

# 基于改进极限学习机的煤与瓦斯突出预测研究\*

乔威豪<sup>1</sup>, 安葳鹏<sup>2</sup>, 赵雪菡<sup>1</sup>, 吕常周<sup>1</sup>

(1.河南理工大学 计算机科学与技术学院, 河南 焦作市 454000;

2.河南理工大学 软件学院, 河南 焦作市 454000)

**摘要:**为提高煤与瓦斯突出预测的准确率和效率,提出了一种基于数据预处理的多策略改进烟花算法(IFWA)优化极限学习机(ELM)的煤与瓦斯突出预测模型。首先,针对于非线性多维特征数据,使用灰色关联度分析(GRA)进行特征选取,利用主成分分析(PCA)进行特征约简,将数据预处理后的数据指标作为模型的输入;其次,引入引力搜索算子和混合变异策略改进烟花算法(FWA)易陷入局部最优的问题;最后,利用IFWA对ELM的输入层到隐含层的权重和偏差进行优化,构建最优的煤与瓦斯突出风险预测模型。结果表明,IFWA-ELM模型的RMSE和 $R^2$ 可达0.074, 0.968,与ELM、GA-ELM、PSO-ELM和FWA-ELM模型相比均有所提升,IFWA-ELM模型对煤与瓦斯突出危险等级预测的准确率可达100%,具有更好的收敛速度和预测精度。研究成果可为煤矿瓦斯突出多数据融合预测提供可靠的理论依据。

**关键词:**煤与瓦斯突出;烟花算法;极限学习机;数据预处理;风险预测模型

**中图分类号:**TD713 **文献标识码:**A

**文章编号:**1005-2763(2024)05-0098-08

## 0 引言

煤与瓦斯突出是指在煤矿开采过程中,煤体破裂释放大量瓦斯,并发生煤岩突出的现象。预测方法主要分为常规静态预测技术、瓦斯涌出指标预测及监测预警方法、突出危险性机器学习模型预测方法<sup>[1]</sup>。为实现预测指标临界值和多种指标融合的综合突出判定,不少学者尝试利用机器学习模型来实现瓦斯突出的精准预测。

付华等<sup>[2]</sup>将等距映射和优化后的加权SVM相耦合,建立了双耦合算法的煤与瓦斯突出预测模型。

李心杰等<sup>[3]</sup>将模拟退火算法和遗传算法结合优化模糊C-均值聚类(FCM),有效解决了FCM算法易陷入局部最优的问题。隆能增等<sup>[4]</sup>使用局部线性嵌入法进行特征降维,再使用果蝇优化BP神经网络模型,实现了煤与瓦斯突出强度的精准预测。徐耀松等<sup>[5]</sup>利用增强拓扑神经进化算法(NEAT)处理稀疏核PCA降维后的数据,并取得了较好的预测效果。王雨虹等<sup>[6]</sup>利用进化的粒子群优化算法(sdPSO)结合量子门节点神经网络(QGNN)来实现瓦斯突出等级预测,具有较好的泛化能力。阎馨等<sup>[7]</sup>结合AdaBoost增强学习框架和LR,构建了较为稳定的瓦斯突出预测模型。

以上方法均提升了煤与瓦斯突出的预测效果,但由于煤与瓦斯突出机理的复杂性以及模型固有的缺陷,使以往的预测模型不能兼顾预测精度和时间效率,仍需要深入研究致突因素及灾害发生的影响程度,以此来提高预测模型的效率和准确率。

本文提出一种基于数据预处理与改进的极限学习机(extreme learning machine, ELM)相结合的瓦斯突出预测模型。该模型在数据处理阶段,使用灰色关联度分析(grayscale correlation analysis, GRA)进行特征选择,使用主成分分析(principal component analysis, PCA)进行特征约简,将提取的主成分序列作为改进烟花算法和极限学习耦合模型的输入,利用多策略改进的烟花算法(fireworks algorithm, FWA)优化极限学习机输入权值和隐含层阈值,可以有效提高极限学习机的预测稳定性和预测精度。通过与其他模型比较,验证该模型预测的泛化能力和高效性,为煤与瓦斯突出预测提供了

\* 收稿日期:2023-07-06

基金项目:国家自然科学基金项目(61872126);河南省重点科技攻关资助项目(192102210123)。

作者简介:乔威豪(1997—),男,河南驻马店人,硕士研究生,研究方向为智能测控技术、煤与瓦斯突出预测, E-mail: 228914636@qq.com。

通信作者:安葳鹏(1969—),男,河南洛阳人,硕士,教授,研究方向为计算机测控技术、矿井通风与瓦斯防治, E-mail: cywaniii@163.com。

新思路。

## 1 煤与瓦斯突出预测参数的选择

煤与瓦斯突出机理作为突出预测的基础,通过总结突出发生规律,对突出现象以及发生条件、原因做出概述,为突出预测指标提供理论依据<sup>[8]</sup>。不少学者都对突出机理做出了研究,普遍认为突出是由地应力、瓦斯、煤的物理力学性质共同决定的<sup>[9]</sup>。因此,致突因素的选取需要考虑煤的破坏程度、煤层应力状态、煤的地质构造、瓦斯含量等<sup>[10]</sup>。

