基于 PSO-BP 神经网络的回转窑喷煤量预测

阳诚平[1]，刘 奇[2]，刘 曙[1]，劳 逸[2]，汤启宙[1]，文 爽[2]，周德军[1]，赵士林[2]
（1. 武钢资源集团程潮矿业有限公司，湖北 鄂州 436051；2. 中南大学 能源科学与工程学院，湖南 长沙 410083）

摘要：喷煤量调节是回转窑内各段温度控制的主要途径和手段，但由于回转窑内球团的煅烧过程具有非线性、时滞性、多变量和不确定性等特点，该部分温度难以有效控制。本文构建一种基于粒子群算法优化 BP 神经网络（PSO-BP）的回转窑喷煤量预测模型，通过仿真试验对比喷煤量的预测值与实际值，分析误差和辨识模型的拟合效果。结果表明：PSO-BP 神经网络预测模型的精度优于原始 BP 神经网络，具有较高的寻优效率，总体拟合效果较好，其线性拟合度约为 0.95，绝对误差约为 0.09 t/h，相对误差约为 2.4%。基于 PSO-BP 神经网络模型预测预热段的温度平均相对误差为 0.8%，总体平均温度波动在 ±10 ℃以内，说明构建的回转窑喷煤量预测模型准确可靠且适用性强，将建立的神经网络作为前馈控制模块与传统的 PID 控制相结合构成预热段温度自动控制系统，可实现回转窑温度场稳定控制。

关键词：回转窑；球团；粒子群算法；BP 神经网络；喷煤量；温度控制
中图分类号：TF046.6；TP183 **文献标识码**：A **文章编号**：1000－8764(2024)05－0047－09
doi：10.13403/j.sjqt.2024.05.074

Prediction of coal injection rate in rotary kiln based on PSO-BP neural network

YANG Chengping[1], LIU Qi[2], LIU Shu[1], LAO Yi[2], TANG Qizhou[1], WEN Shuang[2], ZHOU Dejun[1], ZHAO Shilin[2]
(1. Chengchao Mining Company Limited, WISCO Resources Group, Ezhou 436051, Hubei, China; 2. School of Energy Science and Engineering, Central South University, Changsha 410083, Hunan, China)

Abstract: Coal injection rate adjustment is the main way and means to control the temperature of each section in the rotary kiln, but it is difficult to effectively control the temperature of each section due to such characteristics as nonlinearity, time delay, multivariate and uncertainty of the calcination process of pellets in the rotary kiln. A prediction model of coal injection rate in rotary kiln based on particle swarm optimization BP neural network (PSO-BP) is constructed, and the predicted value and actual value of coal injection rate are compared through simulation experiments, and the error and fitting effect of the identification model are analyzed. The results show that the precision of the PSO-BP neural network prediction model is better than that of the original BP neural network, with high optimization efficiency and good overall fitting effect, with a linear fitting degree of about 0.95, an absolute error of about 0.09 t/h, and a relative error of about 2.4%. Based on the PSO-BP neural network model, the average relative error of the temperature prediction section is 0.8%, and the overall average temperature fluctuation is within ±10 ℃. It shows that the constructed prediction model of coal injection rate in rotary kiln is accurate, reliable and applicable, and the established neural network is combined with the traditional PID control to form an automatic temperature control system for the preheating section, which can realize the

收稿日期：2023－06－17；**修回日期**：2023－09－28
基金项目：长沙市“揭榜挂帅”重大科技项目（kq2301007）
作者简介：阳诚平（1981—），男，高级工程师，从事球团工艺技术研究及生产管理工作。
通信作者：赵士林（1992—），男，特聘教授，从事烟气减污降碳及固废资源化综合利用方面的研究。

stable control of the temperature field of the rotary kiln.

Key words: rotary kiln; pellets; particle swarm optimization; BP neural network; coal injection rate; temperature control

回转窑作为链算机—回转窑—环冷机球团生产工艺中的核心设备，是系统排放热量的主要来源。回转窑的热量主要由窑头的煤粉燃烧装置(喷煤器)提供，其各段温度可通过调节喷煤量进行控制[1]。在回转窑中球团的焙烧具有滞后性、强耦合性和非线性等特点，采用常规的 PID 控制方法很难实现焙烧温度的稳定控制。目前，关于回转窑喷煤量的调节多由操作人员依据经验进行控制，没有统一的控制标准和方法，各段温度的控制效果受操作人员技能熟练程度、温度、喷煤量、风量的测点位置等多因素影响，存在调节不及时、难以稳定控制的问题[2-3]。因此，基于回转窑内温度场建立对应的喷煤量预测模型，对实现回转窑各段温度的稳定控制具有重要的意义。

