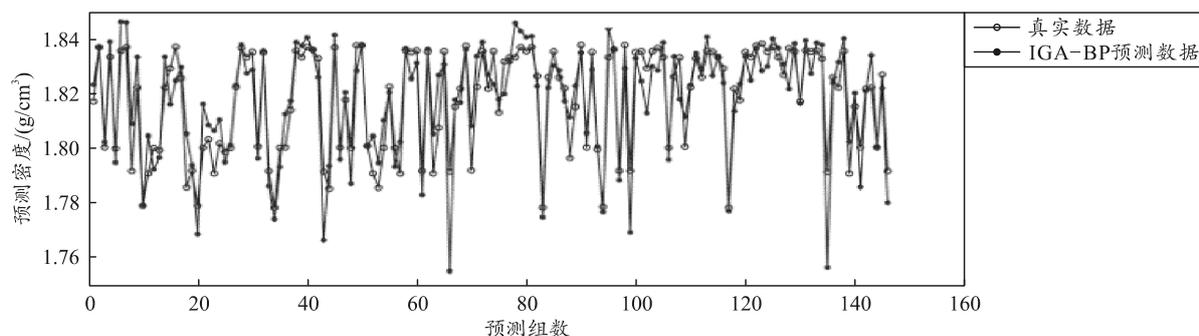
网络参数	初始值	网络参数	初始值
种群规模	20	权重取值范围	[-1, 10]
迭代次数	50	阈值取值范围	[-1, 10]
学习因子范围	[0, 1]		

完成 IGA 算法初始化后，随机选取归一化后的 554 组样本作为训练集输入上述构建的 IGA-BPNN 模型，对模型进行优化训练，最后将归一化后的 146 组样本输入训练好的 IGA-BPNN 模型，对炸药密度进行预测，得到预测密度与真实密度的对比如图 4 所示。

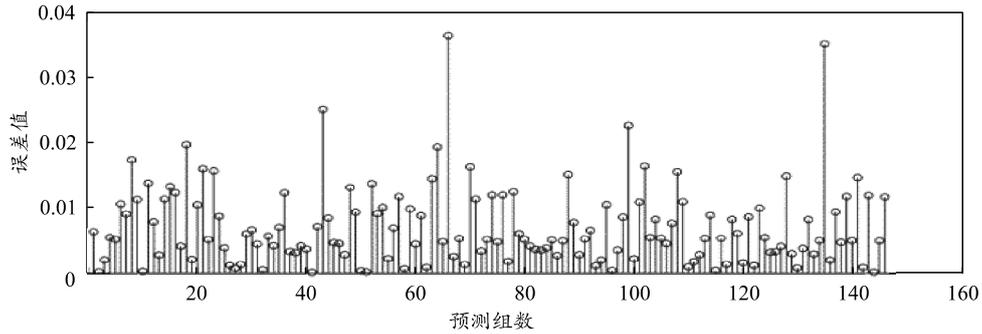
利用 RMSE 评价该模型的精度，具体 RMSE 如式(13)所示：

$$\sqrt{\sum_{k=1}^n (\text{test} - \text{true})^2 / n} \quad (13)$$

式中： test 为预测的结果数据； true 为采集的真实数据； k 为测试样本组数，最大为 n 。



(a) IGA-BPNN 预测



(b) IGA-BPNN 预测误差

图 4 IGA-BPNN 模型预测结果

为排除随机因素对预测结果的影响，笔者进行了 10 次重复实验，实验结果如表 2 所示。

表 2 预测结果均方根误差

实验次数	GA-BP	IGA-BP	实验次数	GA-BP	IGA-BP
1	0.010 2	0.009 3	6	0.009 8	0.008 8
2	0.011 5	0.007 3	7	0.017 8	0.009 7
3	0.072 4	0.012 3	8	0.071 9	0.010 7
4	0.011 1	0.011 0	9	0.010 6	0.008 3
5	0.011 2	0.006 6	10	0.012 7	0.010 2

