文章编号:1001-5078(2023)11-1657-08

· 激光应用技术 ·

基于激光诱导击穿光谱技术的煤灰分特征研究

李云红¹,余天骄¹,周小计²,管今哥³,郑永秋³,张成飞⁴,程 博⁴ (1. 西安工程大学电子信息学院,陕西西安710048;2. 北京大学电子学院,北京100871;

3. 中北大学 省部共建动态测试技术国家重点实验室,山西 太原 030051;4. 内蒙航天动力机械测试所,内蒙古 呼和浩特 010076)

摘 要:灰分是衡量煤炭质量优劣的关键指标,是衡量煤矿和选煤厂煤炭产品质量的主要指标之一。针对传统煤灰分含量识别效率低、煤样本质量不高的问题,本文基于粒子群优化算法(PSO)和BP神经网络,提出了基于粒子群神经网络的煤炭灰分预测模型。目的是快速识别出煤炭产品中灰分的含量,为煤炭开采提供技术支撑。研究选取了180个标准煤粉样品,1~140号样本数据用于训练集,141~180号样本数据作为测试集。应用PSO-BP模型对煤炭灰分特性进行了研究,仿真结果表明:优化后的6维BP神经网络模型,决定系数 R²为0.88501 越接近1,表明建立的PSO-BP模型具有较好的预测性能,灰分预测值与灰分真值无限逼近。进而表明所构建的灰分预测模型具有较高的预测精度,提升了模型的泛化能力和预测精度,为后续的LIBS 术应用于煤炭检测提供一定的理论依据。

关键词:煤灰分;BP 神经网络;粒子群算法;LIBS;光谱强度

中图分类号:0433.4;TN249 文献标识码:A **DOI**:10.3969/j.issn.1001-5078.2023.11.006

Research on coal ash content characteristics based on laser-induced breakdown spectroscopy

LI Yun-hong 1 , YU Tian-jiao 1 , ZHOU Xiao-ji 1,2 , GUAN Jin-ge 3 , ZHENG Yong-qiu 3 , ZHANG Cheng-fe 4 , CHENG Bo 4

- School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China
 Electronic School, Peking University, Beijing 100871, China
 - 3. State Key Laboratory of Dynamic Measurement Technology, Taiyuan 030051, China
 - 4. Inner Mongolia Test Institute of Aerospace Dynamic Machine, Hohhot 010076, China)

Abstract: Ash content is a key index to measure the quality of coal and is one of the main indicators of coal product quality in coal mines and coal preparation plants. Aiming at the problems of low identification efficiency of traditional coal ash content and low quality of coal samples, a coal prediction model based on particle swarm optimization (PSO) and BP neural network is built and the purpose is to quickly identify the ash content in coal products and provide technical support for coal mining. 180 standard pulverized coal samples are selected for the study, and the sample data of No. 1 \sim 140 are used for the training set, and the sample data of No. 141 \sim 180 are used as the test set. The PSO-BP model is applied to study the coal ash characteristics, and the simulation results show that the optimized 6-dimensional BP neural network model, with the coefficient of determination R^2 of 0. 88501, is closer to 1, indicating that the established PSO-BP model has better prediction performance, and the predicted value of ash is infinitely close to the true

value of ash. In turn, it shows that the constructed gray prediction model has high prediction accuracy, which improves the generalization ability and prediction accuracy of the model, and provides some theoretical basis for the subsequent application of LIBS technique to coal detection.

Keywords: coal ash content; BP neural network; particle swarm optimization; LIBS; spectral intensity

1 引言

在我国煤炭开采行业领域中,煤炭检测的精度和对煤炭成份分析不仅影响着煤炭的利用率还影响着煤炭企业经济的发展。而传统的检测分析方法主要是人工煤炭检测,实验分析常用设备有灰分仪和碳硫仪^[1-2]等,检测速度慢、效率低、实验仪器操作复杂、精确度低,随着科学技术的发展已不能够满足大规模的实验检测分析。为了准确检测煤样的各种元素含量以及灰分值等关键工业指标,利用激光诱导击穿光谱技术进行煤样的光谱强度信息采集,这在煤炭检测分析中是一种安全、可靠、快速的技术。