回转窑中除了煤粉燃烧提供主要热量外，环冷机和链算机均会带入部分热量进入回转窑，整个系统物料、能量、气流复杂，难以通过三大守恒建立其数学模型[4]。周仙霖等[5]通过建立线性回归模型研究回转窑温度、煤气量等之间的关联性，但这些参数之间并非简单的线性关系，采用线性回归模型获得的结果存在一定的偏差。谌晓文等[6]采用 BP 神经网络以台车速度、点火温度和主管负压等参数作为模型的输入，建立回转窑烧结终点的预测模型；袁晓红等[1]采用 BP 神经网络以球团焙烧时间、煤粉量和回转窑转速等参数作为模型的输入，预测回转窑的目标温度，预测精度不太理想。这是因为 BP 神经网络每次训练开始时，初始权值和阈值是随机生成的，容易陷入局部最优解，从而导致训练结果难以达到全局最优的效果，所以模型还有进一步优化的空间。为了避免 BP 神经网络陷入局部最优从而提高模型预测精度，一般会引入优化算法(如遗传算法、天牛须算法、灰狼算法、蚁群算法、鱼群算法等)对 BP 神经网络初始的权值和阈值进行优化。廖超[7]采用遗传算法优化的 BP 神经网络以生料流量、喷煤量和主排风速度作为模型的输入，预测回转窑的烧结温度；张信璘等[8]采用遗传算法优化的 BP 神经网络以窑头喷煤量、熟料温度、窑主机电流、窑头负压等参数作为模型的输入，预测回转窑内温度。但这些优化算法均有一定的不足，如遗传算法、天牛须算法和灰狼优化算法在处理部分问题时存在易陷入局部最优解，收敛速度慢，求解精度较低的问题[9-10]；而蚁群算法和鱼群算法存在参数设置复杂，参数设置不当难以得到最优解的问题[11-12]。而粒子群算法虽然属于较为常见的优化算法但其具有下述优点：具有智能群体的思想，拥有一种独特的信息共享机制，能够及时调整粒子位置，不容易陷入局部最优，在处理复杂的问题时更加高效，收敛速度更快；同时，算法本身涉及的参数较少，原理简单，容易在工程上应用[13]。目前在采用算法优化的神经网络来建立回转窑预测模型的相关研究中，主要是以回转窑内的温度作为模型的预测输出，但是在实际球团生产过程中，操作人员需要根据窑内的各种检测参数的变化实时调整喷煤量，以保证球团的正常生产，因此以回转窑的检测参数(温度、转速等)作为模型的输入，将操作参数(喷煤量)作为预测模型的输出更符合球团生产现场的实际调整策略。

基于上述研究现状，本文采用粒子群算法优化 BP 神经网络(PSO-BP)，以回转窑温度、链算机台车机速、料层厚度、回转窑转速作为输入，喷煤量作为输出，进行建模，获得喷煤量的预测模型。通过喷煤量模型的预测结果与实际值之间的误差分析以及预测模型的总体拟合效果，评价建立的喷煤量预测模型的正确性和精确性。此外，基于模型输出的喷煤量，采用 BP 神经网络预测预热段的温度，并考察该值与实际值之间的误差，判断是否能够满足球团生产对预热段温度的要求。研究结果对喷煤量的精确控制，进而实现回转窑温度场稳定控制具有重要作用。

1 喷煤量的调整策略

回转窑的热量主要由喷煤器喷出的煤粉通过燃烧提供。在煤粉完全燃烧且其他参数保持相对

不变的情况下，调节喷煤量是控制系统热量分布、稳定温度场的主要手段，该方式具有滞后性较小、操作简单等优点[14]。

预热段、回转窑、环冷机分布及相关检测参数如图 1 所示。目前关于回转窑喷煤量的调整策略主要有：① 回转窑热工参数。如窑头和窑尾的温度，该温度直接反映了回转窑内热气流和物料的温度，是判断当下是否需要调整喷煤器喷煤量最直接的检测参数。② 回转窑物料参数。如回转窑的喂料量，其间接反映了物料与煤粉燃烧产生的热量之间的热交换程度。为控制回转窑内维持一定的焙烧温度，喷煤器的喷煤量需要与回转窑的喂料量相匹配，但目前球团生产系统中针对回转窑进口处喂料量的检测手段较少，可采用链算机的料层厚度和台车机速之间的函数关系简化替代。③ 回转窑机械参数。如回转窑转速，其决定了物料在回转窑内的物理停留时间以及热交换时间。当喷煤量一定时，回转窑的转速也会影响物料的焙烧温度。基于上述喷煤量调整策略，本文建立各参数与喷煤量间的输入－输出关系如式(1)所示。

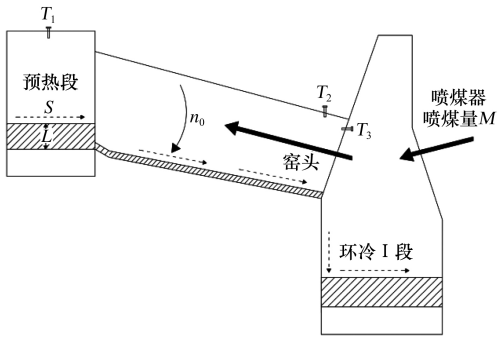


图 1　预热段—回转窑—环冷机分布及相关参数

Fig. 1　Distribution and relevant parameters of preheating section-rotary kiln-ring cooler

（注：T_1 为回转窑的预热段温度，℃；T_2、T_3 分别为第一、二窑头温度，℃；S 为链算机台车机速，m/min；L 为链算机料层厚度，mm；n_0 为回转窑转速，r/min；M 为喷煤器的喷煤量，t/h）

$$M = f(T_1, T_2, T_3, S, L, n_0) \tag{1}$$

式中：f 为参数 T_1、T_2、T_3、S、L、n_0 与喷煤器的喷煤量 M 之间的函数关系。

2　PSO-BP 神经网络模型

粒子群算法(particle swarm optimization，PSO)是一种在自然界鸟类觅食行为的启发下所开发的一种寻优算法：假设自然界中存在一鸟群在一定区域中寻找食物，该觅食区域中有一处食物(食物的位置代表优化问题的最优解)，每只鸟不确定食物的具体方位，但是知晓自己与食物之间的距离，通过个体之间的信息共享，使得鸟群始终在距离食物最近的那只鸟的附近区域进行搜寻，最终引导整个鸟群朝向食物所在位置聚集。粒子群算法通过个体间的信息共享寻找全局最优值，是一种高效且应用较为广泛的优化算法。表 1 给出了鸟群觅食行为和粒子群算法之间的类比关系。

