

铅锌烧结配料过程的智能集成建模与综合优化方法

王春生¹ 吴敏¹ 曹卫华¹ 何勇¹

摘要 以铅锌烧结配料过程为背景, 针对传统配料方法中存在的成本高和准确率低的问题, 提出一种智能集成建模与综合优化方法. 首先, 在建立过程神经网络模型和改进灰色系统预测模型的基础上, 利用信息论中熵值的概念, 提出一种既可保证预测精度又能满足配料计算对数据完备性要求的烧结块成分集成预测模型; 其次, 以成本最小为目标建立烧结配料优化模型, 采用基于专家推理策略和改进免疫遗传算法的定性定量综合集成方法, 实现烧结配料的优化. 仿真结果验证了该方法的有效性.

关键词 铅锌烧结过程, 集成预测模型, 配料优化模型, 专家推理策略, 改进免疫遗传算法, 定性定量综合集成
中图分类号 TP273

Intelligent Integrated Modeling and Synthetic Optimization for Blending Process in Lead-Zinc Sintering

WANG Chun-Sheng¹ WU Min¹ CAO Wei-Hua¹ HE Yong¹

Abstract To deal with the problem of high cost and low accuracy existing in conventional methods for the blending process in lead-zinc sintering, a kind of methodology for intelligent integrated modeling and synthetic optimization is proposed in this paper. First, based on the process neural network model and improved grey system prediction model, an intelligent integrated model is presented using the concept of entropy to not only guarantee the composition prediction precision of Pb-Zn agglomerate but also meet the requirements of the data completeness by blending computation. Then, a blending optimization model is established for the purpose of minimizing the costs. Finally, the mixture ratios are optimized by using a qualitative and quantitative meta-synthesis methodology based on the expert reasoning strategies and improved immune genetic algorithm. The simulation results demonstrate the validity of the proposed methodology.

Key words Lead-Zinc sintering process, integrated prediction model, blending optimization model, expert reasoning strategy, improved immune genetic algorithm, qualitative and quantitative synthesis

铅锌烧结过程是密闭鼓风机铅锌熔炼工艺 (Imperial smelting process, ISP) 的一个重要工艺流程, 配料是烧结生产过程的首道工序, 其一配配比和二配配比用于调节精矿和返粉的加料量, 是铅锌烧结过程的一个重要操作参数, 对烧结透气性等其他参数有较大影响, 并最终影响到烧结生产的产量、质量等指标参数, 所以对烧结配比进行优化具有非常重要的意义.

针对烧结配料优化问题, 许多学者进行了广泛研究^[1-3]. 在实际的铅锌烧结生产过程中, 配料作为稳定和优化生产的首要环节尚未充分发挥作用: 如

配比的确定采用传统的验算法, 工程技术人员根据原料的化学成分和烧结块的技术规格, 凭经验给出各种原料配料比的假设, 然后按照一定步骤进行验算. 该方法存在以下问题: 计算量大且自动化水平低, 配比的确定没有直接与烧结块质量挂钩, 准确率和经济性不高.

本文针对上述问题, 结合某冶炼厂生产实际, 在对烧结过程工艺机理进行分析的基础上, 建立了烧结块成分集成预测模型和配料优化模型, 提出了专家推理策略和改进免疫遗传算法, 从系统论的观点出发, 采用定性定量综合集成方法^[4], 把过程神经网络技术、灰色系统理论与专家推理策略、改进免疫遗传算法有机结合, 实现了烧结配料优化, 最后对优化前后的配料方案进行了比较.

1 烧结过程机理分析

铅锌烧结原料经过一次和二次配料以后, 粉状混合料经过混料圆筒和制粒圆筒成为具有合适水分的混合料料球. 混合料料球通过梭式布料机分别送

收稿日期 2007-11-01 收修稿日期 2008-11-17
Received November 1, 2007; in revised form November 17, 2008
国家高技术研究发展计划 (863 计划) (2008AA04Z128), 国家杰出青年基金项目 (60425310) 资助
Supported by National High Technology Research and Development Program of China (863 Program) (2008AA04Z128) and National Science Fund for Distinguished Youth Scholars of China (60425310)
1. 中南大学信息科学与工程学院 长沙 410083
1. School of Information Science and Engineering, Central South University, Changsha 410083
DOI: 10.3724/SP.J.1004.2009.00605