近年来,更多的学者开展了对煤炭灰分检测的 深入研究。Xie G^[3]研制了一种基于伪双能 X 射线 透射的实时灰分分析仪,通过 X 射线灰分含量与 5 个特征参数的线性关系,验证了 X 射线灰分分析仪 的可行性。郭西进[4]等利用多层神经网络对煤泥 浮选尾矿灰分进行检测。然后对其灰分值进行回归 预测,并与实际尾矿灰分值进行比较分析。建立了 基于深度卷积网络的灰分检测模型,验证其具有较 好的实时性。郭宇潇[5]等使用机器学习方法结合 LIBS 技术进行定量的分析,提出了一种两阶段的变 量选择方法。研究结果表明了,该方法在 LIBS 定量 分析中的高效性和普适性。李云红[6]等通过搭建 激光测量煤灰分实验平台,研究了三种不同标准煤 样在不同厚度下的谱线强度和相对标准偏差。实验 结果表明,煤样的厚度对煤灰分准确度的测量具有 较大的影响。王龙龙[7]等利用机器学习从大量数 据中找到选煤过程中参数的规律,同时利用机器视 觉进行矸石分拣灰分预测,提高了选煤厂在选煤过 程中的效率。Ali D 等[8]利用随机森林、人工神经网 络、自适应神经模糊推理系统来预测细粒高灰分煤 炭特征。LegnaioliS^[9]等利用安装在发电厂的激光 诱导击穿光谱技术实验装置,研究了煤炭灰分含量 的影响。实验结果表明,样品的选择应考虑 LIBS 测 量灰分的大小,可以有效的避免燃烧器在运行期间 结垢结渣。ZhaoyuQiu^[10]等采用多项式回归(PR)、 特征选择多项式回归(PRFS)和粒子群优化支持向量机(PSO-SVM)建立了煤的灰分预测模型。Zhang K^[11]等提出了一种基于神经网络回归的灰分在线测量方法,用于快速估算煤炭的灰分含量。周涛^[12]等利用基于激光诱导击穿光谱技术与传统的激光熔覆分析手段进行对比,实验结果表明激光诱导击穿光谱技术能够有效的克服传统分析手段所需的复杂预处理程序。

由于神经网络模型具有较强的自适应和自学习的能力,对于非线性模型问题能够很好的建模和逼近,为解决非线性模型提供了思路。本文利用激光诱导击穿光谱技术进行了煤炭灰分特征的快速识别,结合了粒子群优化 BP 神经网络模型的定量分析,利用均方根误差(RMSE)、平均绝对百分比误差(MAPE)、平均绝对误差(MAE)作为煤炭灰分预测模型的综合评价指标。探究了煤炭灰分的特征规律,建立了一种快速、安全的灰分检测识别方法,此方法对煤炭的勘探和开发具有一定参考价值。

2 实验原理和测试流程

激光诱导击穿光谱(Laser-Induced Breakdown Spectroscopy, LIBS)技术测量原理为,脉冲激光经过透镜和反射镜聚焦在样品表面上,在高强度的激光脉冲作用下样品表面粒子会吸收激光烧灼能量由固态烧融状态转化为蒸汽状态,最终形成等离子体。同时温度的升高使得等离子体发生迅速膨胀,煤样的表面由于热压力的产生会分解为不规则的小颗粒。在冷却过程中处于激发态原子、离子发生能级跃迁并产生特征谱线,该过程由光纤收集信号传至光谱仪最终由计算机分析。

LIBS 分析仪测试流程如图 1 所示。首先要进行 初始化包括程序的初始化和光谱仪的初始化,然后设置光谱仪相关参数包括光谱覆盖范围、分辨率、信噪比等,同时光谱仪会自动进行对暗背景的测量。其次器件激光器会自由运行并不断由 Q 开关向光谱仪发 送触发信号,接收到触发信号的光谱仪经过设定的延迟时间开始进行光谱测量。并对光谱信号进行积分,当积分时间结束后将光谱数据传输到电脑中判断是

