

基于 PSO-BP 神经网络的煤体瓦斯渗透率预测

邓森^{1,2}, 李希建^{1,2*}, 徐昇泽³

(1. 贵州大学 矿业学院, 贵州 贵阳 550025; 2. 复杂地质矿山开采安全技术工程中心, 贵州 贵阳 550025;

3. 台州市特种设备检验检测研究院, 浙江 台州 318000)

摘要: 为了更加合理地预测煤体瓦斯渗透率, 将粒子群算法 (Particle Swarm Optimization, PSO)、附加动量法与 BP 神经网络 (BP Neural Network) 相结合, 选取影响煤体瓦斯渗透率的 4 个主要因素: 有效应力、瓦斯压力、温度和煤的抗压强度, 建立 PSO-BP 神经网络煤体瓦斯渗透率预测模型。研究表明: 传统 BP 神经网络均方根误差 (Root Mean Squard Error, RMSE) 为 0.135; 基于遗传算法 (Genetic Algorithm, GA) 的神经网络模型均方根误差为 0.068; 基于 PSO 的 BP 神经网络预测法均方根误差为 0.055。相对于其他两种方法, 基于 PSO 的 BP 神经网络预测具有更加广泛的适用性以及更高的精度, 可为预防煤与瓦斯突出以及瓦斯抽采提供更为准确的理论指导。

关键词: 粒子群算法; BP 神经网络; 煤体瓦斯渗透率; 仿真预测

中图分类号: X936 文献标志码: A 文章编号: 1672-9102(2022)04-0035-07

Prediction of Gas Permeability in Coal Body Based on PSO-BP Neural Network

DENG Sen^{1,2}, LI Xijian^{1,2}, XU Bize³

(1. Mining College, Guizhou University, Guiyang 550025, China;

2. Engineering Center for Safe Mining Technology Under Complex Geologic Condition, Guiyang 550025, China;

3. Taizhou Special Equipment Inspection and Testing Institute, Taizhou 318000, China)

Abstract: With the help of the Particle Swarm Optimization (PSO) algorithm, an additional momentum method, and the BP Neural Network (BP Neural Network), a more accurate model for predicting the permeability of coal and rocks has been developed. This model combines the four major factors that affect coal permeability: effective stress, gas pressure, temperature, and the coal's compressive strength. According to the findings, the conventional BP neural network's Root Mean Squard Error is 0.135. The BP neural network prediction approach based on PSO is 0.055, whereas the GA-based neural network model is 0.068. Compared to these two methods, BP neural network prediction based on PSO has a broader application and higher accuracy, which can provide more precise scientific theoretical guidance for the prevention of coal and gas production. BP neural network prediction based on PSO has a larger applicability and higher accuracy compared to these two approaches, which may provide more precise scientific theoretical guidance for the prevention of coal and gas outburst and gas production.

Keywords: particle swarm optimization; BP neural network; gas permeability of coal body; the simulation to predict

煤体瓦斯渗透率是指在一定压差下, 煤体允许瓦斯通过的能力^[1]。在煤矿开采过程中, 由于外力的作

收稿日期: 2021-09-08

基金项目: 国家自然科学基金资助项目 (51874107; 52164015); 贵州省科技计划资助项目 (黔科合平台人才 [2018] 5781 号)

* 通信作者, E-mail: 575914635@qq.com

用使得采场围岩的应力场和渗流场重新分布,导致围岩的渗流运动失稳,极可能造成煤体瓦斯动力灾害^[2].因此,科学预测煤体瓦斯渗透率尤为必要.

