

中文引用格式:张建国,王文唱,任连伟,等. 基于SAA-GRNN优化模型的厚松散层条件下概率积分法参数求解[J]. 中国安全科学学报, 2026, 36(5): 18-26.

英文引用格式:Zhang Jianguo, Wang Wenchang, Ren Lianwei, et al. Parameter solution of probability integral method under condition of thick loose layer based on SAA-GRNN optimization model [J]. China Safety Science Journal, 2026, 36(5): 18-26.

基于SAA-GRNN优化模型的厚松散层条件下 概率积分法参数求解*

张建国^{1,2,3}教授级高级工程师, 王文唱^{**1}, 任连伟⁴教授,
邹友峰⁵教授, 顿志林⁴教授

(1 河南理工大学 安全科学与工程学院, 河南 焦作 454003; 2 炼焦煤资源绿色开发全国重点实验室, 河南 平顶山 467002; 3 中国平煤神马控股集团有限公司, 河南 平顶山 467002; 4 河南理工大学 土木工程学院, 河南 焦作 454003; 5 河南理工大学 测绘与国土信息工程学院, 河南 焦作 454003)

中图分类号: X936 文献标志码: A DOI: 10.16265/j.cnki.issn1003-3033.2026.05.0204

基金项目: 国家自然科学基金联合基金重点项目资助(U23A20600); 河南省科技攻关项目(252102320335)。

【摘要】 为解决现有方法在求取厚松散层条件下采空区地表变形预测的概率积分法(PIM)参数时存在精度不高与适配性不足的问题, 选取36组采煤工作面地表移动实测数据, 通过系统聚类分析(HCA)、熵权法(EWM)及灰色关联度(GRD)分析, 筛选采矿地质条件的核心指标, 进而融合K折交叉验证和模拟退火算法(SAA)邻域扰动策略优化广义回归神经网络(GRNN)模型, 构建SAA-GRNN优化模型, 用于求取PIM参数, 并以济宁地区45组厚松散层采煤工作面数据开展实例分析。结果表明: 7项采矿地质条件指标可划分为3类, 经筛选后得到开采厚度 M 、煤层倾角 α 、开采深度 H 、走向采动程度 D_3/H 和松散层厚度 h 共5项核心输入指标; SAA-GRNN优化模型的均方误差最大值不超过0.1904, 平均绝对误差最大值控制在0.1339, 平均绝对百分比误差最大值为0.1536, R^2 值总体控制在0.8以上; 同等条件下较误差反向传播(BP)神经网络模型和GRNN模型, 求解误差均大幅度下降。

【关键词】 模拟退火算法(SAA); 广义回归神经网络(GRNN); 厚松散层; 概率积分法(PIM); 参数求解

Parameter solution of probability integral method under condition of thick loose layer based on SAA-GRNN optimization model

Zhang Jianguo^{1,2,3}, Wang Wenchang¹, Ren Lianwei⁴, Zou Youfeng⁵, Dun Zhilin⁴

(1 College of Safety Science and Engineering, Henan Polytechnic University, Jiaozuo Henan 454003, China; 2 State Key Laboratory of Coking Coal Resources Green Exploitation, Pingdingshan Henan 467002, China; 3 China Pingmei Shenma Holding Group Co., Ltd., Pingdingshan Henan 467002, China; 4 School of Civil Engineering, Henan Polytechnic University, Jiaozuo Henan 454003, China; 5 School of Surveying and Land Information Engineering, Henan Polytechnic University, Jiaozuo Henan 454003, China)

* 文章编号: 1003-3033(2026)05-0018-09; 收稿日期: 2026-01-11; 修稿日期: 2026-03-13

** 通信作者: 王文唱(1996—), 男, 江苏徐州人, 博士研究生, 研究方向为采空区场地建设技术。E-mail: 1269811881@qq.com。

Abstract: To address the problems of low accuracy and insufficient adaptability in existing methods for determining the parameters of PIM for predicting surface deformation prediction in goaf areas under thick unconsolidated layers, 36 sets of measured surface movement data from coal mining working faces were selected. The core indicators of mining-geological conditions were screened via Hierarchical Cluster Analysis (HCA), Entropy Weight Method (EWM) and Grey Relational Degree (GRD) analysis. Furthermore, the GRNN model was optimized by integrating K -fold cross-validation with the neighborhood perturbation strategy of SAA, and an SAA-GRNN optimization model was constructed for PIM parameter determination. A case study was conducted using 45 sets of data from coal mining working faces with thick unconsolidated layers in the Jining area. The results show that: seven mining-geological condition indicators can be classified into three categories, and five core input indicators were identified screening, namely mining thickness M , coal seam dip angle α , mining depth H , strike mining degree D_3/H , and unconsolidated layer thickness h . The maximum root-mean-squared error (RMSE) of SAA-GRNN model is no more than 0.190 4, the maximum mean absolute error (MAE) is controlled within 0.133 9, the maximum mean absolute percentage error (MAPE) is 0.153 6, and the overall coefficient of determination (R^2) is generally above 0.8. Under the same conditions, the prediction errors are greatly reduced compared with those obtained using Back Propagation (BP) neural network and the conventional GRNN model.