否达到测量点数。如果没有达到,则等待Q开关的下一次触发。如果达到则复位平移台,保存光谱数据同时建立初始煤炭样本光谱信息数据库,作为测试模型训练集和测试集。通过 matlab 软件建立定量分析优化灰分预测模型,并对煤炭样本灰分值预测。

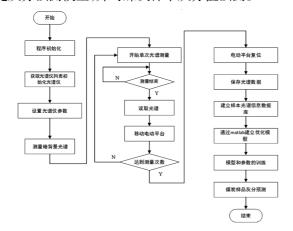


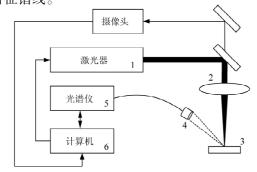
图 1 LIBS 分析仪测试流程

Fig. 1 LIBS analyzer test process

3 实验设计

3.1 实验装置

LIBS 的实验装置,如图 2 所示。实验环境在北京大学电子学院量子电子所冷原子与精密测量实验室,采用调 Q 的 Nd:YAG 脉冲激光器作为激发光源,脉冲激光器波长为 1064 nm,脉冲宽度 10 ns,频率为 1 Hz。在激光诱导击穿光谱的煤质检测应用场景下,要求光谱仪不但有较广的光谱探测范围 200~950 nm,还要求有较高的分辨率,因此光谱数据的采集使用 AVANTES 公司的 AvaSpec-Dual 型光纤光谱仪,焦距为 10 nm,光学的分辨率为 1150。实验中的光谱信号由光纤收集后传至光纤光谱仪进行分光探测,并通过光谱数据传输至计算机分析。同时在实验检测中使用 195 nm~467 nm 的单通道可以检测到 Si、Al、Fe、K等煤质灰分值检测所需的元素特征谱线。



1:激光器 2:聚集光路 3:样品室 4:收集光路 5:光谱仪 6:控制系统 (a)系统框图



(b)实物图

图 2 LIBS 实验系统框图和实物图

Fig. 2 Block diagram and physical diagram of LIBS experimental system 3.2 样品制备

实验样品为济南众标科技有限公司销售的标准 煤粉样品,并以此建立了表 1 相应煤灰分值的数据 库初始样本。实验中煤粉样品的颗粒小于 0.5 mm, 将标准的煤粉样品放在模具中,通过自动压饼机在 20 t 压力下压制成饼状的煤样,防止煤粉在实验过程中飞溅造成实验环境的污染。煤饼的直径为 4 cm,厚度为0.7 cm,并进行统一样品编号。

表 1 数据库初始样本

Tab. 1 Initial samples of database

样品编号	灰分值/%	挥发分/%	热值/(MJ・kg)
1	17. 2489	18. 38	31. 58
2	15. 8774	33. 50	30. 30
3	14. 9533	29. 51	31. 60
4	16. 3466	33. 84	31. 30
5	15. 1611	31. 78	27. 01
6	14. 4401	11. 35	30. 04
7	15. 0910	34. 13	31. 16
8	15. 2590	7. 30	26. 09
9	15. 1610	9. 52	23. 984
10	13. 7910	21. 64	28. 704
11	18. 1950	8. 55	23. 82
:	:	:	:
180	16. 7990	9. 42	29. 75

3.3 实验测量

将压好的煤饼样品固定在 LIBS 测量系统的电动平台上测量。每个煤饼表面选定不同测量位置,经过 100 μs 左右的延迟时间收集光谱信号。每次激光脉冲击打样品表面后,产生在样品表面的浮尘,会吸收激光能量利用吸尘器除尘。在处理基底噪声方面,通过增加光谱仪的延迟来消除噪声。在实验

进行前,开机 LIBS 仪器 15 min,能够更好地提高激光器稳定性。

LIBS 测量过程中由于硬件设备产生的波动以及煤饼制样过程中存在的不均匀性,每条光谱数据的特征向量会不同。通过多条光谱数据的平均处理来削弱测量产生的波动,并对煤样光谱数据模型的训练集和测试集的合理划分。