由图 4 可知：IGA-BPNN 模型有较高的训练精度，训练误差较低。分析表 2 可知，10 次实验中，每组 IG-BPNN 模型预测的 RMSE 均小于 GA-BPNN 模型，因此证明改进后的 IGA-BPNN 模

型对炸药压制密度预测的可行性。

完成密度预测后，再利用该模型对压制密度的均匀性进行预测。

3.3 炸药密度预测结果分析

平均绝对误差 (MAE) 反映预测值偏离真值的平均大小，均方根误差 (RMSE) 反映模型的预测效果优劣程度；因此，笔者将 MAE 和 RMSE 作为模型精度的评价指标。将测试数据输入到训练好的 IGA-BPNN 模型进行预测，其预测结果的 MAE 为 0.007 1，RMSE 为 0.009 3。测试集 IGA-BPNN 模型与 GA-BPNN 模型预测结果对比曲线如图 5 和 6 所示。

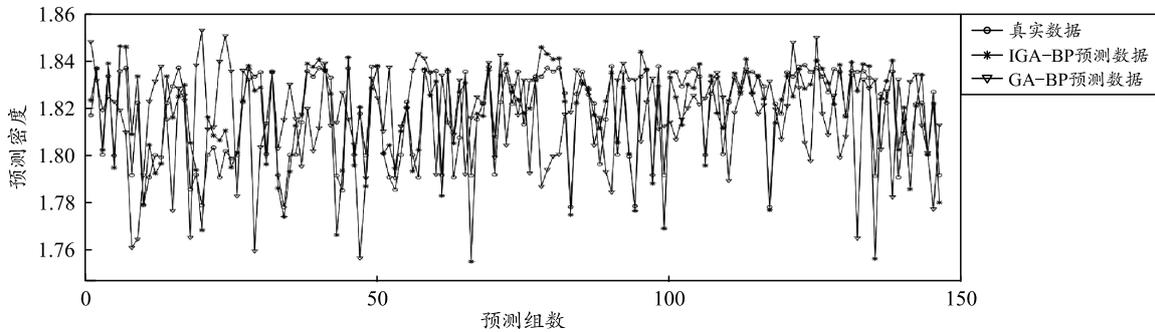


图 5 测试集 IGA-BPNN 与 GA-BPNN 预测结果

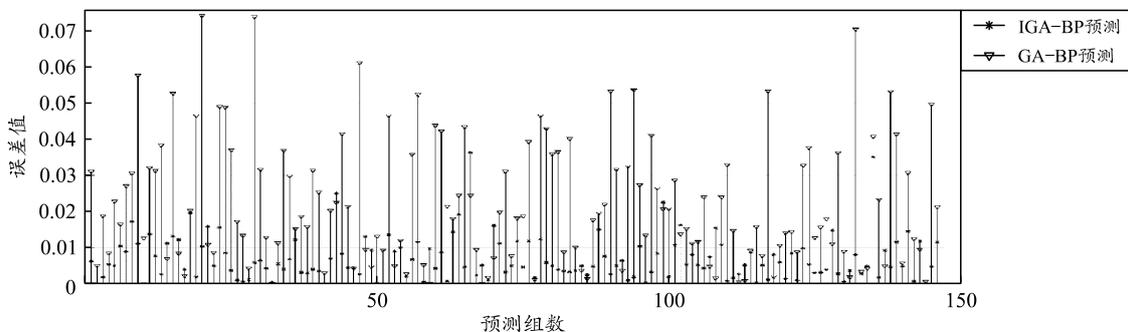


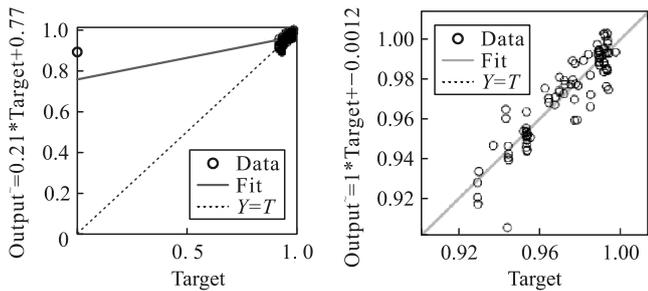
图 6 测试集 IGA-BPNN 与 GA-BPNN 预测误差

从预测结果对比图分析，IGA-BPNN 模型的预测曲线与真实密度的曲线的拟合效果更好，误差也小于 GA-BPNN 模型的预测误差，IGA 模型拟合相

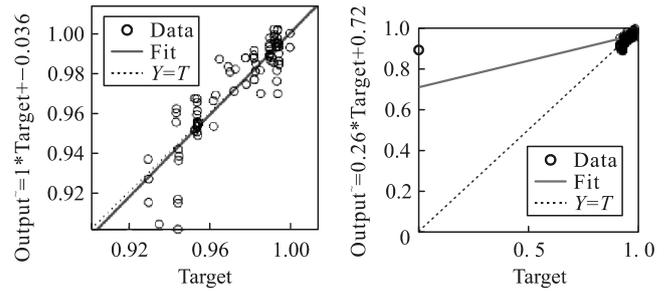
关性结果如图 7 所示。

从下图拟合结果可知：IGA-BPNN 模型的测试集的线性拟合相关系数值达到了 0.89，表明该模型

的预测精度较高。当种群维度设置为 20，迭代次数设置为 50 次，得到的训练结果最佳如图 8 所示，当迭代次数为 30 时适应度值趋于稳定，得到最优适应度值为 0.001 283。结果表明：使用动态自适应方法调整交叉率和变异率后得到的 IGA-BPNN 模型迭代收敛更迅速，最终预测数据的 MAE 值 9.3×10^{-3} 也小于 GA-BPNN 模型的预测数据的 RMSE 值 1.02×10^{-2} ，相较于 GA-BPNN 下降了 8.8%，提高了药柱压制密度预测的准确性。