致突因素的选择也影响着预测模型的收敛性和准确率,结合实际应用需求和限制,参考相关文献与研究,笔者建立了包含煤的破坏类型  $X_1$ 、煤的瓦斯放散初速度  $X_2$ 、煤的坚固性系数  $X_3$ 、煤层瓦斯含量  $X_4$ 、 $K_1$  瓦斯解吸量  $X_5$ 、钻屑量  $X_6$ 、煤层与地质构造带的距离  $X_7$ 、煤的埋深  $X_8$ 、煤的厚度  $X_9$ ,共 9 个致突因素作为模型的预测指标。

由于煤与瓦斯突出的因素过多,对模型的效率会产生影响,各因素之间又存在复杂的非线性关系,因此,笔者选择使用 GRA 进行特性选取,以减少实际应用中数据获取的难度,再利用 PCA 进行特征降维,通过数据预处理在确保预测准确率和泛化能力的同时提高预测模型的效率。

## 2 煤与瓦斯突出预测模型

### 2.1 烟花算法

烟花算法<sup>[11]</sup>是谭营受烟花在夜空中爆炸产生火花并照亮周围区域这一自然现象启发所提出的一种群体智能优化算法,通过烟花爆炸行为交互传递信息,使得群体对环境的适应性在迭代中变得越来越好,从而求得全局最优解<sup>[12]</sup>。FWA 算法包括种群初始化、爆炸操作、变异操作、映射规则、选择策略 5 个部分<sup>[13]</sup>。具体实现步骤如下。

(1) 设烟花种群  $X(t)=[x_1, \dots, x_i, \dots, x_N]$  为第  $t$  迭代的烟花初始种群,其中  $N$  为烟花个体数; $x_i$  代表第  $i$  个烟花在解空间的位置信息,计算适应度值为  $F(x_i)$ 。

(2) 根据式(1)和式(2)计算产生烟花个数  $S_i$  和爆炸半径  $A_i$ ,根据式(3)进行爆炸操作,每个烟花  $x_i$  产生的  $S$  个火花种群集合为  $Y_i(t)=[y_{i,1}, \dots, y_{i,j}, \dots, y_{i,s}]$ 。

$$S_i = c \times \frac{y_{\max} - F(x_i) + \epsilon}{\sum_{i=1}^n (y_{\max} - F(x_i)) + \epsilon} \quad (1)$$

$$A_i = d \times \frac{F(x_i) - y_{\min} + \epsilon}{\sum_{i=1}^n (F(x_i) - y_{\min}) + \epsilon} \quad (2)$$

$$y_{i,j} = x_i + A_i \mathbf{B} \times \text{rand}(-1, 1), \quad 1 \leq i \leq N, 1 \leq j \leq S \quad (3)$$

式中, $y_{\max}$  为当前最差的烟花个体, $y_{\max} = \max(F(x_i))$ ;  $y_{\min}$  为最优的烟花个体, $y_{\min} = \min(F(x_i))$ ;  $c$ 、 $d$  为常数,分别用来限制产生火花的总个数和烟花爆炸的最大半径; $\epsilon$  为一个极小常数,避免分母为零; $y_{i,j}$  为烟花  $x_i$  所产生的火花; $\mathbf{B}$  为一个  $D$  维的随机矩阵,矩阵元素为 0 或 1。

为避免烟花爆炸产生的火花数据过多或者过少,通过式(4)对每个烟花产生的火花数量进行控制。

$$\hat{s} = \begin{cases} \text{round}(ae), & s_i < ae \\ \text{round}(be), & s_i > be, a < b < 1 \\ \text{round}(S_i), & \text{otherwise} \end{cases} \quad (4)$$

式中, $\hat{s}$  为第  $i$  个烟花产生的火花数; $a$ 、 $b$ 、 $e$  为常数; $\text{round}(\cdot)$  为四舍五入取整函数。

(3) 从  $X(t)$  烟花集合中选择  $h$  ( $0 < h < N$ ) 个烟花,根据式(5)进行高斯变异操作,生成高斯变异火花集合  $Z(t)=[z_1, \dots, z_i, \dots, z_h]$ ,丰富烟花种群的多样性。

$$z_i = x_i \mathbf{B} g, 1 \leq i \leq h \quad (5)$$

式中, $z_i$  为经过高斯变异后的火花粒子; $g$  为服从高斯变异的随机变量。

(4) 经过爆炸操作和变异操作后,部分火花粒子会产生在解空间之外,利用式(6)进行模运算,并将其映射到解空间内<sup>[14]</sup>。

$$x_i^k = x_{\min}^k + |x_i^k| \% (x_{\max}^k - x_{\min}^k) \quad (6)$$

式中, $x_i^k$  为烟花粒子  $x_i$  在第  $k$  维上的位置; $y_{\max}^k$ 、 $y_{\min}^k$  分别为烟花粒子在第  $k$  维的上下边界; $\%$  为取模运算。

(5) 从集合  $U(t) = \{X(t) \cup Y(t) \cup Z(t)\}$  中选择  $N$  个烟花粒子作为下一代的候选烟花种群,然后选取适应度最小的烟花作为下一代烟花种群个体,其余的烟花个体采用轮盘赌方式进行选择<sup>[15]</sup>。

$$R(x_i) = \sum_{j=1}^{U(t)} \|x_i - x_j\| \quad (7)$$

$$p(x_i) = \frac{R(x_i)}{\sum_{j \in U(t)} R(x_j)} \quad (8)$$

式中, $R(x_i)$  为烟花个体  $x_i$  与其他个体的距离之和,通过式(7)计算得出; $x_j$  为第  $j$  个烟花在解空间的位置信息; $\sum_{j \in U(t)} R(x_j)$  为集合  $U(t)$  中所有粒子与