影响煤体渗透率的因素很多,代嘉惠等^[3]利用损伤煤岩体渗流试验系统,进行不同轴压、围压和瓦斯压力下煤体渗透率的渗流试验,发现煤样在相同围压条件下时,渗透率与轴压的关系符合二次多项式函数;宫伟东等^[4]用三轴渗流装置对2种原煤样进行瓦斯渗透性试验,在改变单一因素条件下,分别研究围压和瓦斯压力对2种煤样渗透性的影响,结果均反映瓦斯煤体渗透率与有效应力、瓦斯压力、煤体抗压强度有密切联系;李志强等^[5]通过对比试验,阐明不同有效应力条件下煤体渗透率与温度的关系.同时机器学习作为一种全新的技术手段,可以根据含瓦斯煤体渗透率影响因素对煤体瓦斯渗透率做出预测.王攀等^[6]采用MIV算法,对不同影响因素下的煤体瓦斯渗透率进行探究,建立可以准确预测的BP网络模型;王公忠等^[7]利用三轴应力渗流试验装置对特定煤样在受外力破坏以及负压情况下的煤样瓦斯渗透率变化情况进行研究,研究表明在对样本加载负压时的煤体瓦斯渗透率要大于不加载负压时的煤体瓦斯渗透率,并且随着负压增大瓦斯渗透率随之增大;宋曦等^[8]利用随机森林方法并结合影响煤体瓦斯渗透率的主要影响因素,对煤体瓦斯渗透率进行预测研究,得到可以准确预测煤体瓦斯渗透率的预测模型;张炎亮等^[9]将ANFIS模型与BP神经网络相结合,对煤体瓦斯渗透率进行预测,得出精准度高、收敛速度快的预测模型;邵良杉等^[10]通过对有关煤体渗透率的众多研究成果进行总结分析,得出影响煤体渗透率的3个主要因素为有效应力、温度和瓦斯压力,并对煤体瓦斯渗透率进行预测,建立工作面的煤体瓦斯渗透率预测模型;汤国水等^[11]采用改进的人工蜂群算法和支持向量机相结合的方法,对煤体瓦斯渗透率进行研究,建立含煤瓦斯渗透率预测模型.综上所述,这些模型都是基于一种确定型算法并不能解决连续优化问题,而PSO设计之初就是用于解决连续优化问题,其粒子速度更新等相关机制可以很好地对神经网络参数进行优化,因此PSO相比传统算法具有在不同条件和环境下使用的实用性和有效性.

本文提出一种基于PSO和BP神经网络的方法,采用影响煤体瓦斯渗透率的4个主要因素(有效应力、瓦斯压力、温度和煤的抗压强度)作为神经网络的输入层,煤体瓦斯渗透率为输出层进行预测,并通过实例数据和误差分析检验PSO-BP神经网络预测模型的可行性与准确性,得出PSO-BP神经网络模型有效的提升了煤体瓦斯渗透率的预测效果.

1 粒子群算法

PSO是向大自然学习得到的智能算法,其核心思想是对鸟群捕食行为的研究,鸟之间通过相互协作从而达到集体最佳的效果,每个粒子都通过上述方法来对2个极值进行更新,从而形成新一代组合.

把小鸟觅食比作一个粒子 D 维空间进行搜索,根据适应度来判断结果的好坏.假设 D 维空间有 N 个粒子,则粒子的位置,速度,区域最佳点和全局最佳点表达方式如下^[12]:

$$x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{iD}); \quad (1)$$

$$v_i = (v_{i1}, v_{i2}, v_{i3}, \dots, v_{iD}); \quad (2)$$

$$p_{\text{best}i} = (p_{i1}, p_{i2}, p_{i3}, \dots, p_{iD}); \quad (3)$$

$$g_{\text{best}i} = (g_{i1}, g_{i2}, g_{i3}, \dots, g_{iD}). \quad (4)$$

式中: x_i 为粒子 i 位置; v_i 为粒子 i 速度; $P_{\text{best}i}$ 为个体最优位置; $G_{\text{best}i}$ 为全局最优位置.

通常将第 d ($1 \leq d \leq D$)维的位置限定在 $[x_{\min}, x_{\max}]$,速度 v 限定在 $[v_{\min}, v_{\max}]$,若超过了边界则该维的速度和位置会受到限制.粒子 i 在 d 维空间的速度更新公式如式(5)^[13]:

$$v_{id}^k = wv_{id}^{k-1} + c_1r_1(p_{\text{best}id} - x_{id}^{k-1}) + c_2r_2(g_{\text{best}id} - x_{id}^{k-1}). \quad (5)$$

d 维空间中粒子 i 的位置更新公式如式(6):

$$x_{id}^k = x_{id}^{k-1} + v_{id}^{k-1}. \quad (6)$$

式中: v_{id}^k 为粒子 i 第 k 次迭代飞行速度矢量的第 d 维分量; x_{id}^k 为粒子 i 第 k 次迭代飞行位置矢量的第 d 维

分量; c_1, c_2 为加速度常数; r_1, r_2 为两个随机函数; w 为惯性权重.