4 PSO-BP 神经网络的灰分预测

4.1 主成分分析(PCA)算法

在光谱数据预处理之前,经常会遇到维度较高的数组,并且变量与变量之间存在着很多相互的关系,造成数据在处理过程中很难抓住主要特征信息。主成分分析算法的核心是通过数值的变化将多维的特征变量转换为维度较小的不相关变量。同时这些变量尽可能反映出数据预处理之前的相关信息。利用主成分分析算法分析光谱数据的响应特征,将原始数据的变量转化为相对独立的数据变量。同时数据在降维的过程中能够排除数据的异常点,简化数据的结构。降维往往作为预处理步骤,在数据应用到其他算法之前对其清洗。在利用主成分分析方法之前对输入光谱数据先进行归一化处理,可以降低光谱的不确定性,提高光谱与元素浓度之间的相关性。

设 $x_1, x_2, \dots x_p$ 为P个原始特征变量,数据样本个数为n,构成 $n \times p$ 维矩阵X:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}$$
 (1)

对矩阵 X 进行主成分分析主要步骤如下 $^{[13-15]}$:

(1)为了避免数据受到量纲的影响,对光谱数据进行标准化处理。并计算出 *P*×*P*维的协方差矩阵 A。

$$cov(x_{i}, x_{j}) = E[(x_{i} - E(x_{i}))(x_{j} - E(x_{j}))]$$

$$= \frac{1}{n-1} \sum_{i=1, j=1}^{n} (x_{i} - \overline{x_{i}})(x_{j} - \overline{x_{j}})$$
(2)

$$A = \begin{bmatrix} \cos(x_{1}, x_{1}) & \cos(x_{1}, x_{2}) & \cdots & \cos(x_{1}, x_{p}) \\ \cos(x_{2}, x_{1}) & \cos(x_{2}, x_{2}) & \cdots & \cos(x_{2}, x_{p}) \\ \vdots & \vdots & \cdots & \vdots \\ \cos(x_{p}, x_{1}) & \cos(x_{p}, x_{2}) & \cdots & \cos(x_{p}, x_{p}) \end{bmatrix}$$
(3)

式中, x_i 代表测量样本数据的均值。 $cov(x_i, x_j)$ 代表样本数据的协方差, 协方差为正时, 说明 x_i 和 x_j 是正相关。反之协方差为负时, 说明 x_i 和 x_j 是负相关。

(2)计算出特征值对应的特征向量。用特征值分解方法求协方差矩阵 A 的特征值,得到 λ_1 , λ_2 ,… λ_p ,特征值。对应特征值的大小 $\lambda_1 \ge \lambda_2 \ge \dots \lambda_p$,此时对应的最大特征值 λ_i ,特征向量为:

$$a_{1} = \begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{n-1} \end{bmatrix}, a_{2} = \begin{bmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{n-2} \end{bmatrix}, \dots, a_{m} = \begin{bmatrix} a_{1m} \\ a_{2m} \\ \vdots \\ a_{n} \end{bmatrix}$$
 (4)

(3) 根据公式 $Y = A^{T}x$ 可得 $Y_{1} = a_{1}^{T}x$ 为第一主成分, $Y_{2} = a_{2}^{T}x$ 为第二主成分等,以此类推得到不同对应主成分。

4.2 BP 神经网络

BP算法(Back Propagation)是一种多层前馈神经网络,是由输入层、隐含层、输出层三部分组成,如图3所示。BP神经网络算法的传播方向包括,正向传播与反向传播。正向传播,是从输入层 x₁ 经过 L_R 传输至输出层 y₁。若输出值 y₁与期望输出预测结果存在一定的误差,则进行反向传播。通过神经网络的反复学习训练后,梯度下降不断修正参数使得实际输出值与期望值不断地接近。BP神经网络根据梯度下降法,不断更新调整网络各层的输入层和隐含层之间权值和阈值,而隐含层和输出层之间阈值容易使得 BP神经网路获得局部最优解,这会使得灰分预测值和灰分实际真值相差甚远,最终导致模型预测精度降低。

