

中文引用格式:高飞,梁宁,贾喆,等.基于SSA-RBF神经网络的煤自然发火预测模型[J].中国安全科学学报,2024,34(8):128-137.
英文引用格式:GAO Fei, LIANG Ning, JIA Zhe, et al. Prediction model of coal spontaneous combustion based on SSA-RBF neural network[J]. China Safety Science Journal, 2024, 34(8): 128-137.

基于 SSA-RBF 神经网络的煤自然发火预测模型*

高飞^{1,2}副教授,梁宁¹,贾喆¹,侯青³

(1 辽宁工程技术大学安全科学与工程学院,辽宁葫芦岛 125130;2 矿山热动力灾害与防治教育部重点实验室,辽宁葫芦岛 125130;3 河北冀中能源股份有限公司,河北邢台 054099)

中图分类号:X936 文献标志码:A DOI: 10.16265/j.cnki.issn1003-3033.2024.08.1567

基金项目:国家自然科学基金面上项目资助(51874161)。

【摘要】为解决传统煤自燃预测模型预测状态单一和预测精度不高的问题,提出基于麻雀搜索算法(SSA)优化的径向基(RBF)神经网络煤自然发火预测模型。首先,采用程序升温试验分析煤样指标气随温度的变化特征,将煤自然发火过程按煤温分为缓慢($80 \leq t_i < 120$ °C)、加速($120 \leq t_i < 160$ °C)和激烈($t_i \geq 160$ °C)3个氧化阶段,同时分析这3个阶段指标气与煤温的灰色关联度;其次通过不同维度测试函数检验粒子群算法(PSO)、灰狼算法(GWO)和SSA算法性能;最后利用6个矿区数据验证基于SSA-RBF神经网络的煤自燃预测模型的优越性。结果显示,缓慢氧化阶段CO/ ΔO_2 、CO、C₂H₄这3种指标气体与煤温的灰色关联系数最大;而加速氧化阶段C₂H₄/C₂H₆、CO/ ΔO_2 、CO₂/CO 3种指标与煤温的灰色关联系数最大。3种不同维度函数的测试结果表明:SSA与PSO、GWO相比具有更好的全局搜索能力和稳定性,其收敛速度更快;神经元数量为5个、迭代次数为300次时,SSA-RBF神经网络预测模型对缓慢氧化和加速氧化阶段的预测准确性分别达到了99%和93%。

【关键词】 麻雀搜索算法(SSA); 径向基函数(RBF)神经网络; 煤自然发火; 预测模型; 指标气; 灰色关联度

Prediction model of coal spontaneous combustion based on SSA-RBF neural network

GAO Fei^{1,2}, LIANG Ning¹, JIA Zhe¹, HOU Qing³

(1 School of Safety Science and Engineering, Liaoning Technical University, Huludao Liaoning 125130, China; 2 Key Laboratory of Mine Thermodynamic Disasters and Control of Ministry of Education, Huludao Liaoning 125130, China; 3 Jizhong Energy Group, Xingtai Hebei 054099, China)

Abstract: To solve the problems of single prediction state and insufficient prediction accuracy of the traditional coal spontaneous combustion prediction model, a prediction model based on RBF neural network optimized by SSA was proposed. Firstly, the temperature programmed test was used to analyze the variation characteristics of the index gas of coal samples with temperature. The coal spontaneous combustion process was divided into slow oxidation stage ($80 \leq t_i < 120$ °C), accelerated oxidation stage ($120 \leq t_i < 160$ °C)

and intense oxidation stage ($t_i \geq 160$ °C) with coal temperature as the node. At the same time, the grey correlation degree between the index gas and coal temperature in each stage of coal spontaneous combustion was analyzed. Secondly, the performance of Particle Swarm Optimization (PSO), Grey Wolf Optimization (GWO) and SSA algorithm was tested by different dimension test functions. Finally, the superiority of the RBF neural network optimized by SSA algorithm to the coal spontaneous combustion prediction model was verified by using six mining area data. The results show that the grey correlation coefficients of $\text{CO}/\Delta\text{O}_2$, CO and C_2H_4 with coal temperature are the largest in the slow oxidation stage. The grey correlation coefficient between $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$, $\text{CO}/\Delta\text{O}_2$, CO_2/CO and coal temperature is the largest in the accelerated oxidation stage. The test results of three different dimensional functions show that SSA has better global search ability, stability and faster convergence speed compared with PSO and GWO. When the number of neurons is 5 and the number of iterations is 300, the prediction accuracy of the SSA-RBF neural network prediction model for the slow and accelerated oxidation stages reaches 99% and 93% respectively.

Keywords: sparrow search algorithm (SSA); radial basis function (RBF); coal spontaneous combustion; prediction model; indicator gas; grey relational analysis

0 引言

煤层自然发火是矿井火灾的主要表现形式之一,由煤炭自燃引起的矿井火灾占全部矿井火灾的90%以上,近几年我国每年因煤矿事故导致200多人被困或死亡^[1],因此,预防煤层自燃极其重要。

针对煤自燃的预测主要有测温法、示踪气体法和指标气分析法^[2]等,但煤层的内部温度很难采用测温法直接测量。在煤层发火过程中,会产生一系列反映煤氧化和燃烧程度的指标气,如 CO 、 CO_2 、烷烃、烯烃等。不同氧化阶段所产生的气体种类和气体体积分数有明显差异,通过分析这些气体的组分、体积分数以及变化速率等特性,能够很好地反映煤自燃所处的状态,便于进行煤层火灾的早期预报。印度学者 SAHAY 等^[3]较早提出了数值拟合 CO 体积分数随温度的变化曲线,并加以求导,得出曲线斜率为1的点即为煤自燃的临界温度,但该方法缺乏科学的理论依据。罗海珠等^[4]研究发现,低温氧化过程中 CO 的生成量与煤温之间存在密切的关系,因此, CO 被作为预测煤自燃的指标气体。而姚海飞等^[5]则认为, CO 体积分数容易受风量的影响, CO 作为预测指标,很难准确地预测煤自燃状态。为解决漏风环境造成的指标气数据检测不准的问题,国内外学者提出了以烷烃类气体作为辅助指标气体,以协同预测煤自燃状态。如邓军^[6]、ITAY^[7]等选择了 CO 和 C_2H_4 作为主要预测指标,并将 CH_4 、 O_2 、 C_2H_6 、 $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$ 、 $\text{CO}/\Delta\text{O}_2$ 作为辅助预测指标,对煤自燃过程进行了阶段划分,预测精度大大提高。