2 PSO-BP 神经网络预测模型

2.1 BP 神经网络法原理

BP 神经网络模型中,可将各个影响因素作为网络模型输入,煤体瓦斯渗透率作为网络模型最终输出,而 BP 神经网络隐含层节点数 m 是神经网络拓扑结构的核心部分,可由式(7)计算^[14]:

$$m = \sqrt{l + n} + a. \quad (7)$$

式中: m 为 BP 神经网络隐含层节点数; n 为输入层神经元节点数, $n=4$; l 为输出层神经元节点数, $l=1$; a 为隐含层调节常数, $a=1, 2, \dots, 10$. 本文取 $m=4$, 故 BP 神经网络的拓扑结构为 4-4-1. 选取 Sigmoid 函数为激活函数. BP 神经网络相关公式如下:

$$z_j^l = \sum_k^n w_{jk}^l a_k^{l-1} + b_j^l. \quad (8)$$

式中: w_{jk}^l 为第 $(l-1)$ 层的第 k 个神经元连接到第 l 层的第 j 个神经元权重; b_j^l 为第 l 层的第 j 个神经元偏置; z_j^l 为第 l 层的第 j 个神经元的输入; n 为第 l 层的神经元个数.

$$a_j^l = f\left(\sum_k^n w_{jk}^l a_k^{l-1} + b_j^l\right). \quad (9)$$

式中: f 为激活函数; a_j^l 为第 l 层的第 j 个神经元的输出.

由于选用的激活函数为 sigmoid 函数,则式(9)又可以写为式(10).

$$a_j^l = \frac{1}{1 + \exp\left(-f\left(\sum_k^n w_{jk}^l a_k^{l-1} + b_j^l\right)\right)}. \quad (10)$$

代价函数被用来计算神经网络输出值与实际值之间的误差,并更新神经元之间的权重.常用的代价函数是二次代价函数,公式如式(11)所示.

$$C = \frac{1}{2n} \sum_k^n \|y(x) - a^L(x)\|^2. \quad (11)$$

式中: x 为输入样本; y 为实际分类; a^L 为预测的输出; L 为神经网络最大层数; n 为训练样本的个数.

由于 BP 神经网络采用依赖于初始权值的沿梯度下降的搜索求解算法,不恰当的初始权值会增加计算过程反向传播次数和各层权值重置次数,导致 BP 神经网络收敛速度缓慢.当目标函数存在多个极值点时容易陷入局部最优,而粒子群算法具有好的鲁棒性和全局搜索能力,可为 BP 神经网络赋予最合适的权值和阈值,同时可与 BP 神经网络的非线性映射能力结合,大幅度提高网络收敛速度和瓦斯含量预测准确性.

2.2 模型可靠性验证

为验证搭建的 PSO-BP 神经网络模型的准确性和可靠性,采用均方根误差(RMSE)反映模型预测的稳定性,平均绝对误差(MAE)衡量模型的预测精度,平均绝对百分比误差(MAPE)表示预测模型的优劣,计算公式如式(12)~式(14):

$$\text{RMSE} = \frac{1}{M} \sum_{i=1}^M (\hat{y}_i - y_i)^2; \quad (12)$$

$$\text{MAE} = \frac{1}{M} \sum_{i=1}^M |\hat{y}_i - y_i|; \quad (13)$$

$$\text{MAPE} = \frac{1}{M} \sum_{i=1}^M \left| \frac{\hat{y}_i - y_i}{y_i} \right|. \quad (14)$$

式中: M 为样本数量; \hat{y}_i 为预测值; y_i 为实际值.

2.3 PSO-BP 神经网络模型预测步骤

搭建 PSO-BP 预测模型大致流程如下：

1) 对种群进行初始化,对粒子的适应度进行相应的计算,对个体最优位置 p_{best} 和全局最优位置 g_{best} 进行更新,并以整体即指为中心建立禁区.进行小范围搜索.