Keywords: simulated annealing algorithm (SAA); generalized regression neural network (GRNN); thick unconsolidated layer; probability integral method (PIM); parameter solution

0 引言

矿区煤炭资源高强度开采易引发地表采空塌陷,威胁资源型城市转型与国土空间安全开发^[1-2]。采空区地表变形预测是降低采动损害的关键环节,其中概率积分法 (Probability Integral Method, PIM) 作为地表移动变形计算中理论成熟、应用广泛的方法,其参数取值的可靠性直接决定变形预测结果的有效性^[3],因此,精准求取 PIM 参数具有重要的工程应用价值。

PIM 基于随机介质理论,属非连续介质模型代表,其参数求解方法随非线性方程求解技术的发展可划分为特征点法、线性近似法、正交试验设计及机器学习 4 类^[4]。前 3 类方法存在精度低、收敛性差、效率与适用性不足等缺陷,且高度依赖地表移动变形实测数据。然而,实测数据获取周期长、工作量大、易出现异常与缺失,加之采矿地质条件复杂,固定经验公式难以适配多工况求解需求。以神经网络为代表的机器学习凭借优异的非线性映射、并行处理与自适应能力为 PIM 参数求解提供了新的技术路径^[5]。郭文兵等^[6]验证了实测数据优化训练的可行性。于宁锋^[7]、牛亚超^[8]、吕伟才^[9]、吴满毅^[10]等分别采用混合粒子群、遗传、多种群遗传及麻雀搜索算法优化误差反向传播 (Back Propagation, BP) 神经网络,显著提升了计算精度与收敛速度。此外,学者们通过函数拟合建立了采矿地质条件与

PIM 参数的经验关系^[7-8,11]。然而,现有研究缺乏对采矿地质条件的系统评价,两者关联性的定量刻画仍显不足。

鉴于此,笔者拟采用系统聚类分析 (Hierarchical Cluster Analysis, HCA)、熵权法 (Entropy Weight Method, EWM) 和灰色关联度 (Grey Relational Degree, GRD) 分析法,综合分析采矿地质条件并筛选关键指标,进而选取结构简单、参数易获取的广义回归神经网络 (Generalized Regression Neural Network, GRNN)^[12],用于预测 PIM 参数,通过 K 折交叉验证和模拟退火算法 (Simulated Annealing Algorithm, SAA) 邻域扰动策略优化 GRNN 模型,以提高泛化性和可靠性,为 PIM 参数求取提供新途径,旨在为厚松散层矿区国土空间的安全开发提供科学依据与技术支持。

1 用于 PIM 参数求解的指标筛选方法

1.1 HCA

HCA 通过构建数据对象的层次化聚类结构,将相似的对象逐步分组,最终形成由细到粗的聚类层次^[13-14],适用于探索性分析和小样本数据。

首先,对原始数据进行均值化处理,以消除各指标在量纲和数量级上的差异;其次,将处理后的数据 n 个样本或 p 个指标各视为一类,并确定类与类之间的距离;然后,将最小距离的 2 类合并,并重新计算新类与其他类的距离,且循环进行并类环节直至所有样

本或指标并成一类;最后,根据实际需要进行分类。

1.2 EWM 核心步骤

EWM 是多指标评价中客观赋权的核心方法^[15],适用于数据驱动的科学决策。具体流程如下:

步骤 1: 根据原始数据集建立样本矩阵,记为 $\mathbf{X}=(x_{ij})_{n \times p}$,其中, n 为样本数量, p 为指标项。

步骤 2: 对评价矩阵进行标准化处理,以平衡各指标的差异和量纲在评价中的误差,得到标准矩阵 $\tilde{\mathbf{X}}$,标准化公式为:

$$\tilde{x}_{ij} = \frac{x_{ij} - \min\{x_{1j}, x_{2j}, \dots, x_{nj}\}}{\max\{x_{1j}, x_{2j}, \dots, x_{nj}\} - \min\{x_{1j}, x_{2j}, \dots, x_{nj}\}} \quad (1)$$

步骤 3: 假定标准化后的矩阵仍用 $\mathbf{X}$ 表示,求取各元素在该指标向量中的比重 P_{ij} ,即:

$$P_{ij} = \frac{x_{ij}}{\sum_{i=1}^n x_{ij}} \quad (2)$$

步骤 4: 计算各项指标的熵值 e_j ,表达式为:

$$e_j = -\frac{1}{\ln n} \sum_{i=1}^n P_{ij} \ln(P_{ij}), j = 1, 2, \dots, p \quad (3)$$

