

基于粒度分布评估与优化的制粒过程 PSO-BP 控制算法

李勇^{1,2} 吴敏^{1,2} 曹卫华^{1,2} 赖旭芝^{1,2} 王春生^{1,2}

摘要 针对钢铁烧结中混合料粒度分布无法在线测量、难以实现混合制粒过程优化控制的问题, 提出基于粒度分布评估函数 (Evaluation model of granularity distribution, EMGD) 的混合制粒优化控制算法. 首先, 根据烧结生产历史数据和混合料筛分实验数据建立粒度分布 BP 神经网络 (BP neural network, BPNN) 评估模型; 然后, 以该模型为目标函数, 以制粒过程状态参数的边界为约束条件, 采用粒子群算法 (Particle swarms optimization, PSO) 计算粒度分布优化值; 最后建立基于 BPNN 的制粒水分设定模型, 根据粒度分布优化值和当前配重实现水分优化控制. 仿真实验和工业应用表明评估模型真实反映了粒度分布对料层透气性的影响; PSO-BP 粒度分布优化控制算法对改善透气性、减少燃料损耗、稳顺烧结生产具有重要意义.

关键词 烧结混合制粒, 粒度分布评估函数, BP 神经网络, 粒子群算法

引用格式 李勇, 吴敏, 曹卫华, 赖旭芝, 王春生. 基于粒度分布评估与优化的制粒过程 PSO-BP 控制算法. 自动化学报, 2012, 38(6): 1007–1016

DOI 10.3724/SP.J.1004.2012.01007

PSO-BP Control Algorithm of Granulation Process Based on Evaluation and Optimization of Granularity Distribution

LI Yong^{1,2} WU Min^{1,2} CAO Wei-Hua^{1,2} LAI Xu-Zhi^{1,2} WANG Chun-Sheng^{1,2}

Abstract Since granularity distribution of mixing materials in iron sintering can hardly be measured and controlled online, an optimal control algorithm based on evaluation model of granularity distribution (EMGD) has been developed. Firstly, EMGD based on BP neural network (BPNN) has been built by studying data from screening tests and historical state parameters in sintering process. Secondly, by using particle swarms optimization (PSO), optimal granularity distribution can be found from the optimization model restricted by the boundaries of state parameters, whose objective function is EMGD. Finally, according to optimal granularity distribution and online solid flow measurement, humidity setting model based on BPNN is studied to keep the granularity distribution stable and reasonable. Simulation and industrial application have proven that the algorithm makes great sense in permeability improvement, reduction of fuel consumption and stability of sintering process.

Key words Granulation, evaluation model of granularity distribution (EMGD), BP neural network (BPNN), particle swarms optimization (PSO)

Citation Li Yong, Wu Min, Cao Wei-Hua, Lai Xu-Zhi, Wang Chun-Sheng. PSO-BP control algorithm of granulation process based on evaluation and optimization of granularity distribution. *Acta Automatica Sinica*, 2012, 38(6): 1007–1016

混合制粒是钢铁烧结过程中的重要工序之一, 为点火烧结过程提供具有一定粒度分布规律的混合料. 混合制粒粒度分布是否合适对烧结过程的料层透气性具有直接影响, 进而影响烧结生产燃料消耗

和烧结矿质量. 因此, 研究混合制粒粒度分布优化控制, 对稳顺烧结生产过程、提高烧结矿质量、降低钢铁烧结燃料消耗具有重大意义.

国内外长期研究表明, 混合制粒粒度分布与制粒过程的加水量、制粒设备转速、填充率和制粒时间相关^[1–2]. 水分控制对于混合料粒度分布的影响巨大, 因此, 国内外的研究主要集中在混合制粒过程水分的测量与控制方面^[3–5]. 另一方面, 不同特性的原料组成与制粒后的粒度分布规律也是重点研究的领域^[6–8]. 然而, 国内外罕见研究粒度分布优化以及混合制粒过程优化控制问题, 混合制粒粒度分布控制以人工经验和手动控制为主.

本文从烧结生产实际出发, 结合制粒工艺和原

收稿日期 2011-05-06 录用日期 2012-3-20
Manuscript received May 6, 2011; accepted March 20, 2012
国家高技术研究发展计划 (863 计划) (2009AA04Z157) 资助
Supported by National High Technology Research and Development Program of China (863 Program) (2009AA04Z157)
本文责任编辑 刘民
Recommended by Associate Editor LIU Min
1. 中南大学信息科学与工程学院 长沙 410083 2. 先进控制与智能自动化湖南省工程实验室 长沙 410083
1. School of Information Science and Engineering, Central South University, Changsha 410083 2. Hunan Engineering Laboratory for Advanced Control and Intelligent Automation, Changsha 410083

料筛分实验, 提出粒级参数的概念并获得数据, 使连续的粒度分布定量化; 通过研究烧结过程料层厚度、透气程度与粒级参数之间的关系, 提出粒级参数模糊评估函数, 使制粒效果定量化. 在此基础上, 通过研究粒级参数及其模糊评估值之间的关系, 建立起粒级参数评估模型, 精确评估不同粒度分布的制粒效果; 进而以此为目标函数, 建立粒级参数优化模型, 采用粒子群算法 (Particle swarms optimization, PSO) 求解最优粒级参数, 使传统工艺中对粒度分布的定性描述提高为对粒级参数的定量计算. 最后设计水分优化控制算法, 根据粒度分布优化给定值和配重值 (进料流量), 计算出水分优化设定, 实现混合制粒粒度分布的优化控制.

1 粒级参数和粒度分布评估函数

混合制粒一般采用两次混合工艺, 分为一次混合和二次混合, 如图 1 所示. 混合料粒度分布既对烧结过程透气性具有重要影响, 也决定了混合料层所能承受的最大高度, 间接影响了烧结矿的质量和产量. 因此, 制粒过程的优化控制是现代厚料层烧结技术的关键问题之一, 找出并维持最合理的粒度分布是其核心所在.