2) 运行 PSO-BP 预测模型,根据适应度值的计算结果更新变化粒子的个体最优位置 p_{best} 和全局最优位置 g_{best} ,设置收敛精度,使 g_{best} 不断逼近此精度.

3) 若 g_{best} 在收敛精度范围之外,则继续计算粒子的适应度值,更新 p_{best} 和 g_{best} ;若 g_{best} 进入收敛精度范围,则终止计算,并将结果赋值给 BP 神经网络作为神经网络的权值和阈值.根据训练组样本数据训练被赋值的 BP 神经网络,通过验证组样本对结果进行预测.PSO-BP 神经网络模型预测流程图如图 1 所示.

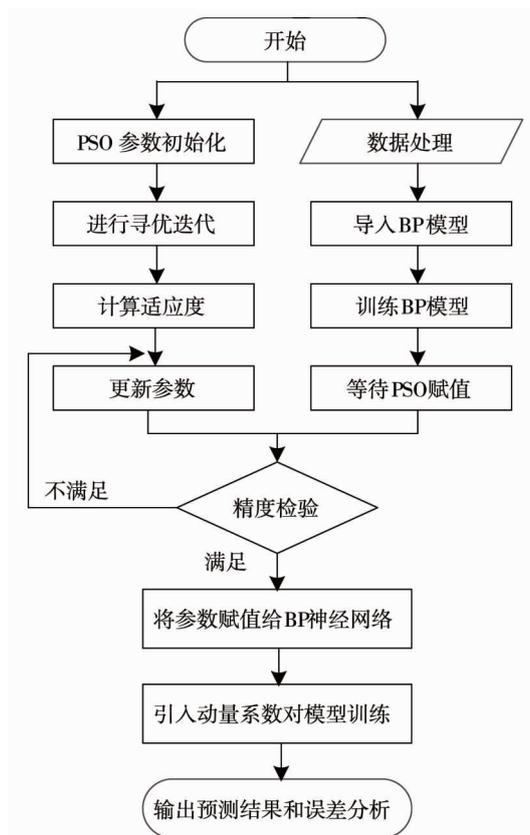


图 1 PSO-BP 预测流程

3 应用实例

煤体瓦斯渗透率受煤体情况和赋存条件等因素共同影响,随着赋存条件的变化而改变.文献[3]利用损伤煤岩体渗流试验系统对煤样进行试验,文献[4]用三轴渗流装置对 2 种原煤样进行了瓦斯渗透性试验,都研究了围压和瓦斯压力对 2 种煤样渗透性的影响;而文献[5]通过对比试验证明了煤体瓦斯渗透率与温度联系,结果均反映瓦斯煤体渗透率与有效应力、瓦斯压力、温度和煤体抗压强度有密切联系.根据上述文献的相关试验以及理论分析可以得知,影响煤体瓦斯渗透率影响因素众多,有效应力、瓦斯压力、温度和煤的矿压强度是影响煤体瓦斯渗透率的主要因素.

因此选取有效应力、瓦斯压力、温度和煤的矿压强度为影响因素.本次研究数据来自文献[11]中的实验数据见表 1,其中 1~35 号样本为训练样本,其余为检验样本来验证预测效果.

煤体瓦斯渗透率受煤层埋深、地质构造、地应力、瓦斯压力等多种因素共同影响^[15-16].相关性分析图是对数据分布情况以及不同因素的相互关系进行直观可视化的一种方法.为了直观反映各种因素的变化情况,将原始数据经过归一化处理得出斯皮尔曼相关性分析图,如图 2 所示,图中颜色越深表示变量之间

正相关性越强,颜色越浅表示变量之间负相关性越强.由图2可知煤体瓦斯渗透率与影响因素之间的关系并非完全的线性相关.