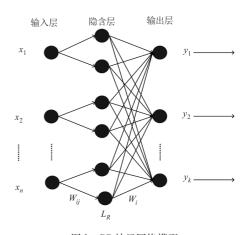


图 3 BP 神经网络模型 Fig. 3 BP neural network

其中,隐含层的节点数公式如下[16]:

$$s = \sqrt{m+n} + \lambda \tag{5}$$

式中,s 表示的是神经网络的节点数;m 与 n 分别代表的是 BP 神经网络的输入节点数和输出层的节点个数; λ 代表是常量取值范围为 $\lambda \in (1 \sim 10)$ 。

使用激活函数为非负的 Sigmoid 函数:

sigmoid
$$(x) = \frac{1}{1 + e^{-x}} \in (0,1)$$
 (6)

式中,e 是纳皮尔常数 2.7182…, Sigmoid 函数作为 激活函数,进行信号转换,转换后的信号被传送至下一个神经元。隐含层选取 Sigmoid 函数,该函数的 梯度随着 x 增大或减小均趋于 0,在反向传播时会造成"梯度消失"现象。

BP 神经网络训练的步骤如下:

令样本 $x = \{x_1, x_2, \dots, x_n\}$ 为输入向量, $y = \{y_1, y_2, \dots, y_k\}$ 为输出向量, x_n 为输入层个数, L_R 为 隐含层个数, y_k 为输出层个数, W_{ij} 和 W_{jk} 分别为输入层到隐含层和隐含层到输出层的连接权值。

4.3 粒子群算法

粒子群算法(Particle Swarm Optimization, PSO) 是一种模拟鸟群觅食行为的智能搜索算法。通过群体中的个体相互协作和信息共享来寻找最优的解。 其基本思想是模拟鸟群搜寻食物的路径找到食物最 多的地点,即根据局部的最优解寻找全局最优解。 粒子群算法对于解决高维光谱数据优化问题具有一定的优势。

粒子群算法优化主要包括两方面:第一,对于BP神经网络拓扑结构的优化。第二,对权值和阈值进行优化。粒子群算法的关键是粒子位置和速度,逻辑步骤如下:

- (1)初始化规模为 N 粒子群中每个粒子的位置和速度。
 - (2)计算粒子群中每个粒子的适应值。
- (3)若某个粒子当前的适应值相比于之前记录 该粒子的最优解 pbest 更好,则更新此时的最优解 pbest。
- (4) 若某个粒子当前的适应值相比于之前记录的 全局最优解 gbest 更好,则更新此时的最优解 gbest。
- (5)更新后的最优解 gbest 符合要求,则结束程序。反之更新粒子的速度和位置:

$$v(k+1) = wv(k) + c_1r_1(pbest(k) - present(k))$$

$$+ c_2 r_2(gbest(k) - present(k))$$
 (7)

present(k+1) = present(k) + v(k+1) (8) 其中, w 代表惯性权重; c_1 和 c_2 代表是学习因子; r_1 和 r_2 代表伯努利分布的 0 到 1 的随机数; v(k) 代表是某个粒子在 k 时刻的速度; present(k) 代表是某个粒子在 k 时刻的位置。

(6)继续循环到步骤(2)中。

4.4 粒子群算法优化 BP 神经网络

粒子群算法优化 BP 神经网络模型的训练流程图如图 4 所示。整个模型的训练学习过程包括粒子群算法和 BP 神经网络。而粒子群算法优化BP 神经网络模型,通过对各层神经元权值和阈值的不断修正,使得误差函数沿梯度方向下降。当误差平方和小于目标误差时满足实验条件,输出最优权值、阈值。同时对模型的最优参数进行训练输出预测结果。

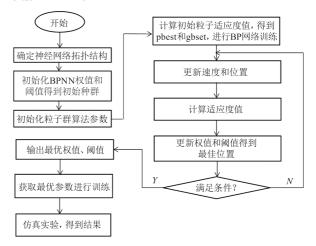


图 4 粒子群优化流程

Fig. 4 The process of particle swarm optimization

5 模型评价指标

实验选取均方根误差(Root Mean Square Error, RMSE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)、平均绝对误差(Mean Absolute Error, MAE)来评估模型的性能。即 RMSE、MAPE、MAE 越接近于 0,表明模型预测具有较好的精度。其指标评价的计算公式如下:

$$MAPE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{\hat{y}_i - y_i}{y_i} \right|$$
 (9)