入点火仓和主料仓。点火后的混合料跟随台车一起移动, 经过干燥、加热、反应和烧结四个阶段, 成为具有一定结构的烧结块料, 并在烧结机尾产出。烧结块料经过两级破碎, 规格合适的成为烧结块进入熔炼工艺流程; 不合适的再经过两级破碎成为返粉, 重新进入二次配料流程。

烧结过程是一个复杂的物理化学反应过程。由于从配料到烧结完成得到烧结块要长达 2 个多小时的时间, 这样长的时间使得检测到的烧结块成分数据失去了实时指导生产配料的意义。因此, 需要建立有效的烧结块成分预测模型。同时, 由于配料的准确性是决定烧结块质量的最重要因素, 并影响到生产的成本, 因此需要对烧结配比进行综合优化。

铅锌烧结块成分的预测可以看成是时间序列预测问题, 同时, 烧结块成分的预测还具有灰色性, 主要表现在: 影响烧结块成分的因素是灰色的, 且影响烧结块成分的某些关系是灰关系。影响烧结块成分的因素较多, 如原料的性能、配料的配比、点火温度、台车速度、风机风量、料层透气性、烧结终点位置等, 很难确定影响烧结块成分的所有因素, 有许多因素不完全明确, 有些已经明确的又难以进行量化描述。同时, 影响烧结块成分的各个因素之间存在着耦合关系, 这种耦合关系难以精确描述。

基于上述分析, 本文利用基于数据的统计建模方法, 分别采用过程神经网络和灰色系统理论建立成分预测模型, 对烧结块成分进行预测。为提高预测精度, 利用智能集成思想^[5-6], 将两个单一模型进行集成, 进而得到烧结块成分集成预测模型。

2 烧结块成分集成预测模型

2.1 过程神经网络预测模型

过程神经网络在结构上与传统的人工神经网络^[7]类似, 不同之处在于过程神经网络的输入和相应的连接权是时变函数。应用传统时间序列预测方法对烧结块成分进行预测, 实质上就是根据时间序列 $\{x_k\}$ 的烧结块成分含量历史实际检测数据 x_k, x_{k-1}, \dots 对未来 $k+1$ 时刻的成分含量 x_{k+1} 进行估计, 即认为 x_{k+1} 与其之前的数据 x_k, x_{k-1}, \dots 之间存在着某种函数映射关系, 可描述为

$$x_{k+1} = G(x_k, x_{k-1}, \dots) \quad (1)$$

这样, 烧结块成分时间序列预测问题就转换为对函数 $G(\cdot)$ 的逼近问题。显然, 采用传统的人工神经网络对未来 $k+1$ 时刻的烧结块成分含量 x_{k+1} 进行预测时, x_{k-1}, x_{k-2}, \dots 对 x_k 的影响难以表达, 即难以表达时间序列中实际存在的时间累积效应, 这势

必影响到模型的预测精度。

若将烧结块成分含量数据进行函数拟合, 产生一个时变函数 $x_k(t)$, 就可以认为时间序列在 $k+1$ 时刻的取值 x_{k+1} 与函数 $x_k(t)$ 之间存在某种泛函映射关系, 可描述为

$$x_{k+1} = F(x_k(t)) \quad (2)$$

此时, 烧结块成分含量时间序列预测问题就转化为对泛函 $F(\cdot)$ 的逼近问题。现有文献已经证明过程神经网络是任意连续泛函的一致逼近器^[8], 因此, 将 $x_k(t)$ 作为网络的输入, 就可以将烧结块成分含量时间序列预测问题转化为对泛函 $F(\cdot)$ 的逼近问题。

本文提出的基于过程神经网络的铅锌烧结块成分时间序列预测模型是一种 3 层前向过程神经网络, 其拓扑结构为 1-10-1。令 $x(t) = x_k(t)$, 则基于过程神经网络的铅锌烧结块成分时间序列预测模型对未来 $k+1$ 时刻的成分含量的预测为

$$\hat{x} = \sum_{i=1}^{10} v_i f \left(\int_0^T w_i(t) x(t) dt - \theta_i \right) - \theta \quad (3)$$