式中: $-1/\ln n$ 为熵值系数; e_j 的值域为 $[0, 1]$,若公式中 $P_{ij}=0$,则定义 $e_j=0$ 。

步骤 5: 定义 $1-e_j$ 为信息效用值,对信息效用值进行归一化处理可得该指标的熵权 δ_j ,即:

$$\delta_j = \frac{1 - e_j}{\sum_{j=1}^p (1 - e_j)}, j = 1, 2, \dots, p \quad (4)$$

δ_j 的值越大,说明指标差异程度越大,在影响评价中的作用越大。

1.3 GRD 分析步骤

GRD 是一种基于数据序列几何相似性的关联分析工具,在信息不完全、数据量少的场景中具有独特优势^[16]。步骤如下:

步骤 1: 构建原始分析矩阵 $\mathbf{Z}$,确定其中的对比序列 $\mathbf{X}=(x_{ij})_{n \times p}$ 和参考序列 $\mathbf{Y}=(y_{il})_{n \times s}$,即:

$$\mathbf{Z} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} & y_{11} & y_{12} & \cdots & y_{1s} \\ x_{21} & x_{22} & \cdots & x_{2p} & y_{21} & y_{22} & \cdots & y_{2s} \\ \vdots & \vdots & & \vdots & \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} & y_{n1} & y_{n2} & \cdots & y_{ns} \end{bmatrix} \quad (5)$$

步骤 2: 采用均值化方法进行归一化处理^[17],消除分析矩阵 $\mathbf{Z}$ 的量纲和数量级。

步骤 3: 假定均值化后的标准矩阵仍用 $\mathbf{Z}$ 表示,

为衡量序列间的相似度,以两者绝对差值矩阵 $\Delta_{ij}(k)$ 表示,并计算绝对差的两极值 $\Delta_{\min}$ 和 $\Delta_{\max}$,即:

$$\Delta_{ij}(k) = |y_l(k) - x_j(k)|, k = 1, 2, \dots, n \quad (6)$$

$$\begin{cases} \Delta_{\min} = \min[\min |y_l(k) - x_j(k)|] \\ \Delta_{\max} = \max[\max |y_l(k) - x_j(k)|] \end{cases} \quad (7)$$

式中: $x_j(k)$ 为归一化后对比序列中第 j 列的第 k 个样本; $y_l(k)$ 为归一化后参考序列中第 l 列的第 k 个样本。

步骤 4: 依据序列各点的绝对差值判定两者的关联性;当两者绝对差值越小,距离越近,关联系数越大。关联系数 $\xi_{ij}(k)$ 的表达式如下:

$$\xi_{ij}(k) = \frac{\Delta_{\min} + \rho \Delta_{\max}}{\Delta_{ij}(k) + \rho \Delta_{\max}} \quad (8)$$

式中: $\xi_{ij}(k)$ 为序列间的关联系数,值域位于 $[0, 1]$ 区间; ρ 为分辨系数,取值区间为 $(0, 1)$ 。

步骤 5: 通过关联系数 $\xi_{ij}(k)$ 求均值得到两序列的整体关联度 γ_{ij} ,计算方法如下:

$$\gamma_{ij} = \frac{\sum_{k=1}^n \xi_{ij}(k)}{n} \quad (9)$$

实际应用中,当关联度 $\gamma_{ij} > 0.7$ 时,关联性强,当关联度 $\gamma_{ij} < 0.3$ 时,关联性弱。

2 厚松散层条件核心指标筛选实例分析

2.1 数据来源说明

选取《建筑物、水体、铁路及主要井巷煤柱留设与压煤开采指南》^[18] 中较完整的 36 组采动地表移动实测数据开展分析,其中,厚松散层工作面为 14 组,部分数据信息见表 1。采矿地质条件指标包括覆岩平均坚固性系数 f 、开采厚度 M 、煤层倾角 α 、开采深度 H 、走向采动程度 D_3/H 、倾向采动程度 D_1/H 及松散层厚度 h ; PIM 参数选取下沉系数 q 、水平移动系数 b 、主要影响角正切 $\tan\beta$ 、开采影响传播角 θ 。

2.2 HCA 结果

以表 1 中 7 项采矿地质条件指标为依据,采用组间联接聚类方法对 36 组工作面数据开展 R 型聚类分析,距离度量选用平方欧氏距离,结果如图 1 所示。

聚类结果将 7 项指标分为 3 类:第 1 类(M 、 H 与 h)综合反映煤层、岩层和松散层的深度信息,其

表 1 36 组工作面采矿地质条件指标和 PIM 参数

Table 1 Mining geological condition indicator and PIM parameters of 36 working faces