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |y_i - \hat{y}_i|$$
 (10)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$
 (11)

式中,y 和 \hat{y}_i 分别指煤样的灰分真值和模型的灰分 预测值;n 表示灰分值预测个数。

6 结果与讨论

实验模型以 180 组激光诱导击穿光谱实验测试光谱数据为基础,分别用 BP 神经网络模型和 PSO-BP 神经网络模型对数据进行训练和测试。在表 1 编号中 1~140 样本数据用于训练集,141~180 号样本数据作为测试集。在实验过程中,由于测得的原始光谱数据是 4096 的高维向量,数据样本量过大。同时存在一种元素对应多条特征谱线的情况,多出来的特征谱线反应都是同一元素的特征,而过多的参数数量在模型训练的过程中更容易出现过拟合等负面的影响。因此通过主成分分析特征提取,提取后每条数据的向量维度为 27 维,分别对应着样本煤主要元素成分 Si,Al,Fe,Ca 等元素。

表 2 不同维度 BP 网络模型训练结果
Tab. 2 Training results of BP network model in
different dimensions

维度	RMSE	MAPE	MAE
27 维	2. 2336	12. 101	1. 9032
24 维	1. 9303	0. 1078	1. 6613
21 维	15. 5907	0. 9724	15. 4082
18 维	2. 5657	0. 1253	2. 1368
15 维	1. 9482	0. 0848	1. 4882
12 维	0. 9826	15. 6660	15. 824
9 维	3. 0684	16. 3454	17. 1986
6 维	1. 3980	0. 0300	1. 1367
3 维	1. 4636	0. 0994	1. 4636

通过建立 BP 神经网络,设置输入层神经元个数为6,隐含层神经元个数为15,输出层神经元个数为1。先后对比了1到27不同维度下,BP 神经网络模型预测值和灰分实际真值,同时以 RMSE、MAPE、MAE 为评价预测模型分析的指标。表2所示为不同维度训练模型 BP 网络训练结束后得到预测值,通过主成分分析技术对数据进行预处理之后,6维训练效果明显好于其他维度。因此先后比较了27维、7维、6维和5维,对应的均方根误差、决定系数、平均绝对误差大小。而6维BP神经网络的预测结果较为准确,对应的均方根误差、决定系数、平均绝对误差较低,效果明显好于相邻维度的大小,则选择6维BP神经网络对其进行模型优化。