其他个体粒子的距离总和; $p(x_i)$ 为粒子被选择概率。

(6) 判断是否符合终止条件,若符合条件则终止迭代,不符合则继续执行步骤(2)至步骤(5)操作。

## 2.2 多策略改进烟花算法

### 2.2.1 GSA优化的FWA

在FWA算法中,烟花粒子之间缺少有效的信息交互,导致在某些维度上没有取得最优解<sup>[16]</sup>。因此,本文提出利用引力搜索算法(gravitational search algorithm,GSA)优化烟花算法,实现烟花粒子间的信息交互。引力搜索算子通过火花粒子的相互作用力进行粒子位移操作,进而实现粒子之间的信息共享,使粒子能感应到解空间的环境信息并改善较差粒子的位置,具体实现步骤如下。

(1) 设迭代 $t$ 次后的烟花粒子集合为 $W(t)=[w(1),\dots,w(i),\dots,w(N_a)]$ ,由式(9)和式(10)计算出粒子 $i$ 的惯性质量 $M_i$ 。

$$m_i = \frac{f(w_i) - \max_{w_j \in W(t)} f(w_j)}{\min_{w_j \in W(t)} f(w_j) - \max_{w_j \in W(t)} f(w_j)} \quad (9)$$

$$M_i = \frac{m_i}{\sum_{m_j \in W(t)} m_j} \quad (10)$$

式中, $f(w_i)$ 、 $f(w_j)$ 分别为粒子 $w_i$ 、 $w_j$ 的适应度值。

(2) 选取质量最好的 $2 \times N$ ( $N$ 为初始烟花个数)个粒子组成优越火花粒子集 $R$ ,利用式(11)计算 $W(t)$ 中粒子 $i$ 受到的合力 $F_i^k$ 。

$$F_i^k = \sum_{j=1, j \neq i}^{N_a} \text{rand}(0,1)G \frac{M_i \times M_j}{R_{ij} + \epsilon} (w_j^k - w_i^k) \quad (11)$$

式中, $G$ 为引力常数; $R_{ij}$ 为粒子 $i$ 、 $j$ 的欧式距离; $w_i^k$ 、 $w_j^k$ 分别为粒子 $i$ 、 $j$ 在第 $k$ 维上的位置; $M_j$ 为粒子 $j$ 的惯性质量; $N_a$ 为迭代 $t$ 次后的烟花粒子数。

(3) 在合力作用下,粒子的加速度 $a_i^k$ 见式(12)。在下次迭代中,粒子位移后的空间位置为 $v_i$ 。

$$a_i^k = \frac{F_i^k(t)}{M_i} \quad (12)$$

(4) 根据式(13)和式(14)更新下一次迭代在第 $k$ 维的速度 $v_i^k(t+1)$ 和位置 $x_i^k(t+1)$ 。

$$v_i^k(t+1) = \text{rand}_i \times v_i^k(t) + a_i^k(t) \quad (13)$$

$$x_i^k(t+1) = x_i^k(t) + v_i^k(t+1) \quad (14)$$

式中, $\text{rand}_i$ 为 $[0,1]$ 服从均匀分布的随机变量。

### 2.2.2 混合变异策略

在优化算法中,前期须具备较好的全局搜索能

力,中后期为加速收敛,应具备较好的局部搜索能力。柯西分布在原点峰值较小,两翼平缓,宽于高斯分布,产生变异步长大于高斯分布,更有利于跳出局部最优,从而提高烟花算法的全局搜索能力。因此,在FWA中引入混合变异算子,在加快算法收敛速度的同时还可以兼顾全局搜索能力,可以有效提高算法的搜索精度。标准柯西概率密度函数见式(15)。

$$f_{\text{cauchy}}(x;0,1) = \frac{1}{\pi(1+x^2)}, -\infty < x < \infty \quad (15)$$

为实现不同阶段两种变异算子的切换,利用式(16)计算动态切换概率 $p \in (0.2,0.8)$ 。

$$p = 1 - \frac{0.8(i_{\text{max}} - i_0)}{i_{\text{max}}} \quad (16)$$

式中, $i_0$ 为当前迭代次数; $i_{\text{max}}$ 为最大迭代次数。

在火花变异过程中引入随机数 $r \in [0,1]$ ,若 $p \geq r$ ,则采用高斯变异算子;若 $p < r$ ,则采用柯西变异算子。

## 2.3 极限学习机

极限学习机(ELM)是一种单隐藏层的前馈神经网络(SLFN)<sup>[17]</sup>,ELM采用随机选取输入层权重和隐藏层偏置,输入层权重是通过最小化由训练误差项和输出层权重范数的正则项构成的损失函数,依据Moore-Penrose广义逆矩阵理论计算求得。ELM在随机生成隐藏层节点的同时仍保持着SLFN的通用逼近能力,具有较好的泛化能力和学习速率<sup>[18]</sup>。

训练集 $\{x_i, t_i | x_i \in R^D, t_i \in R^m, i=1,2,\dots,N\}$ ( $x_i$ 为第 $i$ 样本的输入, $t_i$ 为第 $i$ 样本的输出),ELM隐藏节点数为 $L$ ,ELM的结构原理如图1所示。