由于煤指标气体体积分数与煤温之间存在较为

复杂的非线性关系^[8],因此,学者们试图建立指标气体与煤温之间的联系,找到这种非线性关系。例如:王福生等^[9]采用灰色关联分析法,优选煤体不同温度段的指标气体,建立了指标气体与煤温的函数关系。宋志等^[10]提出借助人工神经网络理论,结合 Matlab 建立煤自燃可能性预测模型,然而该模型仅能预测煤未自燃和自燃2种状态,没有对煤自燃状态进一步分类。徐杨等^[11]采用自组织特征映射神经网络识别采空区煤自燃状态并进行分类,同时建立前馈神经网络预测模型。孟倩等^[12]建立了自燃极限参数的支持向量机预测模型,该模型可较好地判定煤自然发火程度。LI Shuang 等^[13]提出一种改进的灰狼优化支持向量回归煤自燃温度预测模型,并通过数值模拟验证了改进的灰狼优化算法的有效性。虽然利用神经网络方法预测煤自燃状态具有很强的优越性,但是仍然存在一定的缺陷。首先,神经网络构建的煤自燃预测模型存在收敛速度慢、容易陷入局部最优的问题,径向基函数(Radial Basis Function, RBF)神经网络模型有很好的全局搜索能力,但也不能完全避免其陷入局部最优的情况。其次,现有基于神经网络方法,利用 CO 、 CO_2 、 CH_4 、 C_2H_4 、 C_2H_6 等指标性气体预测煤自燃状态时,没有分析指标气体与煤自燃状态的关联程度。实际上,不同阶段产生的指标气体种类不同,各指标气体与煤温的关联程度不同,因此,若能首先分析不同氧化阶段的指标性气体与煤温的关联度,就能根据优选出的指标气体准确地判断煤的自燃状态。

基于此,笔者拟采用程序升温试验分析6种煤样的指标气随特征温度的变化特性,然后采用麻雀

搜索算法(Sparrow Search Algorithm, SSA)优化 RBF 神经网络模型,构建基于 SSA 优化的 RBF 神经网络煤自燃预测模型,以期为准确预测预报煤自燃状态提供理论依据。

1 程序升温试验中指标气释放特征

1.1 煤样准备

试验煤样分别来自山西省的 6 个矿区,分别为两渡煤、高阳煤、柳湾煤、水峪煤、回坡底煤和吕临能化煤,6 个矿区煤种均为烟煤。为避免煤中矿物质干扰煤的自燃过程,经过选煤厂洗涤加工后,得到不含矸石的精煤。将精煤破碎筛分至 0.15 mm,并在

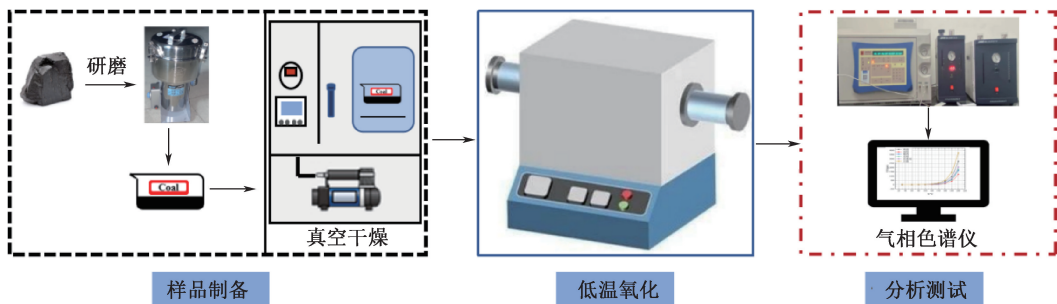


图 1 试验系统

Fig. 1 Experimental system diagram

1.3 指标气的释放特性

煤在程序升温过程中,会释放出 CO、CO₂、烷烃、烯烃等指示性气体,这些气体的产生随煤温上升而发生规律性的变化,因此,能够反映和预测煤自然发火状态^[14-17]。6 种精煤低温氧化过程中指标气体积分数的变化特征如图 2 所示。由图 2 可以看出,6 种煤样低温氧化过程中指标气体积分数的变化特征极为相似,80 °C 时各样品煤中开始出现 CO,并且生成速率较缓慢,O₂ 的含量开始缓慢消耗,说明此时煤开始进入缓慢氧化阶段。

随着温度的升高,120 °C 之后 CO 和 CO₂ 的生成量迅速增加,O₂ 的含量开始快速消耗,并且检测到 C₂H₄、C₂H₆ 和 CH₄ 等烷烃类指标气开始产生,由于煤样本身并不附着 C₂H₄,说明此时煤样开始进入加速氧化阶段。随着煤温的持续升高,各煤样在 160 °C 时 C₂H₄、C₂H₆ 和 CH₄ 等指标性气体的生成量也开始迅速增加,O₂ 的含量急剧消耗,说明煤在 160 °C 以后开始进入激烈氧化阶段。综上所述,将各煤样的自燃过程以温度为节点分为 3 个阶段:120 °C 之前为缓慢氧化阶段,120 ~ 160 °C 之间为加速氧化阶段,160 °C 之后为激烈氧化阶段。

60 °C 下真空干燥 12 h 后待用。

1.2 程序升温试验

采用自制的程序升温系统开展程序升温试验,该系统主要由进气系统、程序升温炉、气体检测系统组成。气体检测由气相色谱仪完成,程序升温炉的入口连接进气系统,出口与气相色谱仪直接相连,气相色谱仪可实时检测气体产物的成分和组成,试验系统如图 1 所示。6 种精煤程序升温试验的参数如下:将 50 g 干燥样品以 1 °C/min 的升温速率进行程序升温,空气流量设定为 100 mL/min,每隔 20 °C 分析 1 次管式炉出口气体成分,升温至 200 °C 后试验结束,关闭升温炉。