其中, $x(t)$ 是过程神经元的输入函数; $[0, T]$ 是样本采样区间; $w_i(t)$ 为相应的连接权函数; v_i 为隐层节点到输出节点的连接权值; θ 为过程神经元阈值; $f(\cdot)$ 为激励函数。

根据 Weierstrass 逼近定理并通过 Gram-Schmidt 正交化步骤, 可以得到在 $C[0, T]$ 空间上的一组标准正交基函数 $b_n(t)$, 则 $x(t), w_i(t)$ 可分别表示为

$$x(t) = \sum_{j=1}^J a_j b_j(t), \quad w_i(t) = \sum_{j=1}^J w_{ij} b_j(t) \quad (4)$$

其中 $a_j, w_{ij} \in \mathbf{R}$ 为展开式系数。

根据正交函数的性质, 式 (3) 可简化为

$$\hat{x} = \sum_{i=1}^{10} v_i f \left(\sum_{j=1}^J w_{ij} a_j - \theta_i \right) - \theta \quad (5)$$

给定 L 组学习样本 $\{x_l(t), d_l\}$ ($l = 1, 2, \dots, L$), d_l 为对应于样本 $x_l(t)$ 的网络期望输出。设 \hat{x}_l 为相应的网络实际输出, 则网络模型的误差函数可定义为

$$E = \frac{1}{2} \sum_{l=1}^L (\hat{x}_l - d_l)^2 = \frac{1}{2} \sum_{l=1}^L \left(\sum_{i=1}^{10} v_i f \left(\sum_{j=1}^J w_{ij} a_{jl} - \theta_i \right) - \theta - d_l \right)^2 \quad (6)$$

记 $X_{il} = \sum_{j=1}^J w_{ij} a_{jl} - \theta_i$. 根据最速梯度下降算法, 网络模型的待训练参数调整规则为

$$\begin{cases} v_i(s+1) = v_i(s) + \alpha \Delta v_i(s) \\ w_{ij}(s+1) = w_{ij}(s) + \beta \Delta w_{ij}(s) \\ \theta_i(s+1) = \theta_i(s) + \gamma \Delta \theta_i(s) \\ \theta(s+1) = \theta(s) + \delta \Delta \theta(s) \end{cases} \quad (7)$$

其中, α, β, γ 和 δ 为学习速率; s 为学习迭代次数.

在每一次的学习迭代中, $\Delta v_i, \Delta w_{ij}, \Delta \theta_i$ 和 $\Delta \theta$ 可分别表示为

$$\begin{cases} \Delta v_i = -\frac{\partial E}{\partial v_i} = -\sum_{l=1}^L (\hat{x}_l - d_l) f(X_{il}) \\ \Delta w_{ij} = -\frac{\partial E}{\partial w_{ij}} = -\sum_{l=1}^L (\hat{x}_l - d_l) v_i f'(X_{il}) a_{jl} \\ \Delta \theta_i = -\frac{\partial E}{\partial \theta_i} = \sum_{l=1}^L (\hat{x}_l - d_l) v_i f'(X_{il}) \\ \Delta \theta = -\frac{\partial E}{\partial \theta} = \sum_{l=1}^L (\hat{x}_l - d_l) \end{cases} \quad (8)$$

具体的学习过程描述如下:

步骤 1. 采用 Legendre 正交基函数将过程神经网络模型的输入函数和连接权函数表示为基函数的展开形式;

步骤 2. 给定学习迭代次数 $s = 0$, 学习误差精度 ϵ , 学习速率: $\alpha, \beta, \gamma, \delta$ 和最大学习迭代次数 I ;

步骤 3. 初始化权值和阈值;

步骤 4. 根据式 (5) 计算误差函数 E , 若 $E < \epsilon$ 或 $s > I$, 则转步骤 6, 否则转步骤 5;

步骤 5. 按式 (6) 和式 (7) 的规则调整权值和阈值, $s + 1 \rightarrow s$, 并转步骤 4;

步骤 6. 输出学习结果, 结束.