表1 煤体瓦斯渗透率测试数据

序号	有效应力/MPa	瓦斯压力/MPa	温度/°C	煤的抗压强度/MPa	煤体瓦斯渗透率/(10^{-5} m^2)
1	2.00	1.80	40.00	10.85	0.88
2	1.51	0.50	55.00	12.85	1.06
3	4.01	0.50	30.00	14.13	0.55
4	2.50	0.40	70.00	12.62	0.63
5	4.01	0.50	50.00	14.13	0.46
6	3.00	1.00	30.00	12.85	0.56
7	3.62	1.00	50.00	11.62	0.47
8	2.00	1.00	30.00	12.85	0.81
.....
45	2.20	1.20	70.00	11.50	0.56
46	1.45	1.00	70.00	11.50	0.78
47	3.00	0.50	30.00	14.13	0.68
48	3.78	1.00	30.00	12.87	0.49
49	1.73	0.50	30.00	14.13	1.18
50	2.00	1.00	70.00	11.50	0.63

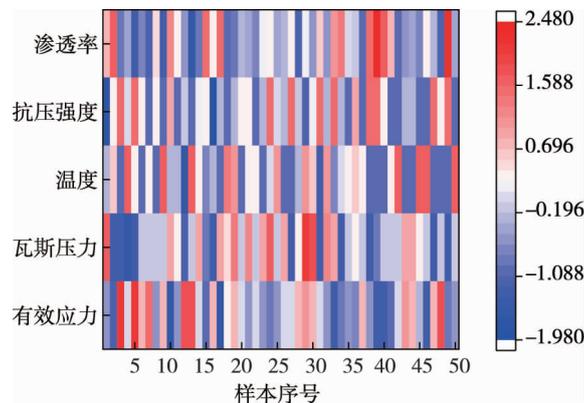


图2 相关性分析

选取表1中的样本数据,将验证组和训练组分别导入模型.设定 PSO 学习因子 $C1$ 为 2, $C2$ 为 2, 权重系数 w 为 0.2, 迭代次数定为 10, 种群数量定为 10 并设定边界, BP 神经网络训练次数为 1 000 次, 学习率为 0.05, 动量系数为 0.8, 误差期望为 0.000 1. 采用 PSO-BP 神经网络对训练集进行模拟, 得到的结果如图 3 所示. 由图 3 可知, 模型对样本数据取得了较好的预测结果, 预测值与训练组真实值大致相吻合, 说明采用 PSO-BP 模型在训练阶段具有优秀的拟合效果.

采用 PSO-BP 神经网络模型对 15 组数据进行验证, 得到的结果如图 4. 由图 4 可知, 预测评价指标 RMSE 为 0.033 121, MAE 值为 0.029 686, MAPE 为 0.041 858, 取得了较为良好的预测结果.

为了证明模型可靠, 将 PSO-BP 神经网络模型, GA-BP 神经网络模型, BP 神经网络模型分别运行, 将 3 者的训练集和验证集的真实值和预测值进行对比, 如图 5 和图 6 所示. 由图 5 分析可知: PSO-BP 神经网络模型, GA-BP 神经网络模型, BP 神经网络模型这 3 种模型在预测值和训练组真实值的对比中都取得良好的拟合效果, 其中 PSO-BP 模型拟合效果最为出众.