图1 ELM结构原理

Fig.1 ELM structure principle

隐藏层的输出 $H(x)=[h_1(x),\dots,h_L(x)]$ 是输入层上对应权重加上偏差,再经过激活函数后所有节点求和得到,隐藏层第 $i$ 个节点的输出 $h_i(x)$

由式(17)求得。

$$h_i(x) = g(\omega_i, b_i, x) = g(\omega_i x + b_i) \quad (17)$$

式中,  $g(\omega_i, b_i, x)$  为激活函数,常用的激活函数有 Sigmoid、Gaussian 函数等。

从隐藏层到输出层为  $f_L(x) = \sum_{i=1}^L \beta_i h_i(x) = H(x)\boldsymbol{\beta}$ ,其中  $\boldsymbol{\beta} = [\beta_1, \dots, \beta_L]^T$  是隐藏层到输出层的权重。 $\boldsymbol{\beta}$  的求解过程可以将  $\min \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\|^2$  作为目标函数,目标函数的最小解就是  $\boldsymbol{\beta}$  的最优解。其中  $\mathbf{H}$  为隐藏层的输出矩阵, $\mathbf{T}$  为训练集的目标矩阵。

通过线性代数和矩阵可推导出目标函数的最优解为  $\boldsymbol{\beta}^* = \mathbf{H}^+ \mathbf{T}$ ,其中  $\mathbf{H}^+$  为矩阵  $\mathbf{H}$  的 Moore-Penrose 广义逆矩阵,可由式(18)求得。

$$\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (18)$$

### 2.4 IFWA-ELM 模型的建立

ELM 随机产生输入权值和隐含层阈值,使得模型存在泛化能力较差和预测精度不理想的缺点<sup>[19]</sup>。因此,本文用 IFWA 算法对 ELM 的输入权值和隐含层阈值进行优化,进而建立煤与瓦斯突出 IFWA-ELM 预测模型,流程如图 2 所示。

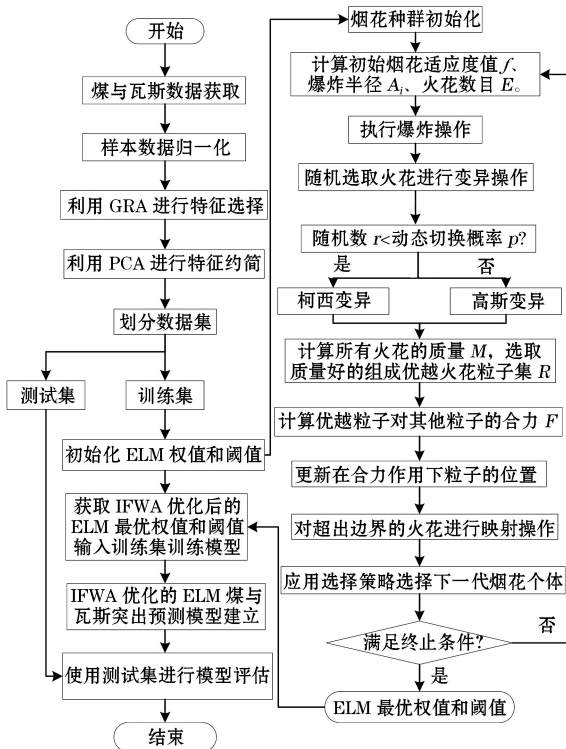


图 2 煤与瓦斯突出 IFWA-ELM 预测模型流程  
Fig.2 IFWA-ELM prediction model process of coal and gas outburst

## 3 试验结果分析

### 3.1 数据来源及评价指标

煤与瓦斯突出数据来源于文献[9],共 50 组数据,取 40 组数据作为训练集进行模型训练,10 组数据作为测试集进行模型评估(见表 1)。根据煤矿作业时现场打孔泄压是否发生喷孔、塌孔等动力现象以及瓦斯压力是否达到阈值,将煤与瓦斯突出划分为 3 个危险指数等级,作为模型的输出,用 0.1 表示“安全”,0.6 表示“一般”,1 表示“严重”。

表 1 煤与瓦斯突出预测数据集

Table 1 Coal and gas outburst prediction data set

序号	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	X <sub>6</sub>	X <sub>7</sub>	X <sub>8</sub>	X <sub>9</sub>	Y
1	3	16.31	0.36	7.85	0.23	3.47	22	365	2.4	0.1
2	3	15.89	0.36	7.66	0.18	3.47	22	366	2.4	0.1
3	3	15.86	0.36	7.48	0.20	3.53	13	369	2.3	0.1
4	3	16.02	0.36	8.66	0.28	3.40	4	365	2.3	0.1
5	3	16.53	0.36	9.70	0.33	3.53	0	365	0	0.6
6	3	16.88	0.36	9.80	0.29	3.47	16	364	2.3	0.6
7	3	17.06	0.36	10.20	0.30	3.27	22	362	2.3	0.6
8	2	17.52	0.28	13.45	0.33	3.80	8	360	2.3	1
9	2	17.50	0.30	10.50	0.37	3.13	20	368	2	0.6
10	2	18.21	0.30	12.88	0.38	3.60	11	363	2	1