工作面 序号	采矿地质条件							PIM 参数			
	f	M/m	$\alpha/(\text{ }^\circ)$	H/m	D_3/H	D_1/H	h/m	q	b	$\tan\beta$	$\theta/(\text{ }^\circ)$
1	5.2	2.1	19	110	5.27	1.23	50	0.88	0.3	2	80
2	6	2.4	12	280	2.46	0.46	17.4	0.655	0.282	1.99	86
3	3.2	2.1	30	60.5	6.58	1.98	10	0.66	0.2	1.55	62
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
34	2.315	3.9	1	112.5	24.36	2.62	30	0.513	0.24	1.95	61.4
35	2.45	1.94	9.5	181	1.66	0.56	110	0.86	0.3	1.8	84
36	5	2	34	114.5	1.66	0.54	4.5	0.63	0.24	1.6	65




图 1 采矿地质条件指标聚类分析结果

Fig. 1 Results of cluster analysis of indicators of mining geological conditions

中 H 和 h 首先聚合,进而与 M 聚合;第 2 类(D_3/H 、 D_1/H)表征工作面开采尺寸和采动程度;第 3 类(α 、 f)反映煤层和上覆岩层的相关属性。

2.3 EWM 获取权重

采用 EWM 确定各指标有效权重,结果见表 2。7 项采矿地质条件指标权重分别为 0.045、0.144、0.130、0.121、0.185、0.151 和 0.225,其中, h 权重最大, f 权重最小; M 、 H 与 h 权重合计达 0.489,表明纵向深度指标对矿区地质条件具有显著影响。

2.4 GRD 分析结果

选取表 1 中 7 项采矿地质条件指标作为对比序列,4 项 PIM 参数作为参考序列,GRD 计算结果见表 3。各指标与 PIM 参数的关联度均大于 0.7,表明两者关联性强。

表 2 各指标的信息熵值、信息效用值和权重

Table 2 Information entropy value, information utility value and weight of each indicator

计算结果	f	M/m	$\alpha/(\text{ }^\circ)$	H/m	D_3/H	D_1/H	h/m
信息熵值	0.966	0.891	0.901	0.908	0.859	0.885	0.829
信息效用值	0.034	0.109	0.099	0.092	0.141	0.115	0.171
权重	0.045	0.144	0.130	0.121	0.185	0.151	0.225

表 3 对比序列和参考序列的 GRD 值

Table 3 GRD values for comparison and reference sequences

参数	f	M/m	$\alpha/(\text{ }^\circ)$	H/m	D_3/H	D_1/H	h/m
q	0.898	0.836	0.820	0.841	0.832	0.818	0.780
b	0.873	0.858	0.799	0.828	0.826	0.809	0.786
$\tan\beta$	0.869	0.853	0.790	0.840	0.834	0.815	0.776
$\theta/(\text{ }^\circ)$	0.900	0.849	0.814	0.849	0.832	0.821	0.784
加权关联度	0.159	0.488	0.419	0.407	0.616	0.491	0.702

为客观区分各指标与 PIM 参数的关联程度,融合 EWM 和 GRD 构建加权关联度 ω_j ,在兼顾指标权重客观性的同时,精准分析指标与评价对象的关联性,计算如下:

$$\omega_j = \delta_j \sum_{l=1}^s \gamma_{lj} \tag{10}$$

由表 3 可知:7 项指标加权关联度介于 0.159~0.702,其中, h 和 D_3/H 大于 0.5,与 PIM 参数综合关联性显著; f 加权关联度小于 0.2。 h 权重及加权关联度较大主要源于 14 组厚松散层工作面的数据特征,该结果适用于厚松散层采煤条件。

依据加权关联度排序,选取 h 、 D_3/H 、 D_1/H 、 M

和 α 作为 PIM 参数分析的关键指标。

2.5 输入指标确认

以 7 项采矿地质条件指标和 4 项 PIM 参数为原始数据,开展综合分析和关联度计算。HCA 结果表明,7 项指标可分为 3 类:第 1 类包括 M 、 H 与 h ,第 2 类包括 D_3/H 、 D_1/H ,第 3 类包括 f 、 α 。EWM 计算得到 7 项指标权重分别为 0.045、0.144、0.130、0.121、0.185、0.151 和 0.225,代入 GRD 加权计算,得到 7 项指标加权关联度介于 0.159~0.702,进而依据加权关联度大小选取 h 、 D_3/H 、 D_1/H 、 M 和 α 作

为厚松散层工作面分析 PIM 参数的关键指标。综合考虑工程实际中指标的重要程度和获取难度,最终选取 M 、 α 、 H 、 D_3/H 和 h 共 5 项指标作为厚松散层工作面 PIM 参数求解的输入指标。

3 基于 SAA-GRNN 优化模型的 PIM 参数求解

构建 SAA-GRNN 优化模型,用于 PIM 参数求解,总体思路如图 2 所示。




图 2 基于 SAA-GRNN 优化模型的 PIM 参数求解总体思路

Fig. 2 General idea of parameter prediction of PIM based on an SAA-GRNN optimization model