2 指标气的优选

2.1 辅助指标气的选取

由程序升温试验可以看出,随着煤温的逐渐升高,在煤氧化过程中有 CO、CO₂、CH₄、C₂H₄、C₂H₆ 等指标气体生成。CO 气体是预测煤早期自燃反应最灵敏的指标之一,但由于 CO 贯穿整个煤氧化阶段,因此,根据单一 CO 气体很难准确区分煤自燃发展到哪个阶段,需结合耗氧量(ΔO₂)的数据综合考虑,即 Graham 系数^[16],其计算过程见下式:

$$\frac{\phi(\text{CO})}{\phi(\text{O}_2)} = 100 \times \frac{\phi(\text{CO})}{0.265 \times \phi(\text{N}_2) - \phi(\text{O}_2)} \quad (1)$$

式中 $\phi(\text{CO})$ 、 $\phi(\text{N}_2)$ 和 $\phi(\text{O}_2)$ 分别为 CO、N₂ 和 O₂ 的体积分数, %。

由图 2 还可以看出,在程序升温氧化试验前期还未检测到 CO 和其他指标气时,CO₂ 体积分数就已经较高了,这说明煤样自身吸附的 CO₂ 初始值过高,在氧化前期 CO₂ 与煤自燃状态并无相关性。张卫亮等^[18]研究发现,在煤氧化升温过程中,CO₂/CO 呈现规律性变化,因此,在选择预测指标时,文中引入 CO₂/CO 作为辅助指标气体,协同预测煤自燃状

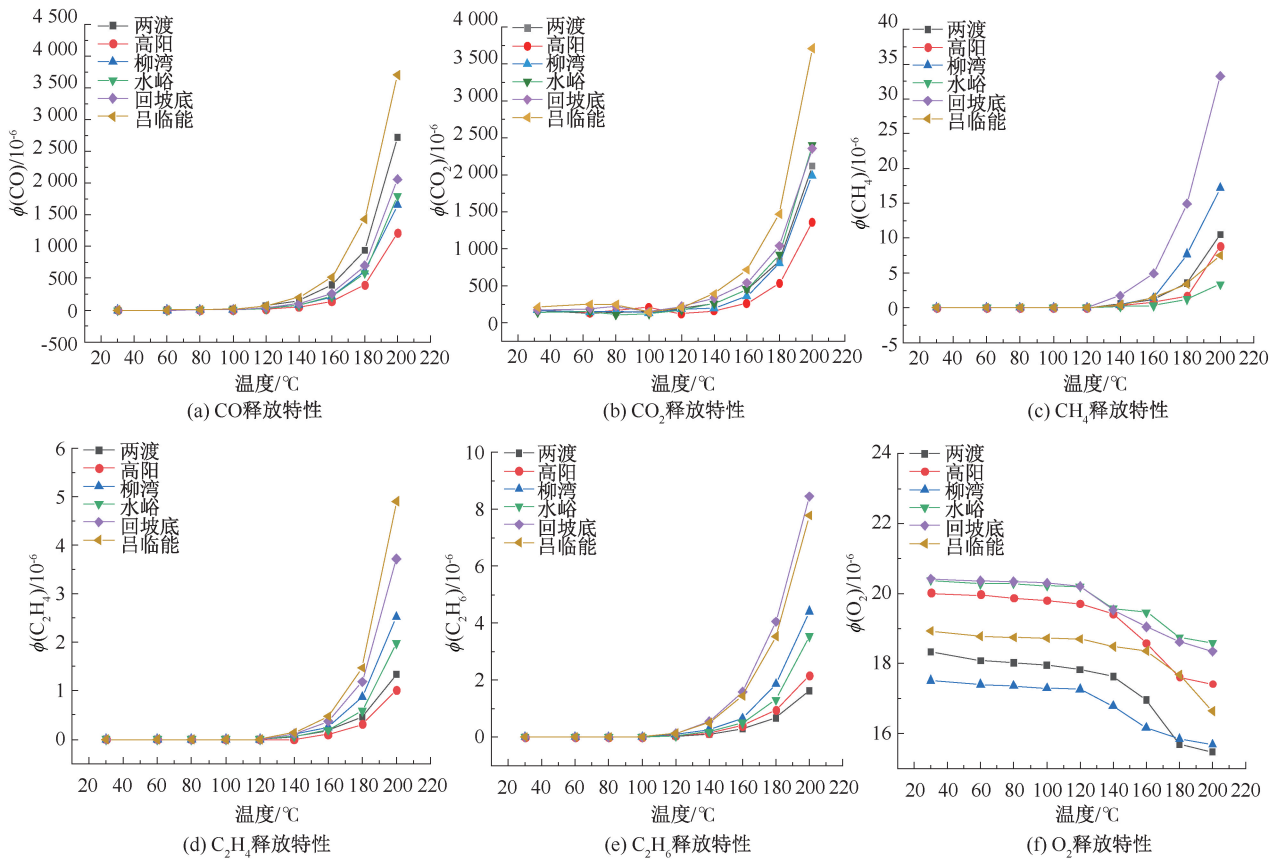


图 2 程序升温过程指标气释放特性

Fig. 2 Index gas release characteristics of temperature programmed process

态。此外,随着煤温的升高,煤氧化自燃反应产生的指标气体种类逐步增多,烷烃类气体的生成成为指标气体的选取提供了多样的选择空间。C₂H₄ 和 C₂H₆ 的出现是煤进入加速氧化阶段的标志,但单一指标气体积分分数通常会受漏风等条件的影响,为了应对煤矿井下新鲜风流对 C₂H₄ 等指标气的影响,在选取预测指标时同时引入大多数学者选用的烷烃比 (C₂H₄/C₂H₆) 作为辅助指标^[2]。