表 1　鸟群觅食行为和粒子群算法的类比关系

Table 1　Analogy between bird predation behavior and particle swarm optimization

鸟群觅食行为	粒子群算法
觅食区间	粒子搜索空间
个体鸟	粒子
鸟的飞行速度	粒子飞行速度
每只鸟的位置	粒子的位置,优化问题的某个解
食物所在位置	优化问题的最优解
鸟与食物之间的距离	适应度值

在 PSO 算法中，搜索空间中的每一个粒子都可以看作实际问题的解，解的好坏通过适应度函数计算得到的适应度值反映，适应度值越大说明越靠近最优解。每一个粒子都有一个随机的初始位置和速度，以个体历史最优和群体历史最优信息为参考，搜寻空间中的最优位置，通过不断迭代更新使得粒子群能够聚集到全局最优位置，从而得到问题的最优解[15]。粒子根据式(2)、(3)更新自己的速度和位置[16-18]。

$$v_i^{k+1} = \omega \times v_i^k + c_1 \times r_1 \times [x_{\text{best}}^k(i) - x_i^k] + c_2 \times r_2 \times [x_{\text{best}}^k - x_i^k] \tag{2}$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \tag{3}$$

式中：v_i^k、x_i^k 分别表示第 i 个粒子在第 k 次迭代中的速度和位置；$x_{\text{best}}^k(i)$、x_{best}^k 分别表示在第 k 次迭代时第 i 个粒子的历史最优位置和群体历史最优位

置；ω 表示惯性权重；c_1、c_2 分别表示个体学习因子和群体学习因子，一般取值范围为[0,2]；r_1、r_2 均表示随机生成的[0,1]范围内的随机数。为保证粒子在搜索过程中在一定空间内进行有效搜索，需要将粒子的位置和速度限制在一定范围内$[-x_{\max},x_{\max}]$，$[-v_{\max},v_{\max}]$。

BP 神经网络是一种应用广泛的前馈神经网络，其主要特点是通过反向传播误差来进行神经网络的训练。该模型能够有效地储存和学习输入与输出之间的映射关系，而且不依赖数学方程来揭示这种映射关系。其具体学习过程如下：数据首先从输入层进入网络，通过一定的运算，经隐含层传递至输出层，得到预测值。然后，将模型预测值与实际值进行比较，如果两者之间的误差满足设定的精度要求，则学习过程终止；如果不满足要求，则利用反向传播将误差从输出层经过隐含层传递至输入层，不断调整网络的权值和阈值，使网络的误差平方和逐渐减小，直到满足设定的精度要求为止。此外，为避免神经网络无法达到设定的精度要求而无休止地进行训练，对其学习次数也需要有一定的限制，即迭代达到设定次数后，无论误差是否满足设定要求，学习过程都将停止。本文当中回转窑喷煤量 BP 神经网络的预测模型结构如图 2 所示。

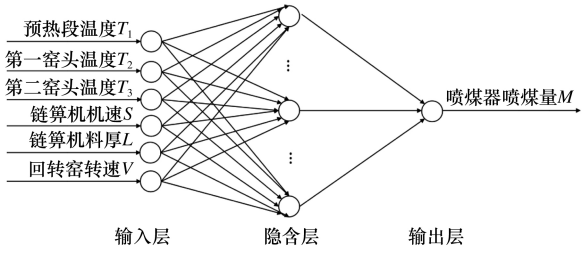


图 2 回转窑喷煤量 BP 神经网络预测模型

Fig. 2 BP neural network prediction model for coal injection rate in rotary kilns

依据喷煤量调整策略，本文建立的 BP 神经网络输入层有 6 个神经元，隐含层的神经元个数未知，输出层有 1 个神经元。神经网络的结构由基本处理单元和它们之间的连接方式决定。这些基本处理单元互相连接机制的结构与神经生理学相似，因而也被称为神经元。以隐含层中的一个神经元为例，模型示意如图 3 所示[7]。

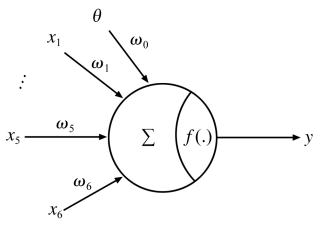


图 3 隐含层神经元模型

Fig. 3 Neuron model of the hidden layer

[注：$x_i(i=1,2,\cdots,6)$为神经元多个输入变量；y 为神经元输出；$\omega_j(j=1,2,\cdots,6)$为连接权重；θ 为阈值；$f(.)$为激活函数)]

激活函数对接受的所有输入进行加权和处理，判断是否激活该神经元。加权和值 s 如式(4)所示。

$$s=\sum_{i=1}^{6}\omega_i x_i-\theta \tag{4}$$

神经元的输出 y：

$$y=f(s) \tag{5}$$

其中，激活函数 $f(.)$ 采用常规 Sigmoid 函数[4]，如式(6)所示，保证输出范围控制在[0,1]。

$$f(s)=\frac{1}{1+e^{-s}} \tag{6}$$

输出层的神经元同理，但是隐含层到输出层的激活函数 $f(.)$ 一般选择 purelin 线性函数[4,19]。BP 神经网络的实现过程可分为正向传播和反向传播：正向传播是指输入从输入层进入网络，经隐含层通过一定运算，最终得到输出层预测值的过程；反向传播则是基于预测值与实际值之间的误差 E，通过不断调整网络的参数(权值和阈值)来使误差逐渐减小以满足精度要求[20]，单个学习样本的计算误差如式(7)所示。

$$E(n)=[y(n)-Y(n)]^2 \tag{7}$$

式中：$n=1$、2、3、…、N(N 为样本总数)；$E(n)$为第 n 个样本的预测值与实际值之间的误差；$y(n)$为第 n 个样本的计算预测值；$Y(n)$为第 n 个样本的实际输出值。