图 1 混合制粒工艺流程图
Fig. 1 Process of blending

然而, 混合料的粒度分布难以在线测量; 同时, 粒度分布具有一定的连续性, 难以采用平均粒度的形式表示. 因此, 直接测量粒度分布或建立软测量模型均难以实现, 致使粒度分布评价只有定性的烧结实践经验, 粒度分布控制也仅依靠人工经验调节.

针对以上两个问题, 本文从制粒工艺机理和数据关联性分析出发, 分析影响粒度分布的主要因素, 确定制粒过程的可控变量; 然后, 根据工艺将连续的粒度分布划分为若干粒级参数, 以获得粒度分布的参数化表现形式; 同时, 研究不同粒级参数的混合料在烧结过程中相应的料层厚度和透气性表现, 提出粒级参数评估函数, 为粒级参数的优化提供了定量指标, 奠定了制粒过程优化控制的基础.

1.1 影响粒度分布的因素

在混合制粒过程中, 生石灰消化 ($\text{CaO} + \text{H}_2\text{O} = \text{Ca}(\text{OH})_2$) 与物料在水分子作用下粘接成团是其主要的化学、物理变化过程. 不同原料对水分的吸

收及吸附程度不同, 会导致制粒效果差异. 但是, 稳顺的烧结生产运行原则上不希望原料频繁变化并且要求原料变化后物理性能尽可能保持一致, 在不考虑原料特性差异的条件下, 混合料粒度分布受到水分、圆筒转速、填充率、混合时间等主要因素影响^[9].

混合制粒过程中水以吸附水、毛细水和重力水 3 种不同的形式存在, 分别对矿粉产生粘接、迁移和漂浮作用. 吸附水和毛细水分别决定制粒强度和制粒速度, 重力水在制粒过程造成负面影响. 水分率不同导致 3 种水分形式比例不同.

制粒圆筒以一定的转速提供摩擦力和离心力, 带动矿粉运动并使矿粉充分分散并受到挤压. 转速低, 物料堆积不易成粒; 转速大, 物料紧贴筒壁, 均会削弱制粒效果.

填充率反映矿粉进入制粒圆筒的总量. 矿粉重力可以提供制粒过程需要的部分挤压力. 填充率小, 产量低, 矿粉间相互作用力不足; 填充率大, 料层厚致使矿粉运动受限, 对制粒造成不利影响. 此外, 制粒过程需要充足的混合时间, 但混合时间进一步增加不能提高制粒效果, 反而影响生产效率.

结合机理分析与灰色关联分析方法, 可以确定粒度分布与水分值、圆筒转速、填充率、混合时间相关. 然而, 在制粒工艺中, 首先, 制粒过程要求圆筒转速恒定; 其次, 混合时间由制粒圆筒长度、倾角和制粒圆筒转速决定, 前两者是设备参数, 设备竣工后为常数, 因此在转速恒定条件下, 该参数也是定值; 再次, 填充率由配重 (进料流量) 与圆筒外形参数决定, 圆筒外形参数也是固定的设备参数, 但配重是根据烧结生产状况实时调整, 属于不可控参数. 因此, 调节粒度分布唯一的可控状态变量是水分, 需要分析在配重变化条件下, 水分与粒度分布之间的关系, 进而实现水分的优化设定.

1.2 粒级参数与粒度分布

粒级参数是指特定直径范围内的混合料重量占混合料全重的比例, 用以表征尺寸数量级从 0.1 mm ~ 1 cm 的连续的粒度分布. 在烧结生产实践中, 制粒后粒级参数 ≤ 3 mm 的混合料在烧结过程中多形成返矿, 粒级参数 ≥ 8 mm 的混合料多形成颗粒直径较大的铺底料等烧结循环利用物, 粒级参数为 3 mm ~ 5 mm 及 5 mm ~ 8 mm 的混合料则主要形成成品烧结矿.

在采用粒级参数定量化粒度分布的过程中, 若粒度分布划分过细, 粒级参数多, 优化问题复杂; 反之则难以真实反映粒度分布状态, 其最优解在实际生产中缺乏指导意义. 基于以上分析并结合烧结生产实践经验, 可以定义尺寸 ≤ 3 mm、3 mm ~ 5 mm、5 mm ~ 8 mm 和 ≥ 8 mm 这 4 种混合料粒级参数. 烧结实践表明, ≤ 3 mm 和 ≥ 8 mm 的混

合料比例相对较少, 而 3 mm ~ 5 mm 和 5 mm ~ 8 mm 占据粒度分布的主流, 4 个粒级参数服从类正态分布, 且接近 [0.15, 0.35, 0.35, 0.15]^T 时, 烧结过程相对稳定, 成品率较高. 粒级参数划分的增加或减少导致出现同一粒级参数可能对应不同烧结产物的情况, 又或多种粒级参数对应同一种烧结产物的情况, 不利于定性的烧结生产实践经验转化成模糊规则引入, 从而导致模糊评估函数建立的依据变得薄弱.

1.3 粒级参数模糊评估函数

目前, 评估^[10-11]多用于定性问题的定量表示. 粒度分布评估函数 (Evaluation model of granularity distribution, EMGD) 是对某粒级参数的混合料在烧结生产过程中优劣的一种评估, 料层透气性和厚度是其主要组成. 前者反映烧结生产稳顺程度并直接影响烧结矿质量, 后者则反映烧结矿产量. 评估的基本思想是料层厚度越大, 透气性指数值越高, 则粒度分布越合理.

烧结过程中料层透气性可以通过 Voice 公式近似计算:

$$JPU = \frac{Q}{A} \left(\frac{h}{P} \right)^{0.6} \quad (1)$$

在实际生产中, Q 表示主抽流量; A 表示抽风面积, 也就是烧结机台车的面积, 对于特定的烧结机, 该值为常数; h 表示料层厚度; P 表示大烟道负压的绝对值; JPU 表示透气性指数. Voice 公式表明透气性评估受到料层厚度的影响, 但可以明显看出, 当 Q 和 P 不变时, JPU 与 h 之间是单调递增的关系, 两者变化趋势的一致性与评估的基本思想相符合, 这使同时评估 h 和 JPU 成为可能.

基于以上分析, 利用模糊建模思想, 可以采用原料筛分实验数据建立粒级参数的模糊评估函数.