3.1 GRNN 结构介绍

GRNN 是基于径向基函数神经网络的改进型神经网络^[19],具有强非线性映射和函数逼近能力,在样本有限和数据波动条件下仍能保证高度鲁棒性、快速收敛和良好预测精度。

GRNN 由输入层、模式层、求和层和输出层组成,构成数据传输和计算的主流程。光滑因子 σ 是影响网络性能的重要参数,直接控制模型泛化能力和学习效果^[20],需通过调优获取。选用 K 折交叉验证在可行解中寻找最优值^[21]。

3.2 SAA-GRNN 优化模型

SAA 是一种运用 Monte Carlo 迭代求解策略进行扰动寻优的算法^[22],将 SAA 与 GRNN 融合,用于求解 PIM 参数。首先,以 GRNN 模型为主体,采用

K 折交叉验证超参数调优 σ 值;进而将当前最优值作为 SAA 初始值,通过随机扰动和迭代求解、依随机概率原则接受新解,通过局部寻优获取 σ 最优值;最后,采用 4 项评价指标直观展示参数求解的稳定性和准确性,验证模型的鲁棒性和泛化能力。

3.3 模型精度评价指标

选取对数据误差敏感的 3 项误差指标和 R^2 作为评价指标,即均方误差 (Root-Mean-Square Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 和平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE),值越小表明模型求解精度越高^[23]。此外,采用 R^2 衡量求解值和真实值的相关性^[24],其值越接近 1,表明回归曲线与真实值的相关信息越多,求解效果越好。

4 PIM 参数求解实例分析

4.1 样本数据说明

选取济宁地区 45 组厚松散层采煤工作面数

表 4 济宁地区 45 个采煤工作面信息

Table 4 Basic information of 45 coal mining faces in Jining area

工作面 序号	采矿地质条件					PIM 参数			
	M/m	$\alpha/(^{\circ})$	H/m	D_3/H	h/m	q	b	$\tan\beta$	θ_k
1	7.4	4	548	1.69	155	0.9	0.25	1.6	0.6
2	3.2	11	490	1.72	300	0.86	0.3	2.2	0.3
3	8.7	6	418	2.49	202	0.82	0.33	2.2	1.5
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
43	3.25	6	1 010	1.29	212	0.82	0.28	1.85	0.5
44	8.72	6	437	6.44	200	0.83	0.27	2.2	0.5
45	5.28	12	450	0.89	400	1	0.28	1.8	0.6

以 5 项采矿地质条件指标为输入序列,4 项 PIM 参数为输出序列。考虑到各采煤工作面数据相互独立,为充分提取数据变化特征,将归一化后的数据随机交叉变换 7 次,每次选取前 44 组信息作为训练序列,剩余 1 组为测试序列。

4.2 求解模型结果分析

为验证 SAA-GRNN 优化模型的适用性和有效性,选取 BP 神经网络、GRNN 作为对照。经多次优化训练和迭代测试,确定隐藏层单元数分别为 13、8、15 和 10;GRNN 光滑因子 σ 为 1;SAA 初始温度 $t_b=500$ 、结束温度 $t_e=0.01$ 、温度衰减系数 $\tau_a=0.95$ 。

各模型对相同样本连续运行 10 次,剔除极值后取均值作为最终输出。PIM 参数专项求解结果和各测试绝对误差如图 3 和图 4 所示。




图 3 求解结果对比

Fig. 3 Comparison of prediction results

据^[25],其中,采矿地质条件包括 M 、 α 、 H 、 D_3/H 和 h ; PIM 参数包括 q 、 b 、 $\tan\beta$ 、 θ_k ,其中, θ_k 为开采影响传播角系数,与 θ 存在线性函数关系。工作面松散层厚度为 48~400 m,平均厚度 181.9 m,部分信息见表 4。




图 4 3 种模型求解绝对误差值

Fig. 4 Absolute error value of three models

7 组测试样本随机抽取,PIM 参数离散程度较高、无明显规律。由图 3 可知:3 种模型的整体求解性能存在优劣差异,同一输出项的求解准确性也存在变化。其中,BP 神经网络模型仅能获取多元数据大致的线性相关关系,求解的 PIM 参数反映整体变化趋势,误差较大,精度无法满足实际应用;GRNN 参数求解结果波动范围较小,误差大幅降低,求解值总体接近真实值;SAA-GRNN 优化模型求解值贴合真实值走向,除个别求解值外,误差进一步降低,整体性能最优。

由图 4 可知:在求解绝对误差方面,BP 神经网络为 0~0.81,GRNN 为 0.01~0.58,SAA-GRNN 优化模型为 0~0.37。在求解性能方面,GRNN 结构相对简单,能充分利用有限样本信息,性能相对稳定,