BP 神经网络的训练目标函数基于所有样本的均方误差，计算公式如式(8)所示。

$$E_{\mathrm{MSE}}=\frac{1}{N}\sum_{n=1}^{N}E(n) \tag{8}$$

式中：E_{MSE}为所有样本的预测值与实际值之间的

均方误差。

在 BP 神经网络的建立过程中，由于每一次的训练开始时，初始的连接权值和阈值都是由设置的随机数获得的，因此采用梯度下降法调整权值和阈值会随着不断的迭代容易陷入局部最优，训练较难达到全局最优的效果，可能会导致预测结果存在一定的误差。因而采用粒子群算法(PSO)优化 BP 神经网络，其原理在于采用 PSO 优化算法，将 BP 神经网络的预测误差作为评价的适应度函数，在搜索域内全局搜索，直至满足误差精度得到最优的初始连接权值和阈值。充分利用 PSO 的全局搜索能力对 BP 神经网络初始的连接权值和阈值进行优化，将算法结束后得到的全局最优解赋予 BP 神经网络，得到神经网络的最优权值和阈值，将前者良好的全局寻优能力与后者的局部寻优能力相结合，以提高神经网络的预测精度，从而改进神经网络整体的搜索效率。

3　基于 PSO-BP 神经网络的喷煤量预测

3.1　算法实现步骤

（1）数据预处理。在生产现场采集的数据可能会存在数据失真、部分值缺失和可用性差等问题。因此，为了确保系统辨识的准确性，在进行辨识之前需要对输入和输出数据进行预处理。预处理的主要目标不仅仅是消除数据中的异常值，还包括去除噪声和干扰、处理缺失值等。此外，不同物理量具有不同的量纲和分布范围，还需要对数据范围进行标准化，提高系统辨识的鲁棒性和可靠性。

本文选用试验现场采集的 300 组输入、输出数据用于神经网络的训练、测试和验证，采用去离群点[21]和相似系数[22]的方法来剔除过失误差数据以最大程度保证输入数据的精度。通过上述方法剔除 30 组异常样本数据，而后在筛选出来的 270 组数据中随机选取 220 组数据作为训练集，剩下的 50 组数据作为测试集和验证集进行神经网络模型的训练。由于输入、输出数据量级不同，为避免小量级数据在运算过程中被湮没，需要将每一个输入、输出参数分别进行归一化处理。由于输入层到隐含层的激活函数 $f(.)$ 采用的是 S 型函数，因此将数据映射到[0,1]区间内。该函数如(9)式所示。

$$x_{st}=\frac{x-x_{min}}{x_{max}-x_{min}} \tag{9}$$

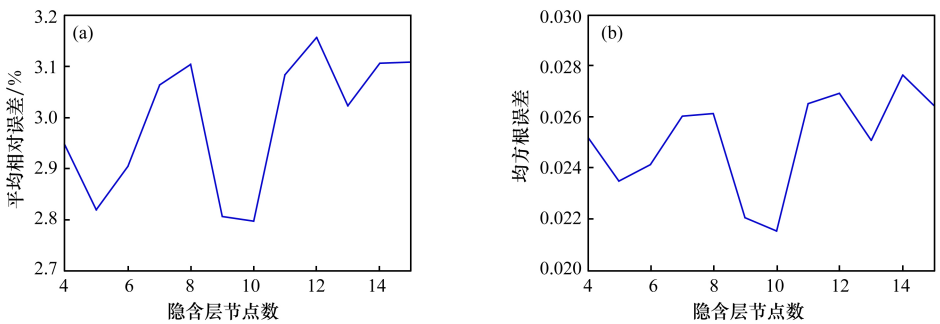
式中：x_{st}为标准化后的数据；x 为原始数据；x_{max}、x_{min}分别为各个参数原始数据集对应的最大值和最小值。

（2）确定 BP 神经网络结构。根据上述确定的系统输入、输出变量和 BP 神经网络结构，可确定模型输入层和输出层的神经元数目分别为 6 和 1，而隐含层中神经元个数未知。一般参考经验公式(10)，结合试凑法确定隐含层的神经元个数。

$$H=(R+C)^{0.5}+r \tag{10}$$

式中：H 表示隐含层中神经元个数；R 表示输入层中神经元个数；C 表示输出层中神经元个数；r 为随机值，一般取值范围为[0,10]。

本文针对[4,15]的隐含层节点数神经网络中的每个隐含层节点数的神经网络分别训练 10 次，取训练效果评价指标的平均值，如图 4 所示。由图 4 可见，当隐含层节点为 10 时，训练效果最



（a）平均相对误差；（b）均方误差

图 4　不同隐含层节点数的 BP 神经网络平均评价指标

Fig. 4　Average evaluation index of BP neural network with different number of hidden layer nodes

佳，对应的平均相对误差为 2.8%，均方误差为 0.021，因而确定神经网络为 6－10－1 型神经网络。

（3）训练参数设置。在进行 PSO-BP 神经网络的训练之前，需要对训练参数进行设置。其中，神经网络中学习率设定为 0.01，训练的最大迭代次数设定为 1 000，训练要求的精度为 0.000 01，其他参数则采用默认值。这些训练参数的设定是为了确保网络能够在合理的时间内达到所需的训练效果，同时避免过长的训练时间或无限循环的情况。