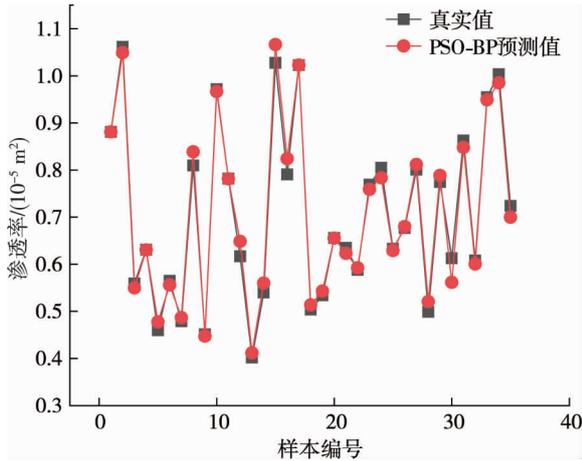


图 3 PSO-BP 模型训练组预测效果

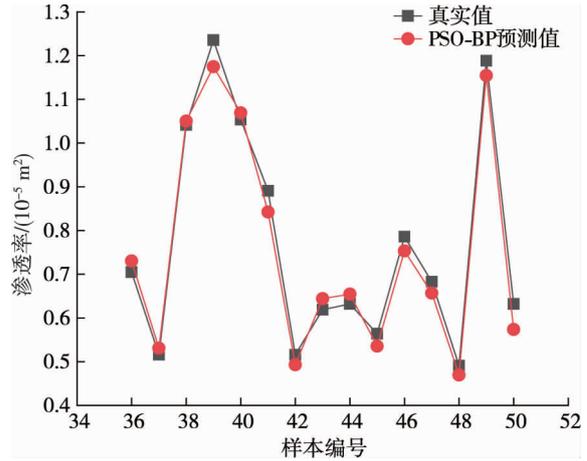


图 4 PSO-BP 模型验证组预测效果

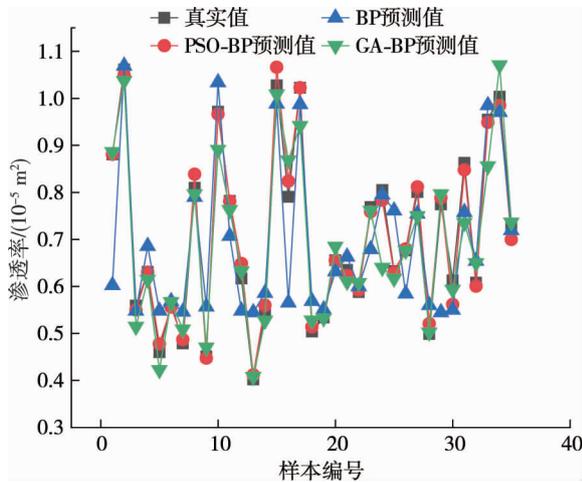


图 5 不同模型的训练组预测对比

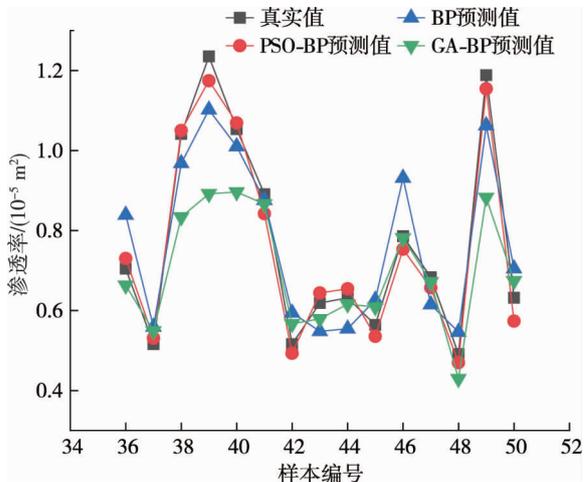


图 6 不同模型的验证组预测对比

PSO 中认知项和社会项前都加有随机数^[20],而 GA 的遗传操作均属随机操作,这 2 种算法是模拟达尔文生物进化理论的自然选择和遗传机械进化过程,但 PSO 算法运算过程中有记忆最优解的能力,并且可以对速度、位置等相应参数进行更新,更适用于解决连续型问题,相对其他的优化算法,PSO 通常能够较快地获得较好的优化结果,更适合与 BP 神经网络模型相结合。

由图 6 分析可知:经过 PSO 优化过的 BP 神经网络在预测准确性方面是优于未经过任何优化的传统 BP 神经网络的;与同样是仿生算法的 GA 相比,经过 PSO 优化的 BP 神经网络准确度更高.说明与传统 BP 神经网络和经过 GA 优化的 BP 神经网络相比,采用附加动量法的 PSO-BP 模型在训练阶段具有优秀的拟合效果。

由于初始权值和阈值是随机产生的,神经网络每次结果有所不同.为了尽量减少这种随机性对试验结果带来的影响,本文分别将 PSO-BP 神经网络模型、GA-BP 神经网络模型、BP 神经网络模型分别运行 30 次,将每次运行程序预测得到的均方根误差 (RMSE),平均绝对误差 (MAPE),平均绝对百分比误差 (MAE) 进行比较得表 2.在 5 次随机实验中,BP 神经网络预测模型的 RMSE,MAPE,MAE 均值分别 0.135,0.115,0.152;GA-BP 神经网络的 RMSE,MAPE,MAE 为 0.068,0.075,0.033;而 PSO-BP 预测模型的 RMSE,MAPE,MAE 分别为 0.055,0.044,0.050.由此可知,整体上 PSO-BP 预测模型的预测结果更加接近于实际情况。