但固定的光滑因子 σ 值,难以适应测试复杂度变化,制约泛化能力;SAA-GRNN 优化模型经交叉训练和 SAA 验证,自适应寻优 σ 值,模型稳健性显著提升,适用于 PIM 参数多元数据求解。

4.3 求解模型精准评价

为进一步验证 SAA-GRNN 优化模型的求解精度与可靠性,以测试次数分组计算 3 种模型的误差

评价指标,结果见表 5。SAA-GRNN 的 RMSE、MAE、MAPE 最大值分别为 0.190 4、0.133 9、0.153 6,均显著低于 BP 神经网络(0.407 9、0.226 9、0.321 6)与 GRNN(0.301 2、0.211 8、0.222 2);平均值较 BP 神经网络分别降低 63.6%、62.7%、62.2%,较 GRNN 分别降低 46.5%、47.1%、33.9%,求解误差大幅收敛,稳健性与准确度优势显著。

表 5 3 种模型的求解误差评价指标对比

Table 5 Comparison of evaluation indexes of solution error of three models

测试次数	BP			GRNN			SAA-GRNN		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
1	0.301 2	0.196 1	0.320 5	0.124 6	0.095 3	0.122 3	0.034 5	0.028 5	0.074 9
2	0.209 8	0.162 4	0.174 6	0.301 2	0.211 8	0.222 2	0.190 4	0.133 9	0.153 6
3	0.234 3	0.168 5	0.114 3	0.213 5	0.152 2	0.106 0	0.160 8	0.091 0	0.051 5
4	0.159 4	0.144 8	0.210 6	0.114 9	0.079 4	0.082 2	0.042 8	0.033 9	0.048 5
5	0.177 1	0.139 9	0.153 9	0.155 3	0.125 5	0.134 4	0.061 9	0.053 2	0.087 7
6	0.076 4	0.058 7	0.060 0	0.092 0	0.059 2	0.057 6	0.024 8	0.021 0	0.033 1
7	0.407 9	0.226 9	0.321 6	0.063 8	0.051 2	0.051 3	0.054 7	0.048 1	0.063 8

对比 3 种模型的拟合优度, R^2 计算结果如图 5 所示。BP 神经网络模型 R^2 波动剧烈,求解稳定性差;GRNN 模型个别测试出现求解失准,但整体优于 BP 神经网络;SAA-GRNN 优化模型的 R^2 总体维持在 0.8 以上,平均值较 BP 神经网络和 GRNN 模型分别提升 9.7%、8.5%,波动幅度较小,表明其能有效获取最优解,稳定程度优于对照模型。




图 5 3 种模型 R^2 值对比

Fig. 5 Comparison of R^2 values of three models

综合 4 项评价指标,SAA-GRNN 优化模型在多次测试中均表现出较低的求解误差和较优的拟合性能。其优势源于 K 折交叉验证深入挖掘采煤工作面复杂时空信息,自适应优化光滑因子 σ ;SAA 改进神经网络训练中的梯度变化问题,启发式和随机扰动策

略进一步提升适用性和稳定性。上述因素协同优化,使 SAA-GRNN 优化模型在厚松散层采矿地质条件下的 PIM 参数求解中性能突出,适用于特殊采矿地质条件且整体求解精度显著提升。

5 结 论

1) 通过 HCA、EWM 和 GRD 分析,从 7 项采矿地质条件指标中筛选出 M 、 α 、 H 、 D_3/H 和 h 共 5 项核心输入指标,明确松散层厚度是影响厚松散层条件下 PIM 参数取值的关键因素。

2) 融合 K 折交叉验证和 SAA 邻域扰动策略有助于优化 GRNN,消除固定光滑因子在厚松散层采矿地质条件下 PIM 参数求解中的适配性偏差,所构建的 SAA-GRNN 优化模型适用于厚松散层条件下 PIM 参数的定量求解。

3) 与 BP 神经网络和 GRNN 模型相比,SAA-GRNN 优化模型的求解误差最低、拟合相关度最高, RMSE 平均值较二者分别降低 63.6%、46.5%, MAE 平均值分别降低 62.7%、47.1%, MAPE 平均值分别降低 62.2%、33.9%; R^2 平均值分别提升 9.7%、8.5%,且总体维持在 0.8 以上。上述结果验证了 SAA-GRNN 优化模型在厚松散层工作面 PIM 参数求解中的适用性与优越性。

参 考 文 献

[1] 邓奇根, 项思思, 周茵子, 等. 煤层硫化氢含量测定装置及方法综述[J]. 中国安全科学学报, 2024, 34(9): 99-106.