（4）粒子群算法优化。将 BP 神经网络初始的连接权值和阈值作为粒子群算法寻优的目标参数。通过粒子群算法的迭代过程，最终获得最优的初始连接权值和阈值。其具体实现步骤：① 初始化 PSO 参数。设置种群更新次数 $F=200$，种群规模 $P=30$、个体学习因子和群体学习因子 $c_1=c_2=2$，初始化粒子群位置和粒子速度，位置和速度均限制[－1,1]。适应度函数与式(8)中 BP 神经网络的目标函数一致，均为网络预测的均方误差，从而使得网络误差最小化。② PSO 迭代寻优。根据适应度函数计算初始粒子适应度获得初始最优粒子，计算种群适应度，通过式(2)、(3)更新粒子的速度和位置，确定粒子历史个体最优解与全局最优解。经过迭代后，粒子群中的所有粒子都会向着最优解靠近，直至达到最小误差精度或者迭代最大次数，输出最优粒子个体。③ 运行 PSO 寻优后的 BP 神经网络。将步骤 2 中得到的最优个体对应的参数赋予 BP 神经网络 Net 结构体参数中的权重和阈值，而后运行神经网络，训练得到最优模型。

（5）性能误差分析。性能误差分析主要针对测试集进行预测误差的分析，误差指标包括模型预测值与实际值之间的平均绝对误差(MAE)、平均相对误差(MRE)、均方误差(MSE)和均方根误差(RMSE)，以及预测值与实际值之间的线性拟合度。通过分析这些误差指标和拟合度，可以评估模型预测准确性和拟合程度。

具体的 PSO-BP 神经网络算法流程如图 5 所示。

3.2 喷煤量预测仿真结果

粒子群算法最优适应度变化曲线如图6所示。

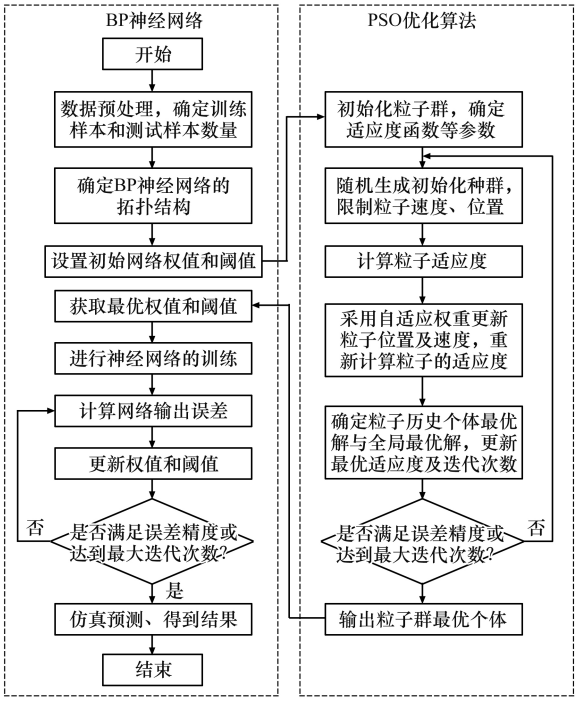


图 5 PSO-BP 神经网络算法流程

Fig. 5 Flow of the PSO-BP neural network algorithm

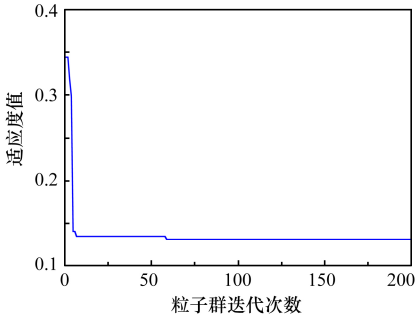
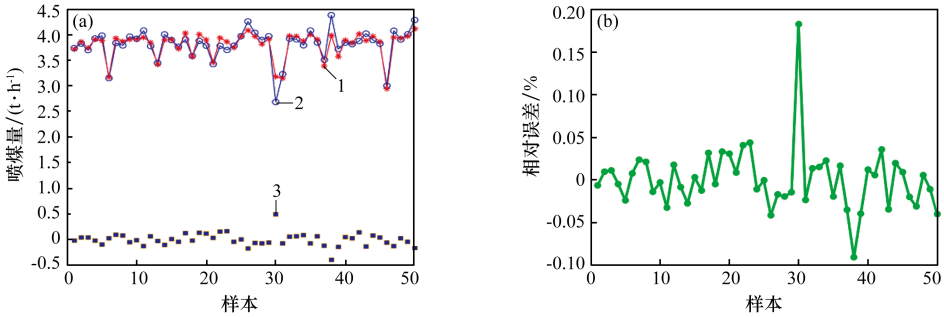


图 6 粒子群算法最优适应度变化曲线

Fig. 6 Optimal fitness change curve of particle swarm optimization algorithm

由图 6 可知：在迭代周期内，粒子群整体逐渐朝向最优适应度移动。当迭代次数约为 60 时，最优适应度值趋于稳定，这表明粒子群算法在寻优过程中具备较高的效率，能够使得粒子群快速接近最优解。

PSO-BP 模型喷煤量预测结果如图 7 所示，BP、PSO-BP 模型喷煤量预测的相关评价指标如表 2 所示。由图 7、表 2 可以看出：基于 PSO-BP 神经网络模型的喷煤量预测值和实际值吻合效果较好。采用 PSO-BP 神经网络模型的预测结果中各性能指标的误差均小于 BP 神经网络模型，就均方误差和平均相对误差而言，精度分别提升了27%



（a）实际值与预测值吻合效果；（b）相对误差

1—实际值；2—预测值；3—误差值。

图 7　基于 PSO-BP 神经网络模型的喷煤量预测结果

Fig. 7　Prediction results of coal injection rate based on PSO-BP neural network model

表 2　BP 与 PSO-BP 神经网络模型经 10 次训练的平均误差比较

Table 2　Comparison of average errors between BP and PSO-BP neural network models after 10 trainings