2.2 灰色关联度分析

利用不同指标气预测煤自燃的结果可能不同,甚至预测的结果可能会存在相互矛盾的情况,因此,需要将不同氧化阶段的煤温与指标性气体进行关联度分析。设定程序升温的特征温度作为参考数列,指标气 CO、CH₄、C₂H₄、C₂H₆ 和辅助指标 C₂H₄/C₂H₆、CO₂/CO、CO/ΔO₂ 作为比较数列。关联度系数、关联度值计算过程如下:

$$\xi_i(k) = \frac{\min_i \min_k |t(k) - X_i(k)| + \xi \max_i \max_k |t(k) - X_i(k)|}{|t(k) - X_i(k)| + \xi \max_i \max_k |t(k) - X_i(k)|} \quad (2)$$

$$\gamma_i = \frac{1}{N} \sum_{k=1}^N \xi_i(k) \quad (3)$$

式中: $\xi_i(k)$ 为 X_i 对 t 在 k 时刻的灰色关联度系数,其中, t 为特征温度,℃ (可作为参考序列); X_i 为指标气体积分分数,% (可作为比较序列); ξ 为分辨系数, ξ 越小分辨力越大,取(0,1),一般取 0.5; N 为煤样品种类的数量; γ_i 为灰色关联度的平均值。

灰色关联度越大说明该指标气体与煤低温氧化过程温度的关联程度越大,即该指标气体对煤自燃的表征越准确。温度在 30~120 °C 之间,各指标气体与煤自燃温度的灰色关联度见表 1,从表 1 可以看出,缓慢氧化阶段各指标气与煤温的关联度排序为 CO/ΔO₂ > CO > C₂H₄ = C₂H₄/C₂H₆ > CH₄ > C₂H₆ > CO₂/CO,因此,在 30~120 °C 之间选择 CO/ΔO₂、CO、C₂H₄ 作为预测煤自燃状态的指标气体。加速氧化阶段各指标气与煤温的关联度排序为 C₂H₄/C₂H₆ > CO/ΔO₂ > CO₂/CO > C₂H₆ > CO > CH₄ > C₂H₄,最终在 120~160 °C 之间选择 C₂H₄/C₂H₆、CO/ΔO₂、CO₂/CO 作为预测煤自燃状态的指标气体。由于温度超出 160 °C 之后,煤已经进入激烈氧化阶段,此时预报煤自燃工作已无实际意义,因此,文中只分析

表 1 指标气与煤自燃温度的灰色关联度

Table 1 Grey correlation degree between index gas and coal spontaneous combustion temperature

煤种	30~120 °C							120~160 °C						
	C ₂ H ₄	C ₂ H ₆	CO	CH ₄	C ₂ H ₄ / C ₂ H ₆	CO ₂ /CO	CO/ ΔO ₂	C ₂ H ₄	C ₂ H ₆	CO	CH ₄	C ₂ H ₄ / C ₂ H ₆	CO ₂ /CO	CO/ΔO ₂
两渡	0.691	0.651	0.736	0.650	0.691	0.691	0.771	0.636	0.672	0.653	0.629	0.985	0.767	0.776
高阳	0.643	0.606	0.719	0.643	0.643	0.533	0.731	0.583	0.667	0.603	0.541	0.740	0.712	0.755
柳湾	0.740	0.697	0.767	0.740	0.740	0.612	0.802	0.586	0.644	0.615	0.600	0.927	0.707	0.724
水峪	0.772	0.723	0.805	0.727	0.772	0.646	0.827	0.566	0.613	0.585	0.602	0.976	0.715	0.685
回坡底	0.689	0.646	0.725	0.648	0.689	0.557	0.756	0.573	0.650	0.592	0.638	0.871	0.690	0.689
吕临能	0.674	0.633	0.743	0.702	0.674	0.559	0.780	0.554	0.648	0.609	0.646	0.527	0.720	0.719
平均值	0.702	0.661	0.749	0.685	0.702	0.580	0.778	0.583	0.649	0.610	0.609	0.838	0.719	0.725

30~160 °C之间的指标气体与煤自燃状态的关联度。

3 SSA-RBF 煤自然发火预测模型

3.1 RBF 神经网络预测模型

RBF神经网络的思想是将低维空间非线性不可分问题转换成高维空间线性可分问题。基于RBF神经网络的煤自然发火预测模型,由输入层、隐含层、输出层3个部分组成,其中输入层为指标气数据、隐含层为RBF、输出层为煤自燃所处状态。通过隐含层建立指标气与煤温之间的线性关系,从而判断煤自燃所处阶段。

在使用RBF神经网络预测煤自然发火状态之前,首先把指标气数据按照8:2分为108组训练集

和27组测试集2类,其中缓慢氧化阶段包括60组训练集和15组测试集,加速氧化阶段包括48组训练集和12组测试集。输入层分为CO/ΔO₂、CO、C₂H₄和C₂H₄/C₂H₆、CO/ΔO₂、CO₂/CO 2组,通过2组不同指标气体分别训练预测缓慢氧化阶段和加速氧化阶段,输出层的输出结果为0和1,分别对应着煤自燃未进入某个阶段和已经进入某个阶段,所建的煤自燃阶段预测模型结构如图3所示。明确预测模型后,利用训练好的模型仿真测试测试样本,可以把2组指标气数据同时输入RBF神经网络,模型自行判定煤自燃状态所处阶段。对比试验结果,检验RBF神经网络模型预测煤自然发火状态的准确性。

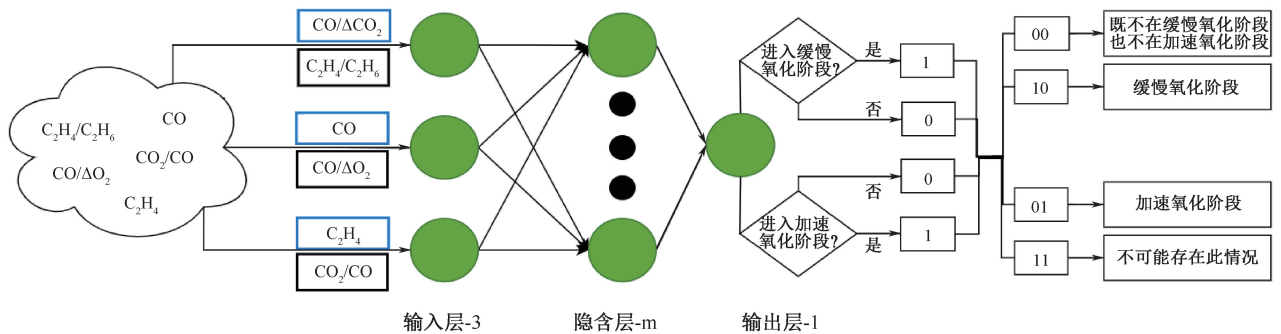


图 3 RBF 神经网络预测煤自燃模型结构

Fig. 3 Structure of coal spontaneous combustion model predicted by RBF neural network