利用改进的 ELM 模型对煤与瓦斯突出数据进行回归预测,得到预测的危险指数  $\hat{Y}$ ,若  $\hat{Y} \leq 0.3$ ,划分为“安全”,若  $0.3 < \hat{Y} < 0.8$ ,为“一般”,若  $\hat{Y} \geq 0.8$ ,为“严重”。为评估所构建模型的预测能力和泛化能力,选取平均绝对误差 MAE、均方根误差 RMSE 和决定系数  $R^2$  作为衡量模型性能的指标,计算公式为:

$$MAE = \frac{1}{m} \sum_{i=1}^m |Y_i - \hat{Y}_i| \quad (19)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (Y_i - \hat{Y}_i)^2} \quad (20)$$

$$R^2 = 1 - \frac{\sum_i (\hat{Y}_i - Y_i)^2}{\sum_i (\bar{Y} - Y_i)^2} \quad (21)$$

式中,  $m$  为样本个数;  $Y_i$  为样本实际值;  $\hat{Y}_i$  为样本预测值;  $\bar{Y}$  样本实际平均值。

### 3.2 基于 GRA-PCA 的特征指标选取

#### 3.2.1 基于 GRA 的特征选取

利用均值法对瓦斯数据集进行归一化处理,计



算出瓦斯突出特征变量和瓦斯突出程度之间的关联系数,再计算得到每个指标的灰色关联度。结果见表2。由表2可知,影响因素的特征排序为: $X_4 > X_5 > X_2 > X_6 > X_8 > X_1 > X_3 > X_9 > X_7$ ,特征因素 $X_7$ 对煤与瓦斯突出危险性关联系数最小且明显劣于其他因素。因此,选取 $X_1$ 、 $X_2$ 、 $X_3$ 、 $X_4$ 、 $X_5$ 、 $X_6$ 、 $X_8$ 、 $X_9$ 作为主控因素。

表2 关联度排序

Table 2 Relevance ranking

评价项	关联度	排序
$X_4$	0.892	1
$X_5$	0.874	2
$X_2$	0.847	3
$X_6$	0.842	4
$X_8$	0.834	5
$X_1$	0.833	6
$X_3$	0.798	7
$X_9$	0.792	8
$X_7$	0.697	9

### 3.2.2 基于PCA的特征约简

先对特征选择后的8个影响指标的初始值进行标准化处理,然后利用PCA对致突因素进行降维<sup>[20]</sup>,得到的特征值及贡献率见表3。由表3可知,前5项累计方差解释率为86.407,根据主成分累计方差解释率大于85%的提取原则,选取前5项主成分指标代替原来的8项预测指标。

表3 各主成分贡献率

Table 3 The contribution rates of each principal component

成分	特征值	方差解释率/%	累计方差解释率/%
1	2.715	33.941	33.941
2	1.667	20.838	54.779
3	1.120	14.001	68.78
4	0.833	10.418	79.198
5	0.577	7.209	86.407
6	0.454	5.676	92.083
7	0.423	5.289	97.373
8	0.210	2.627	100

由PCA约简后的主成分与8个初始指标的线性关系为: $Y_1 = -0.158X_1 + 0.197X_2 - 0.303X_3 + 0.318X_4 + 0.295X_5 + 0.101X_6 - 0.112X_7 - 0.035X_8$ ;  $Y_2 = 0.352X_1 + 0.336X_2 + 0.068X_3 + 0.176X_4 - 0.076X_5 - 0.372X_6 - 0.235X_7 + 0.357X_8$ ;  $Y_3 =$

$-0.392X_1 + 0.236X_2 - 0.15X_3 - 0.052X_4 - 0.048X_5 - 0.393X_6 + 0.667X_7 + 0.237X_8$ ;  $Y_4 = -0.365X_1 - 0.247X_2 - 0.028X_3 - 0.016X_4 - 0.162X_5 + 0.42X_6 - 0.209X_7 + 0.871X_8$ ;  $Y_5 = 0.324X_1 + 0.575X_2 + 0.604X_3 - 0.03X_4 + 0.413X_5 + 0.695X_6 + 0.497X_7 + 0.178X_8$ 。

将特征约简的 $Y_1$ 、 $Y_2$ 、 $Y_3$ 、 $Y_4$ 、 $Y_5$ 作为ELM预测模型的输入,约简后的部分数据见表4。

表4 特征约简后的主成分数据

Table 4 Principal component data after feature approximation

序号	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$
1	2.766	-0.636	0.183	0.031	0.803
2	1.670	0.384	1.935	0.343	-1.183
3	1.869	1.165	-0.086	0.125	-0.748
4	1.515	1.109	-0.511	1.169	-1.081
5	0.129	1.271	1.578	-0.554	2.156
6	0.562	1.460	-0.141	-0.263	1.462
7	2.793	-1.553	-0.672	0.149	0.049
8	0.389	1.795	0.138	-0.474	0.532
9	0.216	1.250	0.580	-0.087	1.026
10	0.880	0.364	1.358	-1.022	-0.398

### 3.3 IFWA-ELM预测模型参数选择

利用特征降维后的数据训练IFWA-ELM模型的性能,首先要确定IFWA的初始参数,设置初始烟花个数 $N=20$ ,维度 $D=36$ ,迭代次数 $t=100$ ,变异火花数 $E=5$ ,爆炸数目限制因子 $a=0.3$ 、 $b=0.6$ ,爆炸数目 $c=6$ ,爆炸半径 $A_i=5$ 。