(a) 训练相关性 $R=0.46868$ (b) 验证相关性 $R=0.90416$



(c) 测试相关性 $R=0.89252$ (d) 整体相关性 $R=0.50074$

图 7 IGA-BPNN 模型回归拟合相关性

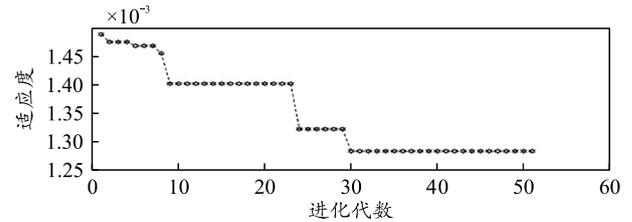


图 8 IGA-BPNN 模型迭代

图 9—11 为炸药密度均匀性预测结果对比图和 GA 寻优结果图。

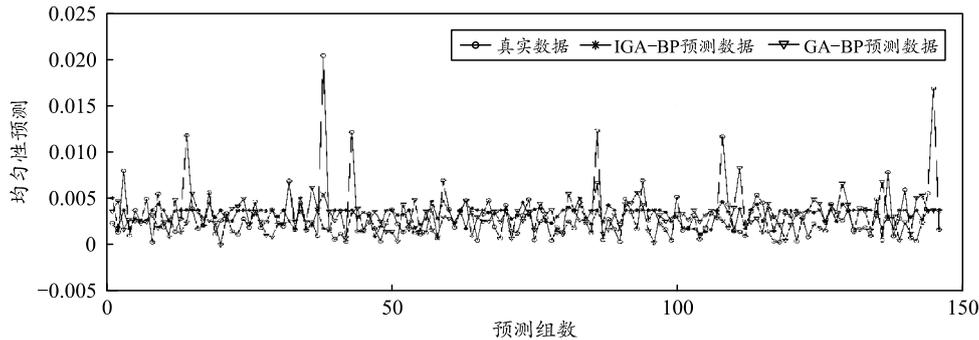


图 9 均匀性测试集 IGA-BPNN 与 GA-BPNN 预测结果

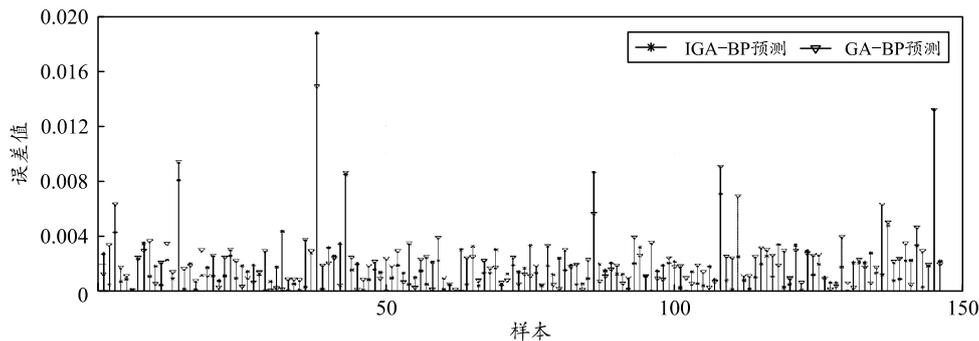


图 10 均匀性测试集 IGA-BPNN 与 GA-BPNN 预测误差

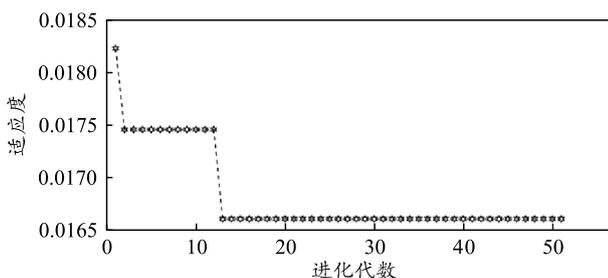


图 11 均匀性 GA 寻优结果

由图 9—11 可知：IGA-BPNN 模型可以对炸药压制密度进行预测，而且对其密度的均匀性预测时迭代到 12 次达到收敛状态，表明该模型应用于炸药密度均匀性预测方面能快速收敛。

3.4 对比实验分析

笔者将 IGA-BPNN 模型预测结果与 GA-BPNN 模型进行对比。表 3 和 4 为不同模型实验结果。

表 3 不同模型炸药密度实验结果

评价指标	BPNN	GA-BPNN	IGA-BPNN	降低率/%
RMSE	0.072 3	1.02×10^{-2}	9.3×10^{-3}	8.8
MAE	0.009 9	0.009 5	0.007 1	25.3

表 4 不同模型炸药密度均匀性实验结果