3.2 RBF 神经网络预测模型的优化

为避免RBF神经网络预测模型陷入局部最优解,需优化所建模型中的算法以提高该模型的稳定性和收敛速度。分别选择SSA、PSO、GWO这3种算法优化多种测试函数,测试函数见表2,表2中f₁(x)和f₂(x)为单峰函数,f₃(x)~f₆(x)为多峰函数,f₇(x)和f₈(x)为固定维度函数。3种算法的参数设置相同,总体规模设置为30次,最大迭代次数为500次,

测试函数在每种算法下运行30次,8个被测函数的二维表示曲线和收敛曲线如图4所示,可以快速比较出3种算法的迭代速度和精确度。

在第1组仿真试验中,测试了f₁(x)和f₂(x)2个单峰测试函数,顾名思义单峰函数仅有1个极值点。由图4a可以看出,对于函数f₁(x),SSA的迭代速度很快,在还未迭代到100次时,最优解的误差已经在10⁻⁵以内,继续迭代最优解误差进一步减小。

表 2 8 种测试函数
Table 2 Eight test functions

测试函数	维度	范围	理论最小值
$f_1(x) = \sum_{i=1}^n ([x_i + 0.5])^2$	30	$[-100, 100]$	0
$f_2(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0, 1)$	30	$[-1.28, 1.28]$	0
$f_3(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]$	-12 569.5
$f_4(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
$f_5(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30	$[-32, 32]$	0
$f_6(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600, 600]$	0
$f_7(x) = \left(\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6}\right)^{-1}$	2	$[-65, 65]$	1
$f_8(x) = \left(x_2 - \frac{5.1}{4\pi^2} x_1^2 + \frac{5}{\pi} x_1 - 6\right)^2 + 10 \left(1 - \frac{1}{8\pi}\right) \cos x_1 + 10$	2	$[-5, 5]$	0.398

GWO 的收敛速度和精度虽好于 PSO,但相较于 SSA 的优化精度和收敛速度有明显差距。由图 4b 可以看出,相较于 $f_1(x)$ 而言,函数 $f_2(x)$ 的 SSA 收敛速度和精度变差了,但 SSA 依然比相应的 GWO、PSO 的收敛速度和寻优能力更强,特别是相对于 PSO 优势更为明显。由此可见:对于单峰测试函数,SSA 的收敛速度、寻优能力和局部开发能力更强。

第 2 组试验测试了 $f_3(x) \sim f_6(x)$ 4 个多峰函数,该函数的特点是存在多个极值点,使得算法容易陷入局部最优的情况。由图 4c 可以看出,对于函数 $f_3(x)$,SSA 的初始优化结果较差,但随着迭代次数增加,SSA 的收敛速度和精度迅速提高,相较 GWO、PSO 的收敛速度和全局寻优能力有很大优势。由图 4d 和图 4e 可以看出,对于函数 $f_4(x)$ 和 $f_5(x)$,PSO 的寻优能力很差,GWO 的寻优能力虽比 PSO 要强,但和 SSA 相比其迭代次数过多,意味着收敛速度较慢。此外,由图 4f 也能明显看出,对于函数 $f_6(x)$,SSA 的寻优能力及收敛速度远优于 GWO 和 PSO。由此可知:对于多峰函数,SSA 逃离局部极值的能力及全局搜索的能力均比 GWO、PSO 更强。

第 3 组试验测试了 $f_7(x)$ 和 $f_8(x)$ 2 个固定维度函数,可以更加全面、系统检测 3 种算法的性能。由图 4g 可以看出,对于函数 $f_7(x)$,SSA 在迭代 100 次之后,其最优解的误差比 GWO、PSO 均大,但继续迭

代之后 SSA 的误差小于 GWO,总体而言 PSO 的收敛速度和全局寻优能力更强。由图 4h 可以看出,对于函数 $f_8(x)$,SSA、PSO、GWO 均有很好的收敛速度和寻优能力,但 SSA 的综合能力更强。2 种固定维度函数测试进一步验证了 SSA 收敛速度、精度和稳定性的优越性。

由 3 种不同类型函数的测试结果发现,总体上 SSA 收敛速度明显优于 GWO、PSO,在全局搜索能力上 SSA 较 GWO、PSO 也有很大的提高,减少了陷入局部最优的情况,从而增加预测结果的准确性;而且 SSA 具有很好的稳定性,能够处理大量样本数据且保障正常运行,为提高 RBF 神经网络的稳定性提供了保障。

3.3 SSA-RBF 神经网络预测模型

构建 SSA-RBF 神经网络后,需要通过不断的迭代训练拟合、调整神经元个数以提高预测的准确率。神经元最佳个数一般不应少于输入层单元个数,且小于输入层单元个数的 2 倍。由灰色关联分析可知:输入层数据由 3 种指标气体单元组成,神经元的最佳个数设置为 3~5 个。与此同时,迭代次数过少达不到精度要求,相反如果迭代次数过多会增长模拟训练的时长,因此,迭代次数设置为 300~500 次。为了增加训练样品数量,且更好地模拟现场实际情况,输入数据分别来源于课题组自主设计的程序升