首先, 根据对生产数据的统计建立模糊隶属度函数, 如料层厚度隶属度计算如下:

$$\begin{aligned} NB: m_{f_1}(h) &= \frac{1}{1 + e^{\frac{h - (E_h - 1.177\sigma_h)}{\sigma_h}}} \\ ZO: m_{f_2}(h) &= e^{-\frac{(h - E_h)^2}{2\sigma_h^2}} \\ PB: m_{f_3}(h) &= \frac{1}{1 + e^{-\frac{h - (E_h + 1.177\sigma_h)}{\sigma_h}}} \end{aligned} \quad (2)$$

其中, NB , ZO , PB 分别表示模糊语言变量“负大”、“零”和“正大”; E_h 和 σ_h 分别为筛分实验料层厚度数据的平均值与标准差, 计算式分别如式 (3) 和式 (4) 所示.

$$E_h = \frac{1}{n} \sum_{i=1}^n h_i \quad (3)$$

$$\sigma_h = \sqrt{\frac{1}{n} \sum_{i=1}^n (h_i - E_h)^2} \quad (4)$$

其中, h_i ($i = 1, 2, \dots, n$) 表示 n 组筛分实验中第 i 次筛分实验对应的料层厚度. 类似可以定义透气性指数的隶属度函数.

然后, 建立如表 1 所示的模糊规则表.

表 1 粒级参数评估模糊规则表
Table 1 Rules of EMGD fuzzy reasoning

JPU	h		
	NB	ZO	PB
NB	NB	NB	ZO
ZO	NB	ZO	PB
PB	ZO	PB	PB

最后, 类似式 (2), 建立如式 (5) 所示的输出隶属度函数, 并采用重心法进行反模糊化, 得到粒级参数评估值的精确量.

$$\begin{aligned} NB: m_{f_1}(y) &= \frac{1}{1 + e^{\frac{(y - 0.3823)}{0.1}}} \\ ZO: m_{f_2}(y) &= e^{-\frac{(y - 0.5)^2}{0.02}} \\ PB: m_{f_3}(y) &= \frac{1}{1 + e^{-\frac{(y - 0.6177)}{0.1}}} \end{aligned} \quad (5)$$

其中, y 为输出论域. 模糊评估函数的建立实现了粒度分布从定性描述向定量计算的转变, 为粒级参数的优化提供了必要条件.

2 粒级参数优化模型及优化算法

在采用粒级参数定量化粒度分布、采用粒级参数模糊评估函数定量化制粒效果的基础上, 建立粒级参数评估模型, 研究不同粒级参数与其评估值之间的关系; 然后, 以最大化该粒级参数评估模型为目标, 以粒级参数为决策变量, 建立粒级参数优化模型, 可以求解最优的粒级参数, 从而为水分的优化控制奠定基础.

2.1 粒级参数优化模型

经数据配准后建立粒级参数样本集 S :

$$\begin{aligned} S &= \left\{ (\mathbf{X}_i, y_i) \mid \mathbf{X}_i = [x_{1i}, x_{2i}, x_{3i}, x_{4i}]^T, \right. \\ &\quad \left. y_i = f(-P_i, Q_i, h_i), i = 1, 2, \dots, n \right\} \end{aligned} \quad (6)$$

其中, x_{1i} , x_{2i} , x_{3i} , x_{4i} 分别表示 ≤ 3 mm, 3 mm ~ 5 mm, 5 mm ~ 8 mm 和 ≥ 8 mm 的 4 个混合制粒粒级参数. $\mathbf{X}_i = [x_{1i}, x_{2i}, x_{3i}, x_{4i}]^T$ 表示经过筛分后的 n 个样本数据中第 i 个粒级参数, y_i 为该粒级参数的粒度分布评估值. 根据该样本集, 采用 BP 神经

网络 (BP neural network, BPNN) 建立粒级参数评估模型. 进而以该模型为粒度分布优化模型的目标函数, 获得粒度分布的优化参数值.

BPNN 以输出误差和梯度信息不断调整自身权值和阈值参数^[12-13], 符合粒级参数评估模型的准确性和实时性要求. 评估模型采用包括输入层、隐含层和输出层的 3 层网络结构. 输入层接收粒度分布的 4 个粒级参数并原样输出, 其输出为 O_i ($i = 1, 2, \dots, I; I = 4$). 隐含层接受输入层信息并计算加权和, 经过非线性激励函数后输出. 隐含层神经元数目 $J = 6$, 输出计算式如下:

$$net_j = \sum_{i=1}^I w_{ij} O_i + v_j \quad (7)$$

$$O_j = f(net_j) = \frac{1}{1 + e^{-net_j}} \quad (8)$$

其中, w_{ij} 为输入层与隐含层间的连接权值, v_j 为隐含层阈值, net_j 为神经元接收的刺激总和, $f(\cdot)$ 为激励函数, O_j 为隐含层输出.

输出层只有 1 个神经元, 具有与隐含层神经元相同的结构, 计算如下:

$$net_k = \sum_{j=1}^J w_{jk} O_j + v_k \quad (9)$$

$$O_k = \frac{1}{1 + e^{-net_k}} \quad (10)$$

其中, w_{jk} 为隐含层与输出层间的连接权值, v_k 为输出层阈值, net_k 表示神经元接收的刺激总和, O_k 表示输出层神经元输出, 亦为 BPNN 输出.

采用反向传播算法训练 BPNN^[14], 得到粒级参数评估模型 $\psi(\mathbf{X})$, 以其为目标函数可建立如式 (11) 所示的优化模型.

$$\begin{aligned} \max y &= \psi(\mathbf{X}) \\ \text{s.t. } 0 &\leq x_i \leq 1 \\ x_1 + x_2 + x_3 + x_4 &= 1 \end{aligned} \quad (11)$$

2.2 粒级参数优化算法

粒级参数优化模型的目标函数为 BPNN, 具有明显的非线性, 优化过程中易于陷入局部最小值, 本文以粒级参数决策变量建立解空间, 采用 PSO 高效求解最优粒级参数.