- Deng Qigen, Xiang Sisi, Zhou Yinzi, et al. Review for measuring hydrogen sulfide content in coal seams[J]. China Safety Science Journal, 2024, 34(9):99-106.
- [2] 杨可明, 李婷婷, 马军, 等. 基于最优PS点获取方法的矿山工业广场沉降监测[J]. 中国安全科学学报, 2024, 34(5):44-51.
- Yang Keming, Li Tingting, Ma Jun, et al. Monitoring of settlement in mining industrial square based on optimal PS point acquisition method [J]. China Safety Science Journal, 2024, 34(5):44-51.
- [3] 顿志林, 王文唱, 邹友峰, 等. 基于时间函数组合模型的采空区地表沉降动态预测及剩余变形计算[J]. 煤炭学报, 2022, 47(增刊1):13-28.
- Dun Zhilin, Wang Wenchang, Zou Youfeng, et al. Dynamic prediction of goaf surface subsidence and calculation of residual deformation based on time function combination model[J]. Journal of China Coal Society, 2022, 47(S1):13-28.
- [4] 谭志祥, 杨嘉威, 邓喀中. 基于SBAS-InSAR的矿区全盆地开采沉陷求参方法研究[J]. 煤炭科学技术, 2021, 49(1):312-318.
- Tan Zhixiang, Yang Jiawei, Deng Kazhong. Study on method of mining subsidence parameters calculating for whole basin of mining area based on SBAS-InSAR[J]. Coal Science and Technology, 2021, 49(1):312-318.
- [5] 查剑锋, 冯文凯, 朱晓峻. 基于遗传算法的概率积分法预计参数反演[J]. 采矿与安全工程学报, 2011, 28(4):655-659.
- Zha Jianfeng, Feng Wenkai, Zhu Xiaojun. Research on parameters inversion in probability integral method by genetic algorithm[J]. Journal of Mining & Safety Engineering, 2011, 28(4):655-659.
- [6] 郭文兵, 邓喀中, 邹友峰. 概率积分法预计参数选取的神经网络模型[J]. 中国矿业大学学报, 2004, 33(3):322-326.
- Guo Wenbing, Deng Kazhong, Zou Youfeng. Artificial neural network model for predicting parameters of probability-integral method[J]. Journal of China University of Mining & Technology, 2004, 33(3):322-326.
- [7] 于宁锋, 杨化超. 基于粒子群优化神经网络的概率积分法预计参数的确定[J]. 测绘科学, 2008, 33(2):78-80.
- Yu Ningfeng, Yang Huachao. Optimal selection of prediction parameters for probability-integral method using particle swarm optimization and BP neural network[J]. Science of Surveying and Mapping, 2008, 33(2):78-80.
- [8] 牛亚超, 徐良骥, 张坤, 等. 基于GA-BP神经网络的概率积分法预计参数研究[J]. 金属矿山, 2019(10):99-106.
- Niu Yachao, Xu Liangji, Zhang Kun, et al. Study on the predicted parameters of probability integral method based on GA-BP neural network[J]. Metal Mine, 2019(10):99-106.
- [9] 吕伟才, 黄晖, 池深深, 等. 概率积分预计参数的神经网络优化算法[J]. 测绘科学, 2019, 44(9):35-41.
- Lyu Weicai, Huang Hui, Chi Shenshen, et al. Neural network optimization algorithm for the prediction parameters of probability integral method[J]. Science of Surveying and Mapping, 2019, 44(9):35-41.
- [10] 吴满毅, 徐良骥, 张坤. 基于SSA-BP神经网络的概率积分法预计参数求取研究[J]. 金属矿山, 2022(8):182-189.
- Wu Manyi, Xu Liangji, Zhang Kun. Estimated parameter extraction research of probabilistic integration method based on SSA-BP neural network[J]. Metal Mine, 2022(8):182-189.
- [11] 张丰, 吴志聪, 张岩, 等. 济宁城市规划区开采沉陷概率积分法参数综合研究[J]. 煤炭科学技术, 2020, 48(10):150-157.
- Zhang Feng, Wu Zhicong, Zhang Yan, et al. Comprehensive study of parameters of probability integral method of mining subsidence in urban planning areas of Jining city[J]. Coal Science and Technology, 2020, 48(10):150-157.
- [12] 李建林, 高培强, 王心义, 等. 基于混沌-广义回归神经网络的矿井涌水量预测[J]. 煤炭科学技术, 2022, 50(4):149-155.
- Li Jianlin, Gao Peiqiang, Wang Xinyi, et al. Prediction of mine water inflow based on chaos-generalized regression neural network[J]. Coal Science and Technology, 2022, 50(4):149-155.
- [13] 王东, 杜涵, 王前领. 基于系统聚类-加权马尔科夫耦合模型滑坡预警方法研究与应用[J]. 煤炭学报, 2020, 45(5):1783-1794.
- Wang Dong, Du Han, Wang Qianling. Research and application for early warning of landslides based on hierarchical clustering coupling weighting Markov chain model[J]. Journal of China Coal Society, 2020, 45(5):1783-1794.
- [14] 杨兆彪, 秦勇, 张争光, 等. 基于聚类分析的多煤层煤层气产层组合选择[J]. 煤炭学报, 2018, 43(6):1641-1646.