在IFWA-ELM模型中,性能取决于激活函数和隐含层节点个数。经过GRA-PCA处理后,模型输入为5,先设定隐含层节点个数为6,各激活函数的性能对比见表5。

表5 激活函数性能对比

Table 5 Performance comparison of activation functions

激活函数	隐含层节点数	平均绝对误差	收敛时间/s
Sigmoid	6	0.0693	0.242
Sin	6	0.0807	0.300
Hardlim	6	0.1647	0.260

由表5可知,激活函数为Sigmoid函数时,IFWA-ELM平均绝对误差最小且收敛速度最快。因此,选取Sigmoid函数作为模型的激活函数。

利用Sigmoid函数作为激活函数对隐含层节点

数进行选取,结果如图 3 所示。由图 3 可知,当节点个数为 8 时,误差最小且最接近平缓。因此,选取隐含层节点个数为 8,输入层节点个数为 1。




图 3 隐含层节点数选取

Fig.3 Selection of hidden layer node number

### 3.4 仿真结果分析

利用前 40 组数据进行模型训练,将 IFWA-ELM 与 GA-ELM、PSO-ELM、FWA-ELM 做比较,将绝对误差作为适应度函数,其收敛曲线如图 4 所示。

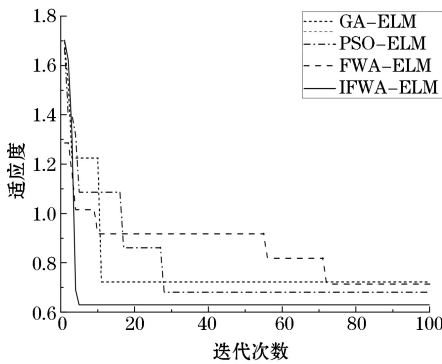


图 4 不同模型适应度曲线

Fig.4 The fitness curves of different models

由图 4 可知,相较于其他优化算法,本文所提出的 IFWA-ELM 模型在寻优能力和收敛速度上都具有较好的表现,验证了本文所提出的多策略改进烟花算法的先进性,从而可以构建出最优的煤与瓦斯突出预测模型。

利用后 10 组数据对模型性能进行评估,以验证在 GRA-PCA 处理下,IFWA-ELM 模型的预测性能,分别将未经 GRA-PCA 处理的数据和经 GRA-PCA 处理的数据作为模型的输入,与 ELM、GA-ELM、PSO-ELM、FWA-ELM 模型进行对比分析,结果见表 6。

表 6 各预测模型结果

模型	未经 GRA-PCA 处理			经 GRA-PCA 处理		
	RMSE	$R^2$	时间/s	RMSE	$R^2$	时间/s
ELM	0.173	0.788	1.125	0.151	0.922	1.117
GA-ELM	0.131	0.895	2.212	0.089	0.942	1.912
PSO-ELM	0.116	0.905	2.258	0.098	0.938	1.985
FWA-ELM	0.113	0.912	2.147	0.085	0.948	1.862
IFWA-ELM	0.105	0.952	2.066	0.074	0.968	1.668

由表 6 分析可知,在预测精度上,相较于单一的 ELM 模型,IFWA-ELM 模型的 RMSE 降低了 0.068, $R^2$  提高至 0.952,与 GA-ELM、PSO-ELM 和 FWA-ELM 模型对比,其 RMSE 和  $R^2$  也都为最优。在预测效率上,ELM 有较好的收敛速度,但精度较差,而 IFWA-ELM 在提升了预测精度的同时兼顾了收敛速度,符合煤与瓦斯突出的预测要求;在数据预处理上,经 GRA-PCA 处理后的数据作为模型输入,相较于未经 GRA-PCA 处理的各个预测模型,GRA-PCA 处理后模型的收敛时间和精度都有所提升,验证了本文所提出的数据预处理方法的合理性。经过对比分析,验证了本文所提出的模型在煤与瓦斯突出预测上具有较好的预测性能。

各模型的危险指数预测结果如图 5 所示。由图 5 可知,IFWA-ELM 模型的预测结果更接近真实值。

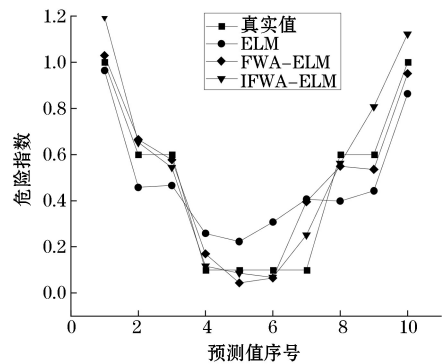


图 5 各模型预测结果对比

Fig.5 Prediction results comparison of each model

根据数据预处理后的 FWA 和 IFWA 优化前后的 ELM 预测结果,对煤与瓦斯突出进行危险等级评估,结果见表 7。由表 7 可知,ELM 将 2 个“安全”样本预测为“一般”样本,FWA-ELM 比单一 ELM 模型的准确率有所提高,但仍存在将“严重”样本预测为“一般”样本的情况,而 IFWA-ELM 预测准确率则达到了 100%,对煤与瓦斯突出危险等级预测效果更佳。

表7 各模型风险等级预测结果

Table 7 The risk level prediction results of each model

序号	实际	ELM	FWA-ELM	IFWA-ELM
1	安全	安全	安全	安全
2	安全	安全	安全	安全
3	安全	一般	安全	安全
4	安全	一般	安全	安全
5	一般	一般	一般	一般
6	一般	一般	一般	一般
7	一般	一般	一般	一般
8	严重	严重	一般	严重
9	一般	一般	一般	一般
10	严重	严重	严重	严重
准确率		80%	90%	100%