PSO 是一种模仿鸟类觅食行为的进化计算算法, 具有搜索效率高、不易陷入局部最小值的特点. 算法基于 3 个假设条件^[15]: 粒子可以感知自身与目标的距离; 可以记忆自身到达过的距目标最近位置 (个体最优值); 相互通信并告知目前群体到达过的距目标最近位置 (群体最优值). 在以上 3 个假设基础

上, 粒子通过自身记忆和群体间相互通信, 使粒子群整体向目标移动, 这就是 PSO 的基本思想.

以 4 个粒级参数建立 4 维空间, 则优化问题 (11) 的一组解映射为该空间中的一点, 即粒子所在位置, 在 PSO 迭代过程中, 每个粒子的移动速度以个体最优值和群体最优值为指导, 并在自身运动惯性的作用下向目标方向移动, 同时在此过程中不断刷新个体最优值和群体最优值, 直至到达目标. 迭代过程如下:

$$\begin{aligned} \mathbf{V}_i(k) &= w\mathbf{V}_i(k-1) + C_1 R_1 \Delta \mathbf{P}_{1i} + C_2 R_2 \Delta \mathbf{P}_{2i} \\ \Delta \mathbf{P}_{1i} &= \mathbf{pIbest}_i(k) - \mathbf{P}_i(k) \\ \Delta \mathbf{P}_{2i} &= \mathbf{pGbest}(k) - \mathbf{P}_i(k) \end{aligned} \quad (12)$$

$$\mathbf{P}_i(k+1) = \mathbf{P}_i(k) + \mathbf{V}_i(k) \quad (13)$$

其中, $\mathbf{V}_i(k)$ 和 $\mathbf{V}_i(k-1)$ 分别表示粒子当前的运动速度和前一次运动速度; $\mathbf{P}_i(k+1)$ 和 $\mathbf{P}_i(k)$ 分别表示粒子下一次运动到的位置和当前所在位置; C_1 , C_2 为常数, 分别影响粒子局部搜索能力和全局搜索能力; R_1 , R_2 为 0 ~ 1 之间的独立随机数; w 表示粒子惯性的系数, 反映粒子惯性的影响. 第 k 次迭代的个体最优值 $\mathbf{pIbest}_i(k)$ ($i = 1, 2, \dots, n$) 和群体最优值 $\mathbf{pGbest}(k)$ 通过 $\psi(\mathbf{X})$ 确定.

经过 PSO 优化后, 可以得到优化粒级参数 $\mathbf{X}^* = [x_1^*, x_2^*, x_3^*, x_4^*]^T$, 进而可以研究在该粒级参数下, 制粒过程各操作参数的优化设定问题.

由于筛分实验无法在线进行, 只能取样后离线完成, 因此粒级参数优化模型的更新和粒级参数优化解的搜索只有在最新样本添加时完成. 若没有新样本添加, 则系统沿用最新计算得到的最优粒级参数, 既节省了算法开销, 也提高了系统的实时性.

3 水分优化设定模型

在获得最优粒级参数后, 需要将其转变为制粒过程水分设定才能应用于实际生产. 由于影响粒度分布的操作参数包括不可控的配重和可控的水分, 因此在研究不同配重和粒级参数与水分设定值之间关系的基础上, 建立水分优化设定模型, 根据最优粒级参数计算不同配重条件下的水分优化设定值是实现粒度分布优化控制的最后一步.

在实际烧结生产过程中, 用于水分检测的红外水分仪长期使用会出现温度漂移等问题, 导致水分测量误差增大, 甚至出现测量错误. 因此, 若直接建立水分、配重等操作参数与各粒级参数 (状态参数) 之间的关系模型, 以此建立水分与粒度分布优化模型之间关系, 甚至以操作参数取代状态参数作为决策变量的常规优化控制方法, 必然导致建模过程中

大量水分数据失实, 优化模型中增加了随机的不确定性因素, 给实际生产带来不利影响. 基于以上分析, 在水分优化设定模型中, 应尽量避免水分数据作为模型输入, 甚至是决策变量.

制粒过程中水分存在的形式和比例不同, 对粒度分布造成了不同的影响. 然而, 在后续的抽风过程中, 水分的蒸发需要消耗更多的焦粉燃烧供热, 制粒过程水分值过高对于抽风烧制过程具有相当不利的影响. 在工艺上, 保证粒度分布合适的条件下, 制粒过程水分值越少越好. 基于该工艺要求, 在建立水分设定样本集的过程中, 对与粒级参数、配重相似而水分值差异较大的样本进行聚类处理, 并取信水分值较小的样本, 剔除水分值较大的样本, 保证了水分值变化相对于粒度分布变化的唯一性. 因此, 对于只有水分、配重影响粒级参数分布的双输入系统, 在已知系统最优状态 (粒级参数) 以及其中一个输入 (配重) 的情况下, 可以反推使该最优状态出现的另一个输入 (水分值).

基于以上思想, 以粒级参数数据及对应配重为样本输入, 以水分数据 (红外水分仪刚标定完成) 为样本输出建立样本集, 采用 BPNN 方法建立水分优化设定模型, 以粒级参数优化模型计算得到的优化粒级参数 \mathbf{X}^* 与时变的配重值为输入, 实时求解出水分实时优化设定值, 建立如图 2 所示的递阶结构水分优化控制系统. 由于模型训练完成后, 其输入最优粒级参数、实时配重均可以准确计算或测量, 因此在很大程度上减少了水分值测量误差带来的建模影响, 更加符合过程控制的稳定性要求.




图 2 水分控制优化控制结构框图

Fig. 2 Optimal control of humidity

经数据配准后建立水分设定样本集 \mathbf{Z} :

$$\mathbf{Z} = \left\{ (\mathbf{X}'_i, y'_i) \mid \mathbf{X}'_i = [x_{1i}, x_{2i}, x_{3i}, x_{4i}, m_i]^T, \right. \\ \left. y'_i = H_i, i = 1, 2, \dots, n \right\} \quad (14)$$

其中, m_i 表示第 i 个样本配重, H_i 表示第 i 个样本水分值, 其他变量与前所述一致.