如图 5 所示 BP 神经网络模型算法下,27 维、7 维、6 维和 5 维下的预测结果输出值和实际真值结果分析比较。

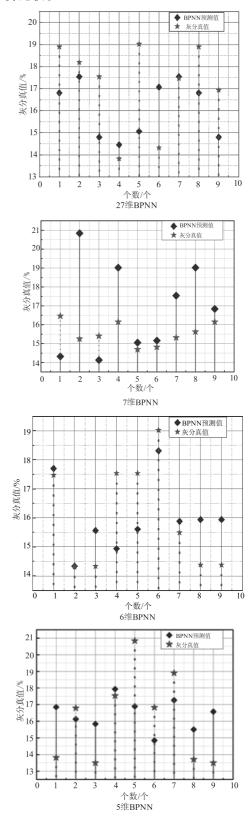


图 5 BP 神经网络模型预测结果

Fig. 5 Prediction results of BP neural network model

为了避免 BP 神经网络陷入局部极小值,提高预测 模型的精度,建立 PSO 算法优化 BP 神经网络模型。优 化后的 6 维 BP 神经网络模型,决定系数 R^2 为 0.88501 更接近于1,表明建立的模型具有较好的预测性能。平 均绝对误差 MAE 为 0.43882, 均方根误差 RMSE 为 0.51984,平均绝对百分比 MAPE 为 2.83 %。在 6 维 PSO-BPNN 实验中使用 MATLAB 仿真软件对 180 组光 谱数据进行训练和预测,模型训练之前对光谱数据进 行归一化处理。设置输入层节点数为6,隐含层节点数 为 15 为,输出层节点数为 1,粒子群初始粒子数量为 50,期望误差设置为 0.001。采用 PSO-BPNN 方法预测 灰分值的适应度函数值变化过程如图 6 所示,从图 6 的实验结果可以看出 PSO 算法能避免 BP 神经网络陷 人局部极小值。初始迭代时获取的适应度函数值大于 4.0,随着迭代次数的迅速下降当迭代次数增加至10次 时,适应度函数值的变换逐渐的在变缓。当迭代次数 到达20次时,训练样本的均方误差到达最优状态,灰 分预测值与灰分真值无限逼近。此实验结果灰分值预 测具有较少的迭代次数,有效的验证了,基于粒子群算 法优化结合 BP 神经网络方法,能够更好地提升灰分值 预测的精度同时具有较好的收敛效果。

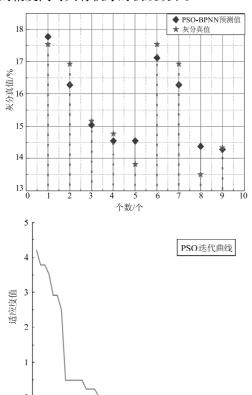


图 6 PSO-BPNN 网络模型预测结果和迭代次数

迭代次数

50

Fig. 6 Prediction results and iteration times of PSO-BPNN network model

7 结 论

- (1)为了快速识别煤炭灰分特征,提出了基于 粒子群优化的 BP 的煤炭灰分优化识别方法。发现 优化后的 BP 神经网络模型,能够更好的克服在寻 优过程中容易陷入局部最优缺陷,提升了模型的泛 化能力和预测精度,同时削弱了神经网络陷入局部 最优的局限。
- (2)对比了 27 维、7 维、6 维和 5 维预测模型的分析指标。优化后的 6 维 BP 神经网络模型,决定系数 R^2 为 0. 88501 更接近于 1,表明建立的 PSO-BP模型具有较好的预测性能,此时的灰分预测值与灰分实际真值无限逼近。
- (3)通过对煤炭灰分特性研究,对模拟分析的结果进行综合评价。实验验证了,本文提出煤炭灰分值参数的预测优化算法的有效性,为后续的 LIBS 术应用于煤炭检测提供一定的理论依据。由于煤炭成分的相对复杂性,本次研究未对预测模型的鲁棒性进行考虑,未来研究还将进一步改进,以提高设计模型预测的准确性。

参考文献:

- [1] Han Junli. Infrared carbon sulfur determination of sulfur content in anthracite improvements [J]. Gansu Metallurgy,2017,39(1):112-114. (in Chinese) 韩俊丽. 红外碳硫仪测定无烟煤中硫含量的方法研究 [J]. 甘肃冶金,2017,39(1):112-114.
- [2] Li Xia, Li Yanan, Xing Chunfang, et al. Application of fast ash measuring equipment in shanxi coking coal group [J]. Shanxi Coking Coal Science & Technology, 2021, 45 (11):18-21. (in Chinese) 李霞,李娅楠,邢春芳,等. 快速测灰设备在山西焦煤集团的应用分析[J]. 山西焦煤科技, 2021, 45 (11): 18-21.
- [3] Xie G. Coal ash content measurement based on pseudodual energy X-ray transmission[J]. Minerals, 2021, 11.
- [4] Guo Xijin, Wei Lingao, Yang Chunbao. Research on ash detection method of coal slime flotation tailings on convolutional neural network [J]. Coal Technology, 2020, 39 (2):144-146. (in Chinese) 郭西进,魏凌敖,杨春宝. 基于深度卷积网络的煤泥浮选尾矿灰分检测方法研究[J]. 煤炭技术, 2020, 39 (2):144-146.
- [5] Guo Yuxiao, Shi Jinfang, Wang Huili, et al. A two-stage

variable selection method for LIBS quantitative analysis [J]. Laser & Infrared, 2021, 51(4):435 - 440. (in Chinese)

郭宇潇, 史晋芳, 王慧丽, 等. 一种两阶段变量选择的 LIBS 定量分析方法 [J]. 激光与红外, 2021, 51(4): 435-440.