- Yang Zhaobiao, Qin Yong, Zhang Zhengguang, et al. Production layer combination selection for coalbed methane development in multi-coal seams based on cluster analysis [J]. Journal of China Coal Society, 2018, 43(6): 1 641–1 646.
- [15] 侯恩科, 纪卓辰, 车晓阳, 等. 基于改进 AHP 和熵权法耦合的风化基岩富水性预测方法[J]. 煤炭学报, 2019, 44(10): 3 164–3 173.
- Hou Enke, Ji Zhuochen, Che Xiaoyang, et al. Water abundance prediction method of weathered bedrock based on improved AHP and the entropy weight method[J]. Journal of China Coal Society, 2019, 44(10): 3 164–3 173.
- [16] 白利娜, 曾家瑶, 高为. 基于灰色关联分析的盘关向斜煤层气有利井区优选[J]. 煤炭科学技术, 2019, 47(4): 169–173.
- Bai Lina, Zeng Jiayao, Gao Wei. Optimization of favorable well for CBM based on grey correlation analysis in Panguan syncline[J]. Coal Science and Technology, 2019, 47(4): 169–173.
- [17] 徐雅静, 汪远征. 主成分分析应用方法的改进[J]. 数学的实践与认识, 2006, 36(6): 68–75.
- Xu Yajing, Wang Yuanzheng. The improvement of the application method of principle component analysis [J]. Mathematics in Practice and Theory, 2006, 36(6): 68–75.
- [18] 胡炳南, 张华兴, 申宝宏. 建筑物、水体、铁路及主要井巷煤柱留设与压煤开采指南[M]. 北京: 煤炭工业出版社, 2017: 99–158.
- [19] 黎峻宇, 姚宜斌, 刘立龙, 等. 基于多源数据和广义回归神经网络的 ZWD 预报模型[J]. 测绘学报, 2023, 52(9): 1 492–1 503.
- Li Junyu, Yao Yibin, Liu Lilong, et al. A predicting ZWD model based on multi source data and generalized regression neural network[J]. Acta Geodaetica et Cartographica Sinica, 2023, 52(9): 1 492–1 503.
- [20] 舒坚, 高素, 陈宇斌. 基于自适应广义回归神经网络的链路质量评估[J]. 计算机研究与发展, 2020, 57(12): 2 662–2 672.
- Shu Jian, Gao Su, Chen Yubin. Link quality estimator based on adaptive general regression neural network[J]. Journal of Computer Research and Development, 2020, 57(12): 2 662–2 672.
- [21] 李龙, 燕旭朦, 张钰声, 等. 采用迁移学习的小样本锂电池荷电状态估算方法[J]. 西安交通大学学报, 2023, 57(11): 142–150.
- Li Long, Yan Xumeng, Zhang Yusheng, et al. Lithium battery state of charge estimation method based on transfer learning [J]. Journal of Xi'an Jiaotong University, 2023, 57(11): 142–150.
- [22] 郭一楠, 崔宁, 程健. 基于 MOPSO-SA 混合算法的矿山微震震源定位方法[J]. 煤炭科学技术, 2020, 48(3): 126–132.
- Guo Yi'nan, Cui Ning, Cheng Jian. Microseismic source localization method based on hybrid algorithm of MOPSO-SA[J]. Coal Science and Technology, 2020, 48(3): 126–132.
- [23] 马天寿, 张东洋, 陈颖杰, 等. 基于神经网络模型的水平井破裂压力预测方法[J]. 中南大学学报(自然科学版), 2024, 55(1): 330–345.
- Ma Tianshou, Zhang Dongyang, Chen Yingjie, et al. Fracture pressure prediction method of horizontal well based on neural network model[J]. Journal of Central South University(Science and Technology), 2024, 55(1): 330–345.
- [24] 倪景峰, 刘雪峰, 邓立军. 矿井通风参数缺失数据插补方法[J]. 煤炭学报, 2024, 49(5): 2 315–2 323.
- Ni Jingfeng, Liu Xuefeng, Deng Lijun. Method for filling missing data of mine ventilation parameters[J]. Journal of China Coal Society, 2024, 49(5): 2 315–2 323.
- [25] 胡绍豪. 济宁市域煤矿采煤沉陷现状及未来十年沉陷状况预测分析[D]. 徐州: 中国矿业大学, 2021.
- Hu Shaohao. Present situation of coal mining subsidence and subsidence prediction in the next ten years of Jining[D]. Xuzhou: China University of Mining and Technology, 2021.



作者简介: 张建国 (1963—),男,河南滑县人,博士,教授级高级工程师,博士生导师,主要从事煤矿灾害治理、瓦斯资源利用和煤矿智能化建设等方面的研究。E-mail: Zhangjg9681@163.com。