表2 不同模型的误差对比

模型	RMSE	MAPE	MAE
BP	0.249	0.198	0.278
	0.082	0.075	0.098
	0.089	0.079	0.101
	0.141	0.121	0.154
	0.112	0.101	0.128
GA-BP	0.054	0.056	0.039
	0.065	0.071	0.049
	0.075	0.047	0.036
	0.017	0.036	0.029
	0.130	0.165	0.010
PSO-BP	0.038	0.027	0.032
	0.088	0.068	0.083
	0.047	0.039	0.051
	0.049	0.048	0.038
	0.051	0.038	0.048

4 结论

1) 煤体瓦斯渗透率预测模型采用了 PSO 和 BP 神经网络相结合的方法,在原有的 BP 神经网络模型的基础上采用附加动量法,引入动量系数 0.8,模型预测结果与实际值具有较高的吻合度。

2) 相较于 BP 神经网络预测模型和 GA-BP 神经网络模型,PSO-BP 预测模型的预测结果更加接近于实际。

3) 通过 PSO 优化的 BP 神经网络模型的预测结果优于基于 GA 优化的 BP 神经网络模型。

参考文献:

- [1] 卢守青,张永亮,撒占友,等.软硬组合煤体塑性破坏与突出能量失稳判据[J].采矿与安全工程学报,2019,36(3):583-592.
- [2] 胡泊.压应力作用下煤体瓦斯解吸及渗流规律研究[D].北京:中国矿业大学(北京),2016.
- [3] 代嘉惠.多因素对煤体渗透率影响的试验研究[J].煤炭技术,2020,39(6):122-125.
- [4] 宫伟东,解学才,梁跃强,等.2种原煤样渗透性对比试验研究[J].中国安全生产科学技术,2017,13(3):47-52.
- [5] 李志强,鲜学福,隆晴明.不同温度应力条件下煤体渗透率实验研究[J].中国矿业大学学报,2009,38(4):523-527.
- [6] 王攀,杜文凤,冯飞胜.基于影响因素优选的煤层瓦斯渗透率预测模型[J].煤矿安全,2017,48(11):21-25.
- [7] 王公忠,孙光中.连续升温条件下煤样瓦斯渗透特性试验研究[J].中国安全科学学报,2016,26(4):108-113.
- [8] 宋曦,宁云才,丁永禄.基于随机森林的煤体瓦斯渗透率预测研究[J].煤炭技术,2019,38(7):130-132.
- [9] 张炎亮,雷俊辉,毕闰芳.基于 ANFIS 的煤体瓦斯渗透率预测模型研究[J].煤矿开采,2017,22(1):101-104.
- [10] 邵良杉,马寒.煤体瓦斯渗透率的 PSO-LSSVM 预测模型[J].煤田地质与勘探,2015,43(4):23-26.
- [11] 汤国水,张宏伟,韩军,等.基于 MABC-SVM 的含瓦斯煤体渗透率预测模型[J].中国安全生产科学技术,2015,11(2):11-16.
- [12] 邓田,余翼.基于 PSO-Faster R-CNN 改进算法的矿石识别分类研究[J].矿业研究与开发,2021,41(2):178-182.
- [13] 张超,侯男,路敬祎,等.改进的 PSO-VMD 算法及其在管道泄漏检测中的应用[J].吉林大学学报(信息科学版),2021,39(1):28-36.
- [14] 马晟翔,李希建.基于因子分析与 BP 神经网络的煤体瓦斯渗透率预测[J].煤矿开采,2018,23(6):108-111.
- [15] 韩雷,沈春明,王维华.水力切槽钻孔瓦斯涌出特征及渗透率反演分析[J].中国安全科学学报,2021,31(7):105-112.
- [16] 张礼,齐庆新,张勇,等.采动覆岩裂隙场三维形态特征及其渗透特性研究[J].采矿与安全工程学报,2021,38(4):695-705.