2.2 改进灰色系统预测模型

已知烧结块成分铅锌含量的原始数据序列为 $X^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\}$, 考虑到运用灰色模型预测时, 如果原始数据有较大波动, 容易造成预测结果不准确^[9-10], 误差较大, 为减弱突变值的影响, 均衡原始数列的趋势, 尽量使原始数列趋势与指数的递增规律保持一致, 进而提高预测的精度, 本文采用均值平滑法, 引入均值生成算子 $x^*(k) = 0.5x(k) + 0.5x(k-1)$ 对烧结块成分原始数据进行平滑处理, 得到平滑后的序列 $X^{(0)*}$, 然后对其进行一阶累加生成序列 $X^{(1)}$.

$$X^{(1)} = \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)\} \quad (9)$$

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)*}(i) \quad (10)$$

建立白化微分方程

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b \quad (11)$$

式中 a 为模型的发展系数, 反映铅锌含量原始数据序列 $X^{(0)}$ 和一阶累加生成序列 $X^{(1)}$ 的发展趋势, b 为模型的协调系数, 反映数据之间的变化关系.

记 $A = [a, b]^T$, 用最小二乘法按下式确定参数:

$$A = (B^T B)^{-1} B^T Y_N \quad (12)$$

式中

$$B = \begin{bmatrix} -0.5(x^{(1)}(1) + x^{(1)}(2)) & 1 \\ -0.5(x^{(1)}(2) + x^{(1)}(3)) & 1 \\ -0.5(x^{(1)}(3) + x^{(1)}(4)) & 1 \\ \vdots & \vdots \\ -0.5(x^{(1)}(n-1) + x^{(1)}(n)) & 1 \end{bmatrix}$$

$$Y_N = [x^{(0)}(2) \quad x^{(0)}(3) \quad x^{(0)}(4) \quad \dots \quad x^{(0)}(n)]^T$$

将求得的 a 和 b 代入式 (9), 通过求解微分方程得

$$x^{(1)}(k+1) = \left[x^{(0)}(1) - \frac{b}{a} \right] e^{-ak} + \frac{b}{a}, \quad k = 0, 1, \dots \quad (13)$$

对上式做累减生成还原, 得到烧结块成分铅锌含量原始数列 $X^{(0)}$ 灰色预测模型为

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 1, 2, \dots \quad (14)$$

2.3 基于信息熵的集成预测模型

设 x_t 为烧结块成分的实际值, m 为单一预测模型的个数 (本文中 $m = 2$), \hat{x}_{it} 为第 i 个单一预测模型在时刻 t 的预测值, 则集成预测模型的预测值为

$$\hat{x}_t = \sum_{i=1}^m w_i \hat{x}_{it}, \quad i = 1, \dots, m \quad (15)$$

其中 w_i 为第 i 个单一预测模型的加权系数, 满足

$$\sum_{i=1}^m w_i = 1, \quad w_i \geq 0, \quad i = 1, \dots, m \quad (16)$$

第 i 个预测模型在时刻 t 的预测相对误差为

$$e_{it} = \begin{cases} \left| \frac{x_t - \hat{x}_{it}}{x_t} \right|, & \text{若 } 0 \leq \left| \frac{x_t - \hat{x}_{it}}{x_t} \right| < 1 \\ 1, & \text{若 } \left| \frac{x_t - \hat{x}_{it}}{x_t} \right| \geq 1 \end{cases} \quad (17)$$

本文利用信息熵^[11-12]的概念,重新定义单一预测模型预测误差序列的变异程度.利用熵值法确定加权系数,其步骤如下:

步骤 1. 计算第 i 个预测模型在时刻 t 的预测相对误差的比重 p_{it} :

$$p_{it} = \frac{e_{it}}{\sum_{t=1}^n e_{it}}, \quad t = 1, \dots, n \quad (18)$$

步骤 2. 计算第 i 个单一预测模型的预测相对误差的熵值 E_i :

$$E_i = -k \sum_{t=1}^n p_{it} \ln p_{it} \quad (19)$$

其中 $k > 0$, 本文取 $k = 1/\ln n$.