评价指标	BPNN	GA-BPNN	IGA-BPNN	降低率/%
RMSE	3.31×10^{-3}	3.06×10^{-3}	2.89×10^{-3}	5.60
MAE	0.002 3	0.002 1	0.001 8	14.28

由上表可知：GA-BPNN、IGA-BPNN 均可实现炸药压制密度和密度均匀性的有效预测，但前者的预测精度和寻优效果远不如 IGA-BPNN 模型预测效果；与 GA-BPNN 模型相比，IGA-BPNN 模型的 RMSE 下降了 8.8%，MAE 下降了 25.3%，且误差范围在[0~0.036]，实现了炸药压制密度的高精度预测。在密度均匀性预测过程中，与 GA-BPNN 模型相比，IGA-BPNN 模型的 RMSE 分别下降了 5.6%，MAE 分别下降了 14.28%，同时实现了炸药压制密度均匀性的准确预测。

3.5 权重分析

利用 IGA-BPNN 密度预测模型的权重矩阵分析每个输入工艺参数对炸药密度的影响权重系数。具体计算如式(14)所示：

$$I_t = \frac{\sum_{m=1}^{m=N_x} \left[\left(\frac{|W_{jm}^{ix}|}{\sum_{k=1}^{N_i} |W_{km}^{ix}|} \right) \times |W_{mn}^{xy}| \right]}{\sum_{k=1}^{k=N_i} \left\{ \sum_{m=1}^{m=N_x} \left[\left(\frac{|W_{jm}^{ix}|}{\sum_{k=1}^{N_i} |W_{km}^{ix}|} \right) \times |W_{mn}^{xy}| \right] \right\}} \quad (14)$$