建立该样本集后, 可以建立 3 层结构的 BPNN 模型, 输入层、隐含层和输出层的神经元数目分别为 5, 6, 1. BPNN 水分设定模型训练完成后, 采用粒级参数优化模型求解出的优化粒级参数 \mathbf{X}^* 与实时配重值作为实时输入, 实现水分的在线优化设定.

4 仿真实验及结果分析

以某钢铁企业 360 m² 烧结生产线 2010 年 4 月至今的生产历史数据以及期间进行的 36 次筛分实验数据, 进行建模、算法设计与分析, 仿真实验结果将分成 3 部分依次给出. 为了比较常用算法的优劣, 选择以大范围全局逼近为特点的 BPNN 模型和以小范围局部泛化为特点的最小二乘支持向量机 (Least squares support vector machines, LS-SVM) 进行建模对比实验, 从而验证选择 BPNN 的优越性.

采用以下 5 种评价标准:

1) 模型平均误差

$$e = \frac{1}{n} \sum_{i=1}^n |t_k(i) - y_k(i)| \quad (15)$$

2) 模型标准差

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n [t_k(i) - y_k(i)]^2} \quad (16)$$

3) 最大误差

$$Emax = \max |t_k(i) - y_k(i)| \quad (17)$$

4) 阈值为 ξ 时的准确率

$$Ac = P(y_k(i) \in [t_k(i) - \xi, t_k(i) + \xi]) \times 100\% \quad (18)$$

5) 模型精度

$$Pr = \left(1 - \frac{\sigma}{\frac{1}{N} \sum_{i=1}^N t_k(i)} \right) \times 100\% \quad (19)$$

其中, $t_k(i)$ 与 $y_k(i)$ 分别为第 i 个样本的期望值与模型输出.

在不同参数下, BPNN 和 LS-SVM 的建模效果不同. 为了消除由于参数设置不同对建模效果的影响, 采用 PSO 对 BPNN 和 LS-SVM 模型的参数进行优化设置, 从而找到建模误差最小的 BPNN 模型和 LS-SVM 模型.

对于 BPNN 而言, 其初始权值、阈值以及学习率、冲量系数对建模效果有重要影响. 初始权、阈值设置给 BPNN 带来了很大的随机性, 一般采用随机数. 学习率是 BPNN 训练过程中的步长系数, 其增大可以加快收敛速度, 但是过大容易影响 BPNN 学习过程的稳定性, 一般取值 0.01 ~ 0.1. 冲量系数是为了加快收敛速度, 反映参数上次变化对本次变化的影响.

对于 LS-SVM 而言, 其参数相对较少, 主要包括风险系数和核函数宽度. 风险系数实现拟合误差

和算法复杂度之间的折中, 过大会造成“过拟合”, 增加模型在样本拟合过程中的结构风险; 反之会造成“欠拟合”, 模型在样本拟合过程中的拟合误差增大. 核函数宽度反映了从低维空间向高维空间映射后样本的形状, 过小容易产生“过学习”现象, 泛化能力较差; 过大容易造成“欠学习”现象, 预测误差较大.

第 1 部分实验进行粒度参数评估模型准确性仿真. 以如式 (20) 所示的训练样本误差平方和的最小化为优化目标.

$$E_m = \sum_{i=1}^M (t_i - O_i)^2 \quad (20)$$

其中, M 为训练样本个数, t_i 为样本期望输出, O_i 为模型输出. 以该式为优化目标对 BPNN 和 LS-SVM 的参数采用 PSO 算法进行优化设置, 经 20 次迭代计算后, 模型初始参数设置如下: 粒度参数 BPNN 模型的学习率 α 选取 0.053, 冲量系数 β 选取 0.105. 粒度参数 LS-SVM 模型风险系数 $C = 292$, 核函数宽度 $\theta = 0.2437$. 20 次收敛过程 E_m 的平均值变化如图 3 所示.





图 3 模型初始参数优化过程图


Fig. 3 PSO optimization for initial parameters setting of BPNN and LS-SVM

经模型初始参数优化后, BPNN 和 LS-SVM 的测试集仿真实验结果如图 4 所示. 5 项建模指标如表 2 所示.



(a) 输出对比图

(a) Comparison of EMGD outputs and actual outputs



(b) 误差曲线图

(b) Error curves

图 4 粒度参数模型仿真实验图

Fig. 4 Simulation of EMGD model using BPNN

表 2 粒度参数评估模型指标表

Table 2 Qualities of EMGD

模型	指标				
	e_M	σ_M	E_{max_M}	Ac_M	Pr_M
BPNN	0.0303	0.0425	0.1061	94.44 %	94.13 %
LS-SVM	0.0830	0.1269	0.3891	66.67 %	82.49 %

仿真结果中, 粒度参数 BPNN 模型精度 Pr_M 达到 94.13%, $\xi = 0.1$ 时的准确率 Ac_M 达到 94.44%; 粒度参数 LS-SVM 模型精度的相同指标仅为 82.49% 和 66.67%. 以上仿真实验结果表明, 在评估不同粒度参数的制粒效果方面, BPNN 模型较 LS-SVM 模型更好地反映了其变化趋势, 可以对不同粒度参数在烧结过程中的表现进行更准确地定量评估, 验证了本文选择 BPNN 作为粒度参数评估模型建模方法的有效性和优越性.

建立粒度参数评估模型后, 采用 PSO 求解最优粒度参数. 粒子惯性系数 w 是一个在区间 $[0, 1]$ 内的常数, 其越大粒子群在搜索初期收敛速度就越快, 但是在收敛末期也越容易发生振荡现象; 反之, 粒子群在搜索初期收敛速度变慢, 增加了迭代次数, 但是在收敛末期不容易发生振荡现象; 粒子群常数 C_1 和 C_2 分别反映个体记忆和群体通信对粒子个体运动状态的影响, C_1 和 C_2 越大, 代表粒子个体受到个体最优值和群体最优值的影响也就越大, 粒子在移动过程中的步长也就越长; 反之, 粒子个体受到个体最优值和群体最优值的影响也就越小. 通过如表 3 所示的实验与参数对比, PSO 参数取值为粒子群规模 $num = 100$, 常数 $C_1 = C_2 = 2$, 惯性系数 $w = 0.8$, 最大迭代次数 $K = 100$. 在以上参数设置下进行 20 次仿真实验, PSO 算法迭代过程全局优化解均值如图 5 所示.