预测模型	平均绝对误差	均方误差	均方根误差	平均相对误差/%
BP	0. 103	0. 022	0. 147	2. 80
PSO-BP	0. 087	0. 016	0. 125	2. 45

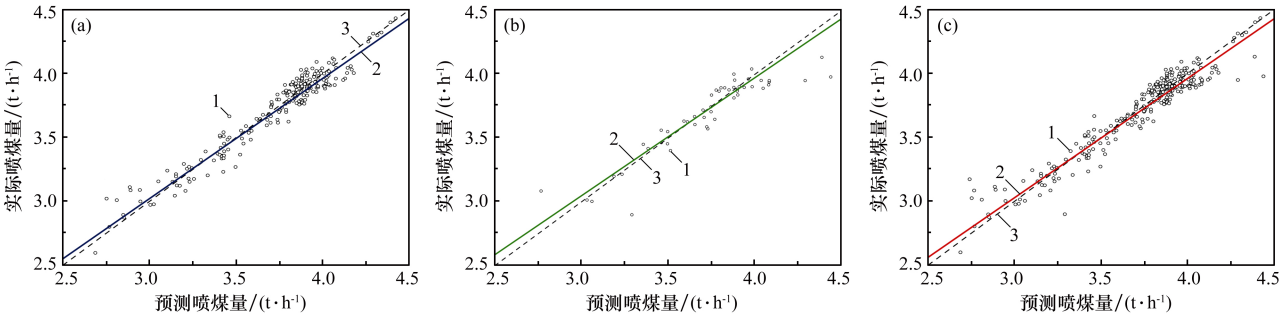
和 13%。这说明采用粒子群算法对 BP 神经网络初始权值和阈值进行优化，能够提高模型的预测精度。

将 PSO-BP 神经网络模型预测的喷煤量与实际值进行线性回归拟合，结果如图 8 所示。由图 8 可以看出：有相当一部分点落在斜率为 1 的直线上，且各个点的分布较为均匀，喷煤量的预测值与实际值偏差较小，总体拟合度为 95%，模型准确性较好。

3. 3　预热段温度的预测仿真及控制系统

依据已有的检测量和实际球团工艺生产的标准，建立 PSO-BP 神经网络模型预测某一时刻理论的喷煤量，本质还是为了控制回转窑内的温度。回转窑内球团焙烧状况主要与回转窑内的烟气温度相关，直接体现在预热段烟罩温度上。为保证球团焙烧过程的正常进行，需要一定预热段温度要求。如果预热段温度过低，可能导致反应难以启动或反应速率较慢；如果预热段温度过高，可能导致物料过早熔融或产生不良反应，影响煅烧过程的正常进行。因此，本部分基于预测的喷煤量，结合 BP 神经网络预测预热段温度，通过分析预热段温度预测值和实际值的温度偏差，来进一步验证 PSO-BP 模型预测效果的精度。

预热段温度的预测值和实际值对比如图 9 所示。由图 9 可以看出，基于 PSO-BO 神经网络模型获得的喷煤量对应的预热段温度预测值与实际值具有良好的一致性，预热段温度约为1 000 ℃，相对

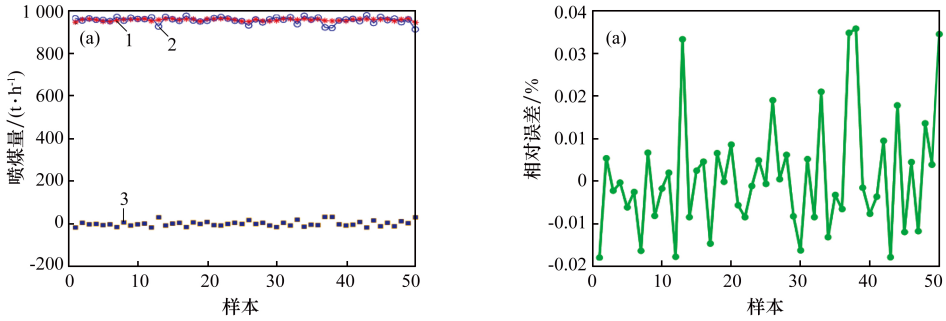


（a）训练集；（b）测试集；（c）总数据集

1—数据点；2—线性拟合曲线；3—线性拟合度为 1 的对角线。

图 8　基于 PSO-BP 神经网络模型预测喷煤量与实际值之间的线性拟合结果

Fig. 8　Linear fitting results between predicted coal injection rate based on PSO-BP neural network model and actual value



（a）预测值与实际值吻合效果；（b）相对误差

1—实际值；2—预测值；3—误差值。

图 9 预热段温度的预测值和实际值

Fig. 9 Predicted and actual values of preheating section temperature

误差最大为 2.5%，绝大部分在 2% 以内，平均相对误差为 0.8%，总体的平均温度波动在10 ℃以内，能够满足大部分球团生产中 ±30 ℃的温度波动要求。

基于前文对 PSO-BP 神经网络进行喷煤量的预测研究，在现有的传统 PID 控制系统的基础上引入神经网络作为前馈控制模块，控制系统如图 10 所示。当系统稳定运行，预热段温度变化幅度较小时，采用常规的 PID 控制模块可以满足正常的控制要求；当系统某一部分发生较大波动，如料层厚度突然变化导致预热段温度发生较大变化时，引入神经网络前馈控制模块，输入当前的检测参数及相关参数，通过训练好的 PSO-BP 神经网络为控制系统输出预测的初始喷煤量，从而缩短预热段的控制时间，提高系统的快速响应性和稳定性，进而提升成品球的质量。