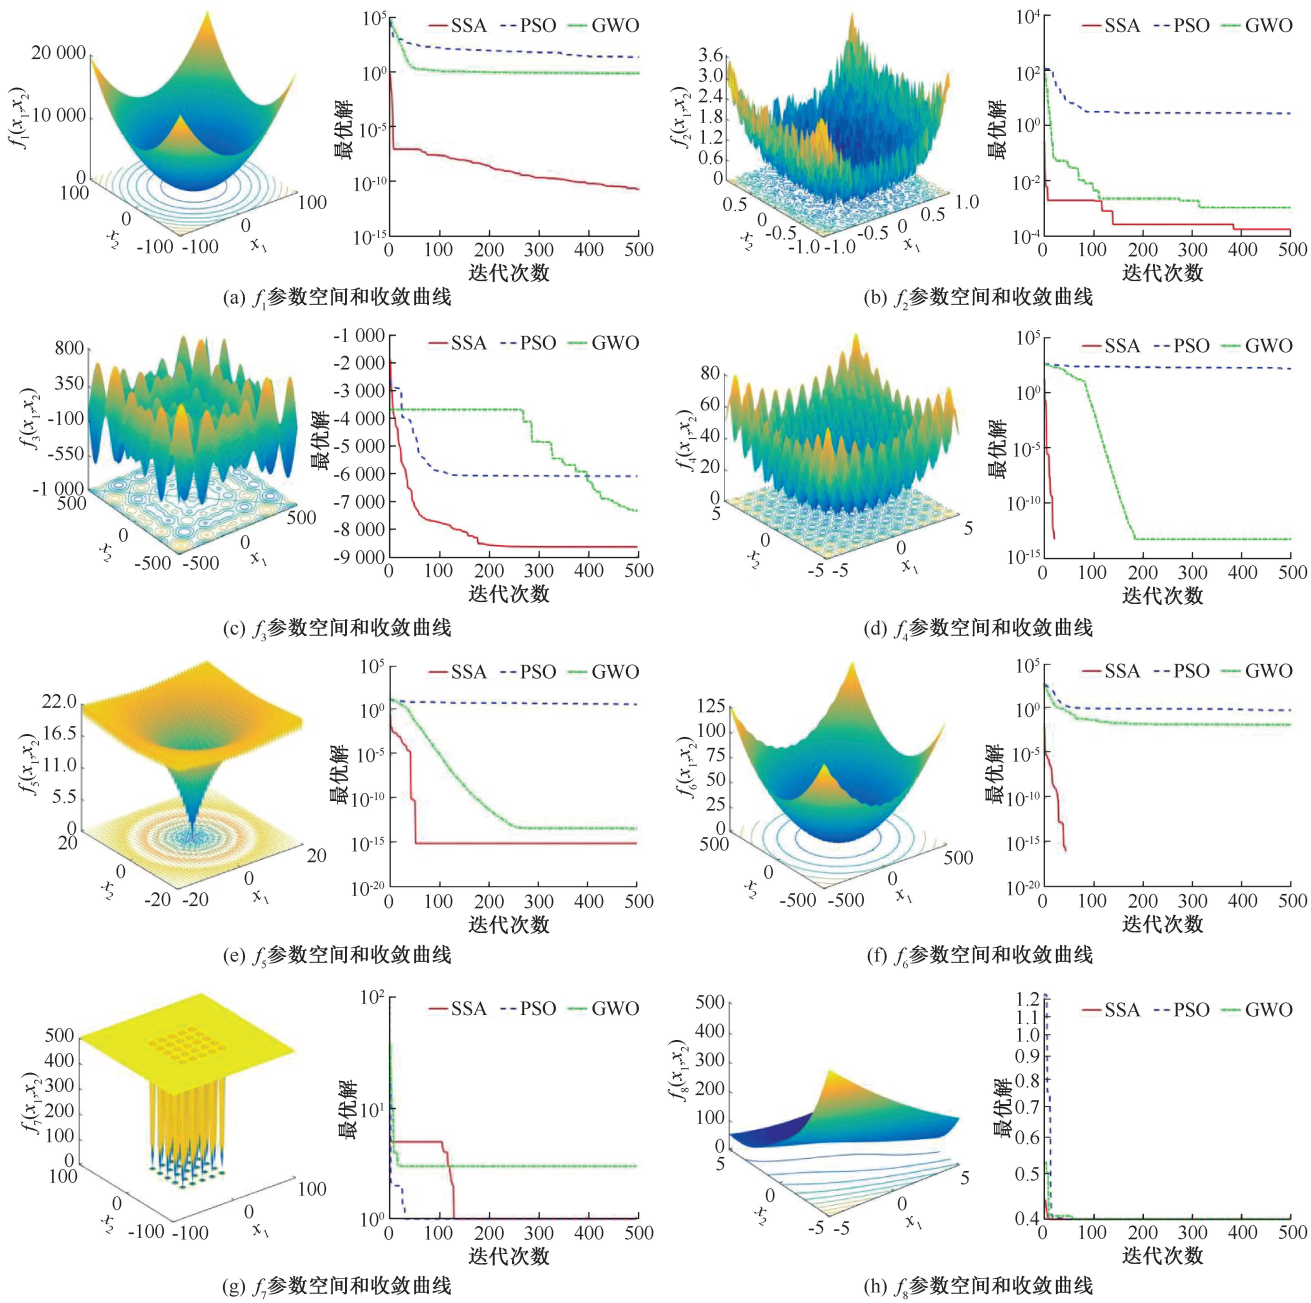


图4 标准函数测试

Fig. 4 Standard function test

温试验和文献[19-20]。

通过上述方式共收集了 30 ~ 160 °C 范围内 15 种煤 135 组各气体体积分数的有效数据,使用 Matlab 软件进行 SSA-RBF 神经网络的模拟仿真。在迭代训练过程中,神经元个数设置为 3 个,迭代次数设置为 300 次,模拟训练结果如图 5 所示。图 5a、图 5b 分别为缓慢氧化阶段的训练集和预测集,图 5c、图 5d 分别为加速氧化阶段的训练集和预测集,横坐标的每 1 个点表示不同煤样品的 1 组指标气数据,纵坐标 0 和 1 表示煤自燃状态。* 代表神

经网络的预测结果,○则表示实际情况,* 和○重合时表示 SSA-RBF 神经网络模型的预测准确。

在图 5a、图 5b 中 0 表示未进入缓慢氧化阶段,1 表示进入缓慢氧化阶段,绝大多数的 * 和○重合,仅有 2 个点预测不准确没有重合,由此可得缓慢氧化阶段的预测准确率达到 97%。在图 5c、图 5d 中 0 表示未进入加速氧化阶段,1 表示进入了加速氧化阶段,其中大多数的 * 和○重合,但有 5 个点预测不准确没有重合,由此可得加速氧化阶段的预测准确率为 89%。依次改变神经元的个数和迭代次数,找