从图 5 中 PSO 优化过程粒度参数评估迭代均值可以看出, 在 100 次迭代内, 最优粒度参数 $\mathbf{X}^* = [0.1359, 0.3662, 0.3420, 0.1559]^T$ 已被找到. 由此可知, 在目标函数为强非线性的粒度参数 BPNN 评估模型的条件, PSO 仍然能够高效搜索粒度分布优

化模型的全局最优解。

表3 粒子群收敛速度对比表
Table 3 Comparison of different parameters settings in PSO

参数设置	指标			
	搜索次数	最优值	搜获次数	准确率 (%)
$C_1 = C_2 = 2, w = 0.8$	1 136	1.03425	20	100
$C_1 = C_2 = 2, w = 1.0$	983	1.03425	18	90
$C_1 = C_2 = 2, w = 0.6$	1 457	1.03425	20	100
$C_1 = C_2 = 1, w = 0.8$	1 569	1.03425	20	100
$C_1 = C_2 = 1, w = 1.0$	1 342	1.03425	19	95
$C_1 = C_2 = 1, w = 0.6$	1 958	1.03425	20	100
$C_1 = C_2 = 3, w = 0.8$	973	1.03425	19	95
$C_1 = C_2 = 3, w = 1.0$	827	1.03425	17	85
$C_1 = C_2 = 3, w = 0.6$	1 089	1.03425	19	95






图5 粒度分布评估优化趋势图
Fig. 5 Process of PSO optimization

第2部分实验在获得最优粒度参数 X^* 后, 首先根据实际粒度参数和实际配重建立 BPNN 水分设定模型和 LS-SVM 水分设定模型, 参数经 PSO 优化后, BPNN 水分设定模型的学习率 $\alpha = 0.071$, 冲量系数 $\beta = 0.127$. LS-SVM 水分设定模型风险系数 $C = 254$, 核函数宽度 $\theta = 0.3143$. 仿真实验结果如图6所示, 对应建模指标如表4所示。



(a) 手动控制与优化控制水分设定对比图
(a) Comparison of given humidity between manual set and optimal set



(b) 误差曲线图
(b) Error curves

图6 粒度参数模型仿真实验图
Fig. 6 Simulation of EMGD model using BPNN

表4 水分设定模型指标表
Table 4 Qualities of humidity setting model

模型	指标				
	e_H	σ_H	E_{maxH}	Ac_H (%)	Pr_H (%)
BPNN	0.0445	0.0527	0.1047	94.44	99.2
LS-SVM	0.0691	0.1133	0.3930	77.78	98.34

仿真结果中, BPNN 水分设定模型精度 Pr_H 达到 99.23%, $\xi = 0.1$ 时的准确率 Ac_M 达到 94.44%; 相应的 LS-SVM 水分设定模型精度与准确率分别只有 98.34% 和 77.78%。以上仿真实验结果表明, BPNN 水分设定模型具有更高的精度和更小的误差, 可以真实反映粒度参数、配重与水分之间的关系。因此, 在建立水分设定模型的过程中, 仍然选择 BPNN 建模方法。

以优化粒度参数和实际配重为输入, 分别代入 BPNN 水分设定模型和 LS-SVM 水分设定模型, 计算各自的水分优化设定, 结果如图7所示。




图7 水分优化设定图
Fig. 7 Optimal humidity setting

由于水分设定模型的仿真结果并不能说明粒度分布的控制效果, 因此第3部分仿真实验需要利用配重、水分生产数据和粒度参数筛分实验数据, 分别对建立4个粒度参数的动态特性数学模型进行系统辨识, 以此作为仿真实验被控对象, 通过控制系统仿真给出最终的评价。在配重输入相同的情况下, 分别输入实际水分给定值和水分优化给定值, 系统稳定

后各粒级参数如图 8 所示。

原有手动控制的水分实际值和仿真实验给出的优化控制水分设定值的各粒级参数控制平均值如表 5 所示。由表 5 可以看出, 与手动控制相比, PSO-BP 优化控制的水分设定更合理, 粒级参数与优化值更接近。

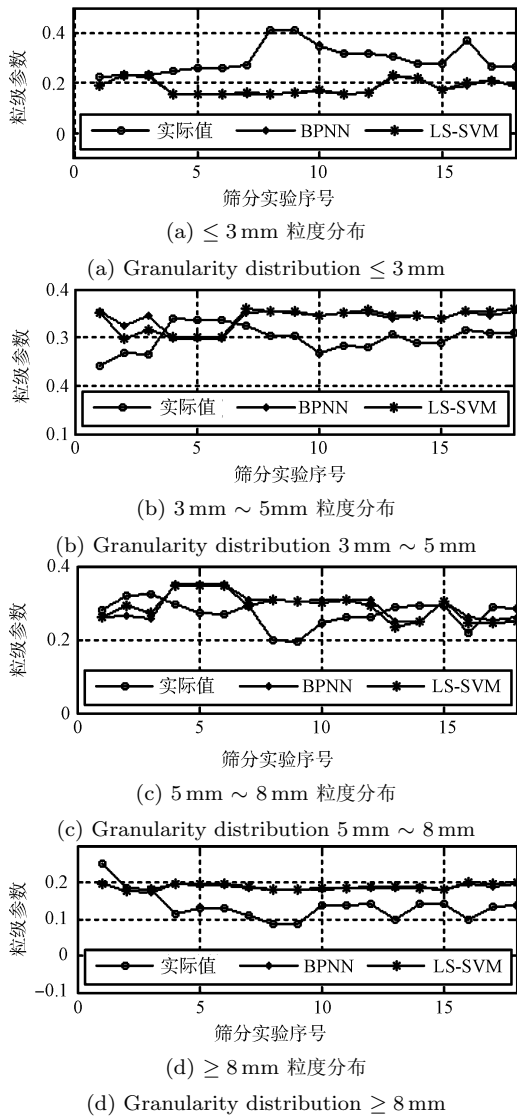


图 8 粒级参数模型仿真实验图

Fig.8 Simulation of EMGD model using BPNN

表 5 不同控制形式的粒级参数对比表

Table 5 Comparison of distribution among different control methods

粒级参数	控制形式		
	手动控制	BPNN	LS-SVM
≤ 3mm	0.2964	0.1830	0.1847
3 mm ~ 5 mm	0.2979	0.3386	0.3380
5 mm ~ 8 mm	0.2709	0.2922	0.2887
≥ 8 mm	0.1348	0.1862	0.1866