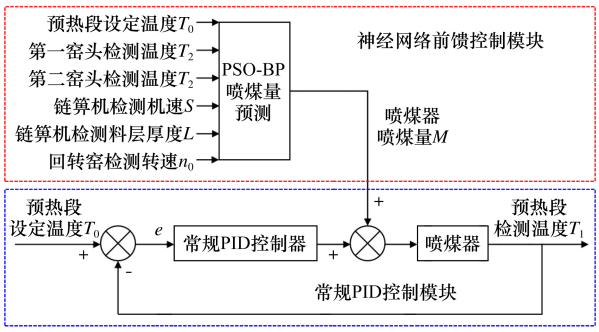


图 10 PSO-BP 神经网络前馈－PID 控制系统

Fig. 10 PSO-BP neural network feed-forward-PID control system

4 结 论

（1）基于回转窑温度、回转窑转速、链算机台车机速、料层厚度、喷煤量的运行数据，建立了 PSO-BP 神经网络的喷煤量预测模型。结果表明采用 PSO-BP 神经网络模型预测的平均绝对误差、均方误差、均方根误差、平均相对误差分别为 0.087%、0.016%、0.125%、2.45%，均优于传统 BP 神经网络模型。

（2）采用粒子群算法对 BP 神经网络的权值和阈值进行优化能够提高模型的精度，对喷煤量的精确预测具有重要作用。基于 PSO-BP 神经网络的喷煤量预测模型的相对误差最大为 2.5%，绝大部分在 2% 以内，平均相对误差为 0.8%，平均温度波动在10 ℃以内，满足球团焙烧的温度控制要求。

参考文献：

[1] 袁晓红，赵国新，王旭仁．回转窑温度神经网络控制[J]．烧结球团，2011，36(3)：34－36.
YUAN Xiaohong，ZHAO Guoxin，WANG Xuren. Neural network control of rotary kiln temperature[J]. Sintering and Pelletizing，2011，36(3)：34－36.

[2] 闫素杰，翟明，王哲．球团矿焙烧过程温度智能化控制技术[J]．山东冶金，2022，44(1)：62－65.
YAN Sujie，ZHAI Ming，WANG Zhe. Intelligent temperature control technology in pellet roasting process[J]. Shandong Metallurgy，2022，44(1)：62－65.

[3] 张瑞先，黄世来，高绪松，等．回转窑焙烧自动控制问题探讨[J]．冶金动力，2020，39(1)：60－63.
ZHANG Ruixian，HUANG Shilai，GAO Xusong，et al. A discussion on the automatic control of rotary kiln roasting[J]. Metallurgical Power，2020，39(1)：60－63.

[4] 张铭，修晓波，周峰，等．链算机预热段温度场模型的

贝叶斯 - BP 神经网络系统辨识[J]. 烧结球团，2020，45(5)：44 - 48；70.
ZHANG Ming，XIU Xiaobo，ZHOU Feng，et al. Identification on Bayes-BP neural network system for temperature field model of preheating section of chain grate[J]. Sintering and Pelletizing，2020，45(5)：44 - 48；70.

[5] 周仙霖，胡钺，刘国防，等. 链算机—回转窑热工系统的控制模型研究[J]. 烧结球团，2023，48(1)：67 - 74.
ZHOU Xianlin，HU Yue，LIU Guofang，et al. Research on control model of grate-rotary kiln thermal system[J]. Sintering and Pelletizing，2023，48(1)：67 - 74.

[6] 谌晓文，邬捷鹏. 基于 BP 神经网络的烧结终点预测模型[J]. 烧结球团，2006，31(4)：21 - 26.
CHEN Xiaowen，WU Jiepeng. BTP forecast model based on BP nerve net[J]. Sintering and Pelletizing，2006，31(4)：21 - 26.

[7] 廖超. 氧化球团烧结回转窑温度控制系统研究[D]. 长沙：中南大学，2010.
LIAO Chao. The research of pellet sintering temperature control system of rotary kiln[D]. Changsha：Central South University，2010.

[8] 张信璘，郭捷楠，沈雪，等. 遗传算法优化 BP 神经网络的水泥窑温度预测模型研究[J]. 水泥，2021(7)：12 - 15.
ZHANG Xinlin，GUO Jienan，SHEN Xue，et al. Research on prediction model of cement kiln temperature based on BP neural network optimized by genetic algorithm[J]. Cement，2021(7)：12 - 15.

[9] 吕昱呈，莫愿斌. 融入变异交叉的改进天牛须算法求解 TSP 及工程应用[J]. 计算机应用研究，2021，38(12)：3662 - 3666.
LÜ Yucheng，MO Yuanbin. Improved beetle antennae search algorithm with mutation crossover in TSP and engineering application[J]. Application Research of Computers，2021，38(12)：3662 - 3666.

[10] 徐松金，龙文. 嵌入遗传算子的改进灰狼优化算法[J]. 兰州理工大学学报，2016，42(4)：102 - 108.
XU Songjin，LONG Wen. Improved grey wolf optimization algorithm embedded with genetic operators[J]. Journal of Lanzhou University of Technology，2016，42(4)：102 - 108.

[11] 王晓东，张永强，薛红. 基于改进蚁群算法对 VRP 线路优化[J]. 吉林大学学报(信息科学版)，2017，35(2)：198 - 203.
WANG Xiaodong，ZHANG Yongqiang，XUE Hong. Improved ant colony algorithm for VRP[J]. Journal of Jilin University (Information Science Edition)，2017，35(2)：198 - 203.

[12] 王联国，施秋红. 人工鱼群算法的参数分析[J]. 计算机工程，2010，36(24)：169 - 171.
WANG Lianguo，SHI Qiuhong. Parameters analysis of artificial fish swarm algorithm[J]. Computer Engineering，2010，36(24)：169 - 171.