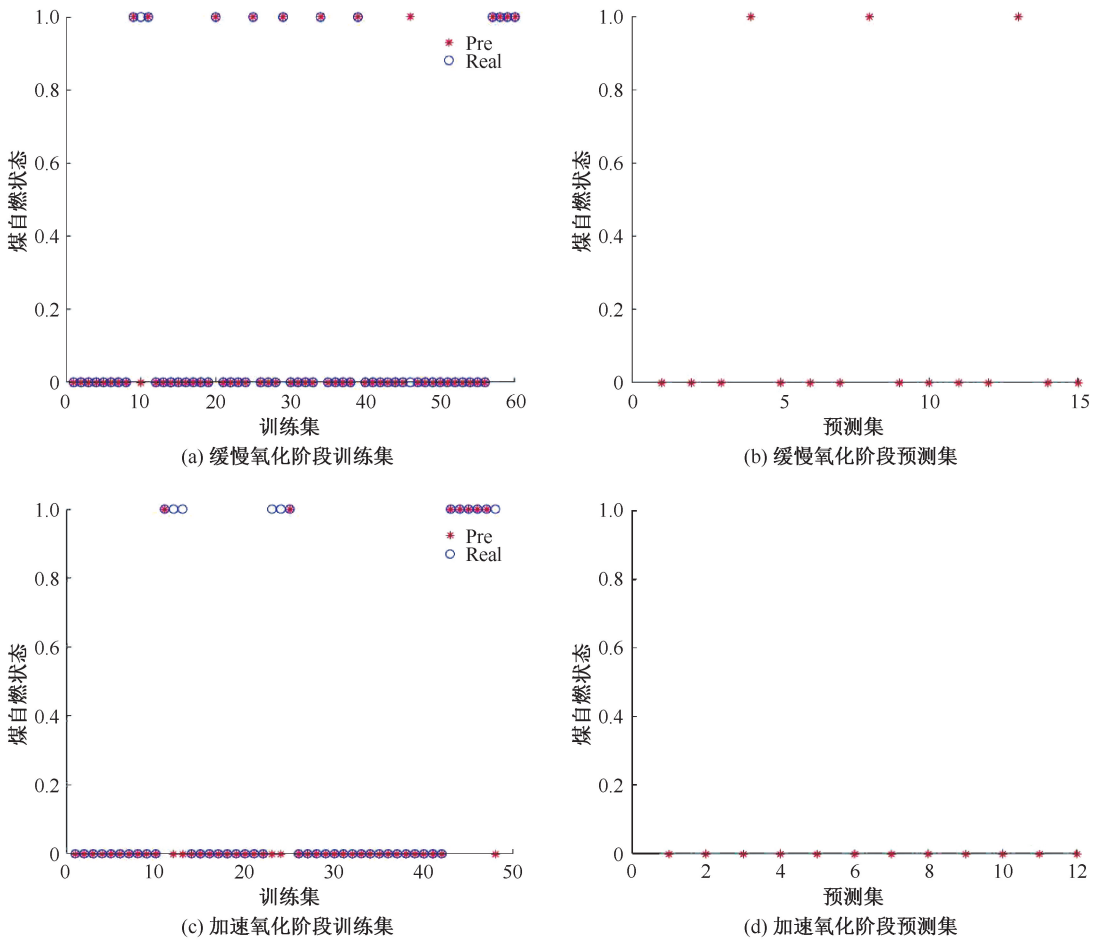


图 5 SSA-RBF 神经网络对煤自燃状态的预测结果

Fig. 5 Prediction results of coal spontaneous combustion state by SSA-RBF neural network

到 SSA-RBF 神经网络预测模型的最优解,如图 6 所示。




图 6 不同参数下 SSA-RBF 神经网络预测准确率
Fig. 6 Prediction accuracy of SSA-RBF neural networks with different parameters

调整神经元个数为 4 个时,该模型对缓慢氧化阶段和加速氧化阶段的预测准确性均有所下降,虽

然增加迭代次数到 500 次时,缓慢氧化阶段预测的准确性有所提高,但加速氧化阶段的预测准确性仍然不高,且迭代次数过高增加了预测模型的训练时长。调整神经元个数为 5 个时,2 个阶段的预测准确性均有较大的提高,其中,迭代次数设置为 300 时,对缓慢氧化阶段和加速氧化阶段预测的准确性分别达到了 99% 和 93%,虽然增加迭代次数到 500 次时,对加速氧化阶段的预测会继续提高,但对缓慢氧化阶段预测的准确性会下降,并且此时预测模型的训练时长较长,因此,综合考虑最终选择设置神经元的个数为 5,迭代次数设置为 300 次。

将文中预测结果与 LI Shuang 等^[13]所提出的 GWO、PSO 预测煤自燃模型相比,不仅在阶段预测上更加明确,预测准确率也有较大的提高,证明了 SSA-RBF 模型对煤自燃预测的优越性。

4 结 论

1) 煤在程序升温过程中,CO 体积分数在 120 °C 之前无显著变化,在 120~160 °C 之间,CO 体

积分数迅速增加且开始产生烯烷类气体,在 160 °C 之后烯烷类气体体积分数急剧增加。

2) 灰色关联度分析结果表明:在缓慢氧化阶段,CO/ ΔO_2 、CO、C₂H₄3 种指标气体与煤温的灰色关联系数最大;而在加速氧化阶段,C₂H₄/C₂H₆、CO/ ΔO_2 、CO₂/CO 3 种指标气体与煤温的灰色关联


系数最大。

3) 3 种不同维度函数的测试结果表明:SSA 与 PSO、GWO 相比,具有更好的全局搜索能力、收敛速度和稳定性;基于 SSA-RBF 神经网络的预测模型对缓慢氧化阶段的预测准确性较高,对加速氧化阶段的预测准确性相对较低。