## 4 结论

本文利用改进的烟花算法(IFWA)优化极限学习机(ELM),构建了煤与瓦斯突出预测模型,并与其他模型做比较,验证了该模型的预测性能,得到以下主要结论。

(1) 利用 GRA-PCA 进行数据预处理后,IFWA-ELM 模型的 RMSE 和  $R^2$  分别达到了 0.074、0.968,相较于未经 GRA-PCA 处理,均有所提升,且运行时间减少了 0.398 s,在保证预测精确的同时,有效提高了煤与瓦斯突出预测效率。

(2) 经 GRA-PCA 处理后,与 ELM、GA-ELM、PSO-ELM、FWA-ELM 模型相比,IFWA-ELM 模型具有较好的收敛速度,拟合优度  $R^2$  分别提升了 5.0%、2.8%、3.2%、2.1%,预测结果更接近煤与瓦斯突出真实值,危险等级预测的准确率可达 100%,验证了 IFWA-ELM 模型在煤与瓦斯突出预测上的有效性。

### 参考文献(References):

- [1] 张超林,王恩元,王奕博,等.近 20 年我国煤与瓦斯突出事故时空分布及防控建议[J].煤田地质与勘探,2021,49(4):134-141.  
ZHANG Chaolin, WANG Enyuan, WANG Yibo, et al. Spatial-temporal distribution of outburst accidents from 2001 to 2020 in China and suggestions for prevention and control[J]. Coal Geology & Exploration, 2021, 49(4): 134-141.
- [2] 付华,丰胜成,高振彪,等.基于双耦合算法的煤与瓦斯突出预测模型[J].中国安全科学学报,2018,28(3):84-89.  
FU Hua, FENG Shengcheng, GAO Zhenbiao, et al. Study on double coupling algorithm based model for coal and gas outburst prediction[J]. China Safety Science Journal, 2018, 28(3):84-89.
- [3] 李心杰,贾进章,李兵.基于 SAGA-FCM 的煤与瓦斯突出预测方法[J].煤田地质与勘探,2016,44(2):14-18.

- LI Xinjie, JIA Jinzhang, LI Bing, Prediction method of coal and gas outburst based on SAGA-FCM[J]. Coal Geology & Exploration, 2016, 44(2): 14-18.
- [4] 隆能增,袁梅,敖选俊,等.基于 LLE-FOA-BP 模型的煤与瓦斯突出强度预测[J].工矿自动化,2019,45(10):68-73.  
LONG Nengzeng, YUAN Mei, AO Xuanjun, et al. Prediction of coal and gas outburst intensity based on LLE-FOA-BP model[J]. Journal of Mine Automation, 2019, 45(10): 68-73.
- [5] 徐耀松,程业伟.基于 SKPCA 与 NEAT 算法的煤与瓦斯突出危险性预测[J].安全与环境学报,2021,21(4):1427-1433.  
XU Yaosong, CHENG Yewei. Prediction of coal and gas protrusion hazard based on SKPCA and NEAT algorithm[J]. Journal of Safety and Environment, 2021, 21(4): 1427-1433.
- [6] 王雨虹,孙福成,付华,等.基于优化的量子门节点神经网络的煤与瓦斯突出预测[J].信息与控制,2020,49(2):249-256.  
WANG Yuhong, SUN Fucheng, FU Hua, et al. Prediction of coal and gas outburst based on optimized quantum gated neural networks[J]. Information and Control, 2020, 49(2): 249-256.
- [7] 阎馨,吴书文,屠乃威,等.基于逻辑回归和增强学习的煤与瓦斯突出预测[J].控制工程,2021,28(10):1983-1988.  
YAN Xin, WU Shuwen, TU Naiwei, et al. Prediction of coal and gas outburst based on logistic regression and reinforcement learning[J]. Control Engineering of China, 2021, 28(10): 1983-1988.
- [8] 梁运培,郑梦浩,李全贵,等.我国煤与瓦斯突出预测与预警研究综述[J/OL].煤炭学报:1-24. [2022-06-15]. <http://www.mtxb.com.cn/article/doi/10.13225/j.cnki.jccs.2022.0965>.  
LIANG Yunpei, ZHENG Menghao, LI Quanguai, et al. A review on prediction and early warning methods of coal and gas outburst[J/OL]. Journal of China Coal Society: 1-24. [2022-06-15]. <http://www.mtxb.com.cn/article/doi/10.13225/j.cnki.jccs.2022.0965>.
- [9] 王恩元,张国锐,张超林,等.我国煤与瓦斯突出防治理论技术研究进展与展望[J].煤炭学报,2022,47(1):297-322.  
WANG Enyuan, ZHANG Guorui, ZHANG Chaolin, et al. Research progress and prospect on theory and technology for coal and gas outburst control and protection in China[J]. Journal of China Coal Society, 2022, 47(1): 297-322.
- [10] 孙利源.基于灰色关联分析和 PSO-SVM 的煤与瓦斯突出预测应用研究[D].徐州:中国矿业大学,2019  
SUN Liyuan. Application research on the coal and gas outburst prediction based on gray correlation analysis and PSO-SVM[D]. Xuzhou: China University of Mining and Technology, 2019
- [11] 马良玉,王永军,左晓桐,等.基于改进烟花算法优化极限学习机的过热汽温特性建模[J].热能动力工程,2020,35(5):105-111.  
MA Liangyu, WANG Yongjun, ZUO Xiaotong, et al. Modeling of superheated steam temperature characteristics based on extreme learning machine optimized by improved fireworks algorithm[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(5): 105-111.