- [6] Li Yunhong, Wen Da, Li Honghao, et al. Study on the influence of coal sample height on the accuracy of laser measurement of coal ash content [J]. Laser & Infrared, 2020,50(5):551-556. (in Chinese) 李云红,文达,李弘昊,等. 煤样高度对激光测量煤灰分准确度影响的研究[J]. 激光与红外,2020,50(5):551-556.
- [7] Wang Longlong, Su Zimu, Yang Xiaoping. Application of machine learning in coal preparation plant[J]. Electromechanical Information, 2019, (12): 122 123. (in Chinese)

 王龙龙,苏子慕,杨小平. 机器学习在选煤厂的应用
 [J]. 机电信息,2019,(12):122-123.
- [8] Ali D, Hayat M B, Alagha L, et al. An evaluation of machine learning and artificial intelligence models for predicting the flotation behavior of fine high-ash coal[J]. Advanced Powder Technology, 2018, 29(12):3493 - 3506.
- [9] Legnaioli S, Campanella B, Pagnotta S, et al. Determination of ash content of coal by laser-induced breakdown spectroscopy [J]. Spectrochimica Acta Part B Atomic Spectroscopy, 2019, 155:123-126.
- [10] Qiu Z, Dou D, Zhou D, et al. On-line prediction of clean coal ash content based onimage analysis [J]. Measurement, 2020.
- [11] Zhang K, Wang W, Lv Z, et al. A CNN-based regression framework for estimating coal ash content on microscopic images [J]. 2022, 189:110589.
- [12] Zhou Tao, Kong Linghua, Huang Xu, et al. LIBS characterization method for laser cladding two-dimensional gradi-

- ent materials[J]. Laser & Infrared, 2019, 34(1):37 39. (in Chinese)
 周涛,孔令华,黄旭,等. 激光熔覆二维梯度材料的
- 周涛,孔令华,黄旭,等. 激光熔覆二维梯度材料的 LIBS 表征方法 [J]. 激光与红外, 2021, 51 (11): 1410-1416.
- [13] Ma Zheng, Zhang Chunlei, Gao Shichen. Lithology identification based on principal component analysis and fuzzy recognition [J]. Lithologic Reservoirs, 2017, 29 (5): 127-133. (in Chinese)
 马峥,张春雷,高世臣. 主成分分析与模糊识别在岩性识别中的应用[J]. 岩性油气藏,2017,29(5):127-133.
- [14] Ye Tao, Wei Ajuan, Huang Zhi, et al. Quantitative identification of volcanic lithology based on comprehensive principal component analysis and bayes discriminant method: a case study of mesozoic in bohai bay[J]. Journal of Jilin University Earth Science Edition, 2019, 49 (3):873 -880. (in Chinese)
 - 叶涛, 韦阿娟, 黄志, 等. 基于主成分分析法与 Bayes 判别法组合应用的火山岩岩性定量识别: 以渤海海域中生界为例[J]. 吉林大学学报: 地球科学版, 2019, 49(3):873-880.
- [15] Chi Yulun, Wu Yaoyu, Jiang Huan, et al. On-line prediction of grinding surface roughness based on fuzzy neural networkand principal component analysis [J]. Acta Metrologica Sinica, 2022, (11):1389-1397. (in Chinese) 迟玉伦,吴耀宇,江欢,等. 基于模糊神经网络与主成分分析的磨削表面粗糙度在线预测 [J]. 计量学报, 2022, (11):1389-1397.
- [16] Liang Wang, Qin Zhaobo, Chen Liang, et al. Longitudinal control method of intelligent vehicles based on the improved BP neural network [J]. Automotive Engineering, 2022,44(8):1162-1172. (in Chinese) 梁旺,秦兆博,陈亮,等. 基于改进 BP 神经网络的智能车纵向控制方法[J]. 汽车工程,2022,44(8):1162-1172.