[13] 王培君，夏露，周文硕，等. 基于并行交换的增强粒子群优化算法在气动优化中的应用[J]. 西北工业大学学报，2022，40(3)：493 - 503.
WANG Peijun，XIA Lu，ZHOU Wenshuo，et al. Applying to aerodynamic optimization an enhanced particle swarm optimization algorithm based on parallel exchange[J]. Journal of Northwestern Polytechnical University，2022，40(3)：493 - 503.

[14] 王祎. 铁矿氧化球团链算机—回转窑模拟模型和控制指导专家系统的研究[D]. 长沙：中南大学，2012.
WANG Yi. Research on simulation model and control guidance guidance expert system of grate-kiln process for iron ore oxide pellet production[D]. Changsha：Central South University，2012.

[15] 黄伟，付家兴，谢威，等. 基于改进粒子群算法的热工温度模型辨识[J]. 热能动力工程，2017，32(11)：98 - 103；134.
HUANG Wei，FU Jiaxin，XIE Wei，et al. Identification of thermal temperature model based on improved particle swarm optimization algorithm[J]. Journal of Engineering for Thermal Energy & Power，2017，32(11)：98 - 103；134.

[16] 金森钧. 基于分布式发电和储能的家庭能量管理系统设计与优化调度算法研究[D]. 杭州：浙江大学，2017.
JIN Senjun. Research on design and optimal scheduling algorithm of home energy management system based on distributed generation and energy storage[D]. Hangzhou：Zhejiang University，2017.

[17] 黎芬芳，崔桂梅. 基于 PSO 优化 T-S 模糊神经网络的磨矿粒度预测[J]. 烧结球团，2022，47(4)：64 - 70.
LI Fenfang，CUI Guimei. Grinding size prediction of optimization of T-S fuzzy neural network based on PSO[J]. Sintering and Pelletizing，2022，47(4)：64 - 70.

(下转第 102 页)

颗粒生长动力学[J]. 中国有色金属学报,2021,31(8):2218 – 2226.
ZHANG Xinyi, LI Xiaoming, ZANG Xuyuan, et al. Growth kinetics of metallic iron particles in coal-based direct reduction of pre-oxidized nickel slag[J]. The Chinese Journal of Nonferrous Metals, 2021, 31(8): 2218 – 2226.

[16] CAO Y Y, XU C Y, TIAN Y C, et al. Effect of roasting temperature on phase transformation in co-reduction roasting of nickel slag[J]. Metals, 2020, 10(4): 550.

[17] MA Y B, DU X Y. Effects of CaO addition on the iron recycling from nickel slags by oxidation-magnetic separation[J]. Metals, 2018, 8(11): 956.

[18] 王冬青,青格勒,潘文,等. w(CaO)对球团矿高温液相生成的热力学分析[J]. 烧结球团,2020,45(1):29 – 34.
WANG Dongqing, QING Gele, PAN Wen, et al. Thermomechanical analysis of w(CaO) on the formation of high temperature liquid phase of pellets[J]. Sintering and Pelletizing, 2020, 45(1): 29 – 34.

[19] YI L Y, HUANG Z C, PENG H, et al. Action rules of H_2 and CO in gas-based direct reduction of iron ore pellets [J]. Journal of Central South University, 2012, 19(8): 2291 – 2296.

[20] WANG Z C, CHU M S, LIU Z G, et al. Effects of temperature and atmosphere on pellets reduction swelling index[J]. Journal of Iron and Steel Research, International, 2012, 19(10): 7 – 19.

[21] 闫树芳,孙体昌,许言. 煤种对嘉峪关某菱铁矿直接还原的影响[J]. 中国有色金属学报,2012,22(5):1462 – 1467.
YAN Shufang, SUN Tichang, XU Yan. Effects of coals on direct reduction roasting of siderite ore from Jiayuguan [J]. The Chinese Journal of Nonferrous Metals, 2012, 22(5): 1462 – 1467.

(上接第55页)

[18] 王大林. 激光辐照下半透明体光热信号模拟及内部参数重构[D]. 哈尔滨:哈尔滨工业大学,2014.
WANG Dalin. Optothermal signal simulation and parameter reconstruction for semi-transparent media under the laser irradiation[D]. Harbin: Harbin Institute of Technology, 2014.

[19] 尹学,李绍铭,闫成忍. 基于GA-PSO-BP神经网络的烧结终点预测模型[J]. 烧结球团,2020,45(6):35 – 39;46.
YIN Xue, LI Shaoming, YAN Chengren. Prediction model of BTP based on GA-PSO-BP neural network[J]. Sintering and Pelletizing, 2020, 45(6): 35 – 39; 46.

[20] 徐照松,元建. 基于BP神经网络的语音情感识别研究[J]. 软件导刊,2014,13(4):11 – 13.
XU Zhaosong, YUAN Jian. Speech emotion recognition based on BP neural network[J]. Software Guide, 2014, 13(4): 11 – 13.

[21] 于洪军. 链箅机—回转窑制煤系统节能改造及自动喷煤控制算法研究[D]. 鞍山:辽宁科技大学,2013.
YU Hongjun. Chain grate-rotary kiln coal preparation system energy-saving design and automatic coal injection control algorithm research [D]. Anshan: University of Science and Technology Liaoning, 2013.

[22] 冯震,付敬奇,熊南. 一种快速的离群点检测方法[J]. 电子测量与仪器学报,2016,30(11):1726 – 1734.
FENG Zhen, FU Jingqi, XIONG Nan. A novel method for rapidly outlier detection[J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(11): 1726 – 1734.