- [12] 樊永生,连云霞,杨臻.改进烟花算法在虚拟士兵路径规划中的应用[J].计算机工程,2018,44(12):228-232.  
FAN Yongsheng, LIAN Yunxia, YANG Zhen. Application of improved fireworks algorithm in path planning of virtual soldier[J]. Computer Engineering, 2018, 44(12): 228-232.
- [13] 张玮,马焱,赵捍东,等.基于改进烟花-蚁群混合算法的智能移动体避障路径规划[J].控制与决策,2019,34(2):335-343.  
ZHANG Wei, MA Yan, ZHAO Handong, et al. Obstacle avoidance path planning of intelligent mobile based on improved fireworks-ant colony hybrid algorithm[J]. Control and Decision, 2019, 34(2): 335-343.
- [14] 沈西挺,白振东,董瑶,等.基于 dynFWA-SVM 的 WiFi 室内定位算法[J].传感器与微系统,2018,37(4):121-124+128.  
SHEN Xiting, BAI Zhendong, DONG Yao, et al. WiFi indoor localization algorithm based on dynFWA-SVM[J]. Transducer and Microsystem Technologies, 2018, 37(4): 121-124+128.
- [15] 马创涛,邵景峰.烟花算法改进 BP 神经网络预测模型及其应用[J].控制工程,2020,27(8):1324-1331.  
MA Chuangtao, SHAO Jingfeng. Prediction model based on improved BP neural network with fireworks algorithm and its application[J]. Control Engineering of China, 2020, 27(8): 1324-1331.
- [16] 朱启兵,王震宇,黄敏.带有引力搜索算子的烟花算法[J].控制与决策,2016,31(10):1853-1859.  
ZHU Qibing, WANG Zhenyu, HUANG Min. Fireworks algorithm with gravitational search operator[J]. Control and Decision, 2016, 31(10): 1853-1859.
- [17] 陈如清,李嘉春,俞金寿.基于 FWade-ELM 的短时交通流预测方法[J].控制与决策,2021,36(4):925-932.  
CHEN Ruqing, LI Jiachun, YU Jinshou. Short-term traffic flow forecasting based on hybrid FWade-ELM[J]. Control and Decision, 2021, 36(4): 925-932.
- [18] 蒋建东,石洋涛,燕跃豪,等.基于改进烟花算法的极限学习机超短期负荷预测[J].郑州大学学报(理学版),2020,52(4):110-115.  
JIANG Jiandong, SHI Yangtao, YAN Yuehao, et al. Ultra-short-term load forecasting of extreme learning machine based on improved fireworks algorithm [J]. Journal of Zhengzhou University (Natural Science Edition), 2020, 52(4): 110-115.
- [19] 徐耀松,邱微,王治国.基于小波 KPCA 与 IQGA-ELM 的煤与瓦斯突出预测研究[J].传感技术学报,2018,31(5):720-725.  
XU Yaosong, QIU Wei, WANG Zhiguo. Based on the wavelet KPCA with IQGA-ELM coal and gas outburst prediction research [J]. Chinese Journal of Sensors and Actuators, 2018, 31(5): 720-725.
- [20] 刘锋.基于 PCA-SAPSO-BP 神经网络的瓦斯涌出量预测研究[J].煤矿安全,2023,54(4):60-68.  
LIU Feng. Prediction of gas emission based on PCA-SAPSO-BP neural network[J]. Safety in Coal Mines, 2023, 54(4): 60-68.

### Research on Coal and Gas Outburst Prediction Based on Improved Extreme Learning Machine

QIAO Weihao<sup>1</sup>, AN Weipeng<sup>2</sup>, ZHAO Xuehan<sup>1</sup>, LYU Changzhou<sup>1</sup>

(1.School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo, Henan 454000, China;

2.School of Software, Henan Polytechnic University, Jiaozuo, Henan 454000, China)

**Abstract:** In order to improve the accuracy and efficiency of coal and gas outburst prediction, a coal and gas outburst prediction model based on data preprocessing multi-strategy improved fireworks algorithm (IFWA) optimized extreme learning machine (ELM) was proposed. Firstly, for the nonlinear multi-dimensional feature data, the grey relational analysis (GRA) was used for feature selection, the principal component analysis (PCA) was used for feature reduction, and the data index after data preprocessing was used as the input of the model. Secondly, the gravitational search operator and hybrid mutation strategy were introduced to improve the problem that the fireworks algorithm (FWA) was easy to fall into local optimum. Finally, IFWA was used to optimize the weight and deviation from the input layer to the hidden layer of ELM, and the optimal coal and gas outburst risk prediction model was constructed. The results show that the  $RMSE$  and  $R^2$  of IFWA-ELM model can reach 0.074 and 0.968, which are improved compared with ELM, GA-ELM, PSO-ELM and FWA-ELM models. The accuracy of prediction of IFWA-ELM model on coal and gas outburst risk level can reach 100%, which has better convergence speed and prediction accuracy. The research results can provide a reliable theoretical basis for multi-data fusion prediction of coal mine gas outburst.

**Key words:** Coal and gas outburst, Fireworks algorithm, Extreme learning machine, Data preprocessing, Risk prediction model