步骤 3. 计算第 i 个单一预测模型预测相对误差序列的变异程度系数 d_i . 因为 $0 \leq E_i \leq 1$, 根据预测相对误差的熵值大小与其变异程度相反的原则, 第 i 个单一模型预测相对误差序列的变异程度系数 d_i 为

$$d_i = 1 - E_i, \quad i = 1, \dots, m \quad (20)$$

步骤 4. 计算第 i 个单一预测模型的加权系数 w_i :

$$w_i = \frac{1}{m-1} \left(1 - \frac{d_i}{\sum_{i=1}^m d_i} \right) \quad (21)$$

步骤 5. 计算集成预测模型的预测值 \hat{x}_t :

$$\hat{x}_t = \sum_{i=1}^m w_i \hat{x}_{it}, \quad t = 1, \dots, n \quad (22)$$

3 烧结配料综合优化方法

3.1 配料优化模型的建立

配料过程分两步进行, 其中一次配料将采购来的各种铅锌矿粉按一定比例配成混合精矿, 用于配混合料的 Pb、Zn 和 SiO₂ 含量. 为使配成的混合

料经烧结后产生的烧结块成分满足熔炼生产的要求, 且整个配料过程的原料成本最小, 得到如下式所示的以成本最小为优化目标、以烧结块成分指标为约束的配料优化模型.

$$\begin{aligned} \min f(x) &= \min \sum_{q=1}^Q C_q x_q \quad (23) \\ \text{s.t.} & \begin{cases} [\text{Pb}]_{C \min}^g \leq [\text{Pb}]_C = \sum_{q=1}^Q x_q [\text{Pb}]_q \leq [\text{Pb}]_{C \max}^g \\ [\text{Zn}]_{C \min}^g \leq [\text{Zn}]_C = \sum_{q=1}^Q x_q [\text{Zn}]_q \leq [\text{Zn}]_{C \max}^g \\ [\text{S}]_{C \min}^g \leq [\text{S}]_C = \sum_{q=1}^Q x_q [\text{S}]_q \leq [\text{S}]_{C \max}^g \\ [\text{CaO}]_{C \min}^g \leq [\text{CaO}]_C = \sum_{q=1}^Q x_q [\text{CaO}]_q \leq \\ \quad [\text{CaO}]_{C \max}^g \\ \frac{1}{1.7} [\text{CaO}]_C \leq [\text{SiO}_2]_C = \sum_{q=1}^Q x_q [\text{SiO}_2]_q \leq \\ \quad \frac{1}{1.4} [\text{CaO}]_C \\ [\text{Fe}]_C = \sum_{q=1}^Q x_q [\text{Fe}_2]_q \geq 2 [\text{SiO}_2]_C \end{cases} \quad (24) \end{aligned}$$

其中, C_q 为第 q 种矿粉的成本价格, x_q 为第 q 种矿粉的一配配比, $[A]_{C \max}^g$ 和 $[A]_{C \min}^g$ 为混合精矿成分指标的上限和下限, A 分别代表混合精矿中的 Pb、Zn、S 和 CaO.

混合精矿成分指标由烧结块成分指标确定, 以铅成分为例, 混合精矿与烧结块成分间关系为

$$[\text{Pb}]_M = \mu [\text{Pb}]_C + (1 - \mu) [\text{Pb}]_R \quad (25)$$

$$[\text{Pb}]_S = f_{PNN+IGS}(X) \quad (26)$$

式 (25) 反映一配混合精矿成分与二配烧结混合料成分之间的关系, 其中, $\mu (\in [0, 1])$ 是二次配料中混合精矿的配比. 函数 $f_{PNN+IGS}(X)$ 表示烧结块成分预测集成模型. 下标 M 表示二配烧结混合料, 下标 C 表示一配混合精矿, 下标 R 表示返粉.

3.2 定性定量综合集成优化方法

针对上述配料优化问题, 本文采用定性定量综合集成优化方法. 首先利用专家推理优化策略对含有成分预测模型的配料优化问题进行粗优化, 所得结果 x_q 作为问题的初始次优解, 然后把 x_q 作为改进免疫遗传算法初始种群中的一个个体, 并从中抽

取疫苗进行二次细优化, 求取问题的最优