采用各粒级平均误差 E_i 、粒度控制平均误差 E 、各粒级粒度标准差 σ_i 与平均粒度标准差 σ 等指标进行进一步对比。 E_i 反映每个粒级参数控制结果与优化给定值之间的误差, E 是 E_i 的整体反映; σ_i 反映粒级参数控制过程的平稳性, σ 是 σ_i 的整体反映。以上参数计算如下:

$$E_i = \frac{1}{n} \sum_{i=1}^n |r_i - y_i(k)| \quad (21)$$

$$E = \frac{1}{4} \sum_{i=1}^4 E_i \quad (22)$$

$$\sigma_i = \sqrt{\frac{1}{n} \sum_{i=1}^n \left[y_i(k) - \frac{1}{n} \sum_{k=1}^n y_i(k) \right]^2} \quad (23)$$

$$\sigma = \sqrt{\frac{1}{4n} \sum_{i=1}^4 \sum_{k=1}^n \left[y_i(k) - \frac{1}{n} \sum_{k=1}^n y_i(k) \right]^2} \quad (24)$$

其中, r_i 表示优化粒级参数; $y_i(k)$ 表示第 k 个样本控制稳定后的第 i ($i = 1 \sim 4$ 分别表示 ≤ 3 mm, 3 mm ~ 5 mm, 5 mm ~ 8 mm 和 ≥ 8 mm) 个粒级参数值。

经过计算, 原有手动控制粒度平均误差为 0.0843, PSO-BP 优化控制为 0.0395; 相对降低 53.14%; 原有手动控制平均粒度标准差为 0.0411, PSO-BP 优化控制为 0.0247, 相对降低 39.90%。其他指标对比如表 6 和表 7 所示。

表 6 指标 E_i 和 E 对比表

Table 6 Comparison of E_i and E

指标	控制形式		
	手动控制	BPNN	LS-SVM
E_1	0.1605	0.0471	0.0488
E_2	0.0683	0.0276	0.0282
E_3	0.0711	0.0531	0.0552
E_4	0.0373	0.0303	0.0327
E	0.0843	0.0395	0.0412

表 7 指标 σ_i 和 σ 对比表

Table 7 Comparison of σ_i and σ

指标	控制形式		
	手动控制	BPNN	LS-SVM
σ_1	0.0570	0.0280	0.0283
σ_2	0.0270	0.0194	0.0225
σ_3	0.0359	0.0350	0.0355
σ_4	0.0386	0.0070	0.0072
σ	0.0411	0.0247	0.0256

从表 6 中可以看出, PSO-BP 优化控制的粒度分布显然较手动控制更为合理, 同时略优于 PSO-LS-SVM 优化控制, 与最优粒度参数差距最小. 由于实际控制过程中无法引入粒度参数的在线反馈, 因此开环控制难以消除与最优粒度参数之间的误差.

从表 7 中可以看出, 配重变化时, PSO-BP 优化控制合理调整了水分给定值, 粒度分布的波动程度较手动控制大幅降低, 略优于 PSO-LS-SVM 优化控制, 保证了烧结生产的稳顺进行.

将优化控制和手动控制的粒度参数代入粒度参数评估模型, 三者评估值对比如图 9 所示. 可以看出: 优化控制的粒度参数评估值明显高于原有的手动控制, PSO-BP 优化控制也略优于 PSO-LS-SVM 优化控制, 制粒效果得到了很大改善.




图 9 控制评估对比仿真实验图

Fig. 9 Comparison of EMGD values among different control methods

以上 3 部分仿真结果充分说明, 基于粒度分布评估的混合制粒 PSO-BP 控制优化算法可以有效提高制粒效果、降低粒度分布波动幅度. 工业实践表明, 粒度分布优化控制提高了料层透气性, 间接降低了燃料消耗并提高了烧结矿的质量. 据工业报表统计, 烧结机焦炭消耗量由 75 082.60 吨/月下降到 72 625.37 吨/月, 降低了 3.3%; 烧结矿合格率从平均 91.08% 提高到 93.78%.

5 结论

本文针对难以实现混合制粒过程优化控制的问题, 提出基于粒度分布评估的混合制粒 PSO-BP 优化控制算法, 得到以下结论:

1) 根据原料筛分实验提出了粒度参数的概念, 获得粒度分布的参数化表现形式;

2) 根据不同粒度分布的混合料在烧结生产中的性能表现, 提出了基于模糊推理的粒度分布评估函数, 并以粒度参数及对应评估值建立样本集, 建立基于 BPNN 的粒度分布优化模型, 进而采用 PSO 求解得到最优粒度参数;

3) 研究了配重变化情况下不同粒度参数与制粒水分之间的关系, 建立了 BPNN 水分设定模型, 在最优粒度参数和实时配重给定的条件下, 实现制粒

过程水分优化控制.

综上所述, 与现阶段单一的粒度分布人工控制相比, 本文提出的优化控制提高了粒度分布的合理性, 改善烧结料层透气性, 对烧结生产的稳顺运行、烧结矿质量的提高具有重要意义.