参 考 文 献

- [1] 刘一鸣. 2022 年煤炭行业发展年度报告[R]. 中国煤炭工业协会, 2023.
- [2] 谭波, 邵壮壮, 郭岩, 等. 基于指标气关联分析的煤自燃分级预警研究[J]. 中国安全科学学报, 2021, 31(2): 33-39.
TAN Bo, SHAO Zhuangzhuang, GUO Yan, et al. Research on grading and early warning of coal spontaneous combustion based on correlation analysis of index gas[J]. China Safety Science Journal, 2021, 31(2): 33-39.
- [3] SAHAY N, VARMA D. Critical temperature-an approach to define proneness of coal towards spontaneous heating[J]. Journal of Mines, Metal & Fuel, 2007, 55(10/11): 510-516
- [4] 罗海珠, 梁运涛. 煤自然发火预测预报技术的现状与展望[J]. 中国安全科学学报, 2003, 13(3): 79-81.
LUO Haizhu, LIANG Yuntao. Present situation and prospect of coal spontaneous combustion prediction technology[J]. China Safety Science Journal, 2003, 13(3): 79-81.
- [5] 姚海飞, 张体镇, 阚国栋, 等. 典型整合矿井煤自燃标志气体判定[J]. 煤炭科学技术, 2014, 42(2): 50-53.
YAO Haifei, ZHANG Tizhen, KAN Guodong, et al. Typical integrated mine coal spontaneous combustion sign gas determination[J]. Coal Science and Technology, 2014, 42(2): 50-53.
- [6] 邓军, 李贝, 李珍宝, 等. 预报煤自燃的气体指标优选试验研究[J]. 煤炭科学技术, 2014, 42(1): 55-59.
DENG Jun, LI Bei, LI Zhenbao, et al. Experimental study on gas index optimization for predicting coal spontaneous combustion [J]. Coal Science and Technology, 2014, 42(1): 55-59.
- [7] ITAY M, HILL C, CLASSER D, et al. A study of the low temperature oxidation of coal [J]. Fuel Processing Technology, 1989, 21(2): 81-97.
- [8] HU Wen, YU Zhijin, FAN Shixing, et al. Prediction of spontaneous combustion potential of coal in the gob area using co extreme concentration: a case study[J]. Combust Science and Technology, 2017, 189(10): 1 713-1 727.
- [9] 王福生, 韩慧兰, 柳晓莉, 等. 煤自然发火预测预报模型的构建[J]. 矿业安全与环保, 2011, 38(1): 21-22.
WANG Fusheng, HAN Huilan, LIU Xiaoli, et al. Construction of coal spontaneous combustion prediction model[J]. Mining Safety and Environmental Protection, 2011, 38(1): 21-22.
- [10] 宋志, 曹坤, 孙宝铮. 采场自然发火的预测和识别[J]. 黑龙江矿业学院学报, 1996, 9(3): 23-25.
SONG Zhi, CAO Kun, SUN Baozheng. Prediction and identification of spontaneous combustion in stope[J]. Journal of Heilongjiang Mining Institute, 1996, 9(3): 23-25.
- [11] 徐杨, 周延. 煤自然发火预报的人工神经网络模型[J]. 西安科技大学学报, 2009, 29(4): 410-413.
XU Yang, ZHOU Yan. Artificial neural network model for prediction of coal spontaneous combustion[J]. Journal of Xi'an University of Science and Technology, 2009, 29(4): 410-413.
- [12] 孟倩, 王洪权, 王永胜, 等. 煤自燃极限参数的支持向量机预测模型[J]. 煤炭学报, 2009, 34(11): 1 489-1 493.
MENG Qian, WANG Hongquan, WANG Yongsheng, et al. Support vector machine prediction model of coal spontaneous combustion limit parameters[J]. Journal of China Coal Society, 2009, 34(11): 1 489-1 493.
- [13] LI Shuang, XU Kun, XUE Guangzhe, et al. Prediction of coal spontaneous combustion temperature based on improved grey wolf optimizer algorithm and support vector regression[J]. Fuel, 2022, 324: 564-577.
- [14] 陆新晓, 赵鸿儒, 朱红青, 等. 氧化煤复燃过程自燃倾向性特征规律[J]. 煤炭学报, 2018, 43(10): 2 809-2 816.

- LU Xinxiao, ZHAO Hongru, ZHU Hongqing, et al. Characteristics of spontaneous combustion tendency in reburning process of oxidized coal[J]. Journal of China Coal Society, 2018, 43(10): 2 809-2 816.
- [15] 费金彪. 煤自燃阶段判定理论与分级预警方法研究[D]. 西安: 西安科技大学, 2019.
- FEI Jinbiao. Study on determination theory of coal spontaneous combustion stage and classification early warning method[D]. Xi'an: Xi'an University of Science and Technology, 2019.
- [16] 杨永国, 黄福臣. 非线性方法在矿井突水水源判别中的应用研究 [J]. 中国矿业大学学报, 2007, 36 (3): 283-286.
- YANG Yongguo, HUANG Fuchen. Application of nonlinear method in discrimination of mine water inrush source[J]. Journal of China University of Mining and Technology, 2007, 36(3): 283-286.
- [17] 张利冬, 宋泽阳, 罗振敏, 等. 基于机器学习的煤自然发火期预测[J]. 中国安全科学学报, 2022, 32(12): 118-124.
- ZHANG Lidong, SONG Zeyang, LUO Zhenmin, et al. Prediction of coal spontaneous combustion period based on machine learning[J]. China Safe Science Journal, 2022, 32(12): 118-124.
- [18] 张卫亮, 梁运涛, 杨宏民. CO/CO₂ 比值作为煤自然发火指标气体在安家岭井工矿中的应用[C]. 2008 年全国煤矿安全学术年会, 2008: 180-185.
- [19] 屈丽娜. 煤自燃阶段特征及其临界点变化规律的研究[D]. 北京: 中国矿业大学(北京), 2013.
- QU Li'na. Study on the characteristics of coal spontaneous combustion stage and its critical point change law[D]. Beijing: China University of Mining and Technology (Beijing), 2013.
- [20] 刘奇. 基于 LVQ 神经网络的煤自然发火预报系统研究[D]. 唐山: 华北理工大学, 2017.
- LIU Qi. Research on coal spontaneous combustion prediction system based on LVQ neural network[D]. Tangshan: North China University of Science and Technology, 2017.



作者简介: 高飞 (1984—), 女, 辽宁葫芦岛人, 博士, 副教授, 主要从事碳封存、矿井火灾防治等方面的研究。E-mail: gfgf2001@163.com。