式中： I_t 为第 t 个输入变量对输出结果的影响权重； N_i 和 N_x 分别为输入层神经元和隐藏层神经元的数量； W 为权重；输入层，上标 i 、 x 和 y 为隐藏层和输出层；下标 k 、 m 和 n 分别为输入层，隐藏层和输出层神经元^[17]。

根据上式计算各个工艺参数对密度的影响权重系数，输入特征中摩擦力、高径比、相对密度、压制速度、温度以及保压时间对炸药密度的影响权重系数分别为 21.48%、11.19%、19.86%、13.74%、14.40%、19.33%，结果如图 12 所示。可以发现：对炸药密度影响最大的为摩擦力，影响权重系数为 21.48%，最小为高径比，影响权重系数为 11.19%。由此可见，保压时间并非为对压制成型密度影响最大的工艺参数，同时从图中可以看出：各个参数对炸药压制成型密度的影响相对均衡，主要集中在 10%~20%，证明了炸药压制成型过程中各个工艺参数对最终压制成品密度一致存在影响，所以在研究炸药压制成型过程中要充分考虑各个参数对压制

密度的综合性影响。

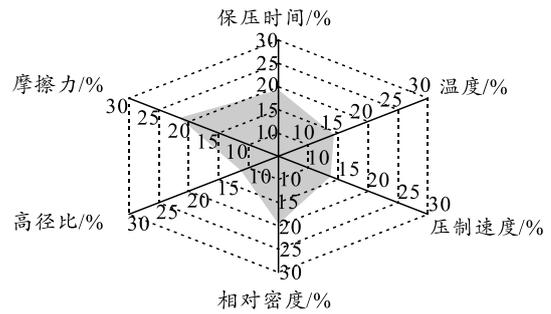


图 12 各工艺参数对炸药密度的影响权重系数

4 结论

针对传统炸药压制密度预测方法不能完成实时预测且预测精度低等问题，笔者提出一种改进 GA 优化 BPNN 的炸药密度预测方法。该方法通过改进 GA 中的交叉率和变异率进而得到 IGA，再利用 IGA 对 BPNN 权重和阈值寻优，构建 IGA-BPNN 预测模型，最后输入测试集工艺参数完成实验预测。上述实验结果表明：IGA-BPNN 模型可实现对炸药密度预测，且与 GA-BPNN 模型相比具有更高的预测精度，预测准确率能达到 93.5%以上。通过本次实验完成炸药压制密度的高精度预测，为炸药密度预测提供了方法；对密度预测，能有效提高压制成品合格率，减少试错环节，提高炸药质量，从而提高炸药的毁伤性能，在工程运用上该方法具有一定的参考价值。IGA-BP 预测模型能广泛适用于多维度单输出结果预测领域，相比较于 GA 算法能快速收敛于最优值。

参考文献：

- [1] 谭凯元, 曹落霞, 文尚刚, 等. 装药密度小幅变化对三氨基三硝基苯基聚合物粘结炸药短脉冲冲击起爆特性的影响[J]. 兵工学报, 2018, 39(3): 468-473.
- [2] 王峰, 万冶, 陶小亮, 等. 基于 BP-PSO 的电驱质量预测模型及工艺参数敏感性分析[J]. 制造技术与机床, 2022, 725(11): 137-143.
- [3] 周萍, 费树岷. 基于 BP 神经网络的织机工艺质量预测模型研究[J]. 工业控制计算机, 2014, 27(6): 44-45, 47.
- [4] 曹兴. 粉体炸药压制成型工艺仿真与质量预测[D]. 太原: 中北大学, 2021.
- [5] 郭进勇, 伍凌川, 刘彬, 等. 基于改进 PSO-RBF 的炸药药柱密度预测研究[J]. 兵器装备工程, 2023, 44(S2): 121-127.
- [6] 郭海湘, 诸克军, 胡杰, 等. GA-BP 嵌套算法的理论及应用[J]. 数学的实践与认识, 2008(1): 116-125.