References

- Wang Jing-Bo, Wu Feng-Xia, Li Fa-Zhan. Some measures for reducing sinter returns. *Sintering and Pelletizing*, 2003, **28**(4): 53–55
(王静波, 吴凤霞, 李发展. 降低烧结返矿率的途径与实践. 烧结球团, 2003, **28**(4): 53–55)
- Li Qiang. Research on the granulation parameters of sinter mix with higher concentrates ratio in TAIGANG. *Sintering and Pelletizing*, 2008, **33**(4): 24–28
(李强. 太钢高精粉率原料条件下制粒参数优化的探索. 烧结球团, 2008, **33**(4): 24–28)
- Li Yong, Wu Min, Cao Wei-Hua. An adaptive control scheme for granulating humidity craft using PSO algorithm. *Chinese Journal of Scientific Instrument*, 2009, **30**(6S): 64–68
(李勇, 吴敏, 曹卫华. 基于 PSO 算法的烧结制粒湿度自适应控制. 仪器仪表学报, 2009, **30**(6S): 64–68)
- Hossein-Babaei F, Rahbarpour S. Porosity modification for the adjustment of the dynamic range of ceramic humidity sensors. In: *Proceedings of the 3rd International Conference on Sensing Technology*. Tainan, China: IEEE, 2008. 648–651
- Gong Da-Cheng, Xiang Zhan-Qin, Pan Xiao-Hong, Lv Fu-Zai. Design and research of in-process particle size measurer. *Chinese Journal of Scientific Instrument*, 2006, **27**(6): 602–606, 642
(龚大成, 项占琴, 潘晓弘, 吕福在. 新型在线粒度检测仪的设计与研究. 仪器仪表学报, 2006, **27**(6): 602–606, 642)
- Waters A G, Litster J D, Nicol S K. A mathematical model for the prediction of granule size distribution for multicomponent sinter feed. *The Iron and Steel Institute of Japan International*, 1989, **29**(4): 274–283
- Kapur P C, Runkana V. Balling and granulation kinetics revisited. *International Journal of Mineral Processing*, 2003, **72**(1–4): 417–427
- Kawaguchi T, Yoshinaga M, Ichidate M. Development and application of an integrated simulation model for iron ore sintering. *Ironmaking Proceedings*, 1987, **46**(1): 99–106
- Zhou Chuan-Qiang, Bai Chen-Guang, Lv Xue-Wei, Xie Hao, Wang Tao, Xia Hai-Ying. Fuzzy cluster analysis of granulation characteristics of iron ore. *Sintering and Pelletizing*, 2009, **34**(3): 16–20
(周传强, 白晨光, 吕学伟, 谢皓, 王涛, 夏海英. 铁矿粉制粒特性模糊聚类分析. 烧结球团, 2009, **34**(3): 16–20)
- Li Ming, Zhang Hua-Guang, Wang Cheng-Hong. Fuzzy tracking control design for nonlinear systems via T-S fuzzy performance evaluator. *Acta Automatica Sinica*, 2004, **30**(4): 578–582
(黎明, 张化光, 王成红. 基于 T-S 模糊性能评估器的非线性系统跟踪控制器设计. 自动化学报, 2004, **30**(4): 578–582)
- Ge T. The concept of configuration redundancy and integrated evaluation and disposition of redundancy in sensor systems. *Acta Automatica Sinica*, 2003, **29**(2): 181–189
- Wu Min, Tang Zhao-Hui. Expert control using neural networks for an electrolytic zinc process. *Acta Automatica Sinica*, 2001, **27**(6): 867–869
(吴敏, 唐朝晖. 锌湿法冶炼电解过程的神经网络专家控制. 自动化学报, 2001, **27**(6): 867–869)

- 13 Cai Z X. *Intelligent Control*. Beijing: Publishing House of Electronics Industry, 2004. 253–258
- 14 Wu Min, Xu Chen-Hua. An intelligent integrated predictive method based on gas temperature profile for Burn-through Point. *Acta Automatica Sinica*, 2007, **33**(12): 1313–1320 (吴敏, 徐辰华. 基于烟气温度场分布的烧穿点智能集成预测方法. *自动化学报*, 2007, **33**(12): 1313–1320)
- 15 Pan Feng, Chen Jie, Xin Bin, Zhang Juan. Several characteristics analysis of particle swarm optimizer. *Acta Automatica Sinica*, 2009, **35**(7): 1010–1015 (潘峰, 陈杰, 辛斌, 张娟. 粒子群优化方法若干特性分析. *自动化学报*, 2009, **35**(7): 1010–1015)



李 勇 中南大学信息科学与工程学院博士研究生. 2006 年获中南大学学士学位. 主要研究方向为过程控制与智能控制. E-mail: liyong@wuhua.csu.edu.cn
(**LI Yong** Ph.D. candidate at the School of Information Science and Engineering, Central South University. He received his bachelor degree from Central South University in 2006. His research interest covers process control and intelligent control.)



吴 敏 中南大学信息科学与工程学院教授. 1999 年获东京工业大学博士学位. 主要研究方向为过程控制, 鲁棒控制, 智能系统. 本文通信作者.
E-mail: min@csu.edu.cn
(**WU Min** Professor at the School of Information Science and Engineering, Central South University. He received his Ph.D. degree from Tokyo Institute of Technology in 1999. His research interest covers process control, robust control, and intelligent systems. Corresponding author of this paper.)



曹卫华 博士, 中南大学信息科学与工程学院教授. 2007 年获中南大学博士学位. 主要研究方向为过程控制, 多智能体系统, 机器人技术.

E-mail: caowh@mail.csu.edu.cn

(**CAO Wei-Hua** Ph.D., professor at the School of Information Science and Engineering, Central South University. He received his Ph.D. degree from Central South University in 2007. His research interest covers process control, multi-agent systems, and robot technology.)



赖旭芝 博士, 中南大学信息科学与工程学院教授. 主要研究方向为非线性控制, 机器人, 智能系统, 传感器网络.

E-mail: xuzhi@csu.edu.cn

(**LAI Xu-Zhi** Ph.D., professor at the School of Information Science and Engineering, Central South University. Her research interest covers nonlinear control, robotics, intelligent systems, and sensor networks.)



王春生 博士, 中南大学信息科学与工程学院副教授. 2008 年获中南大学博士学位. 主要研究方向为过程控制与智能控制.

E-mail: wangcsu@mail.csu.edu.cn

(**WANG Chun-Sheng** Ph.D., associate professor at the School of Information Science and Engineering, Central South University. He received his Ph.D. degree from Central South University in 2008. His research interest covers process control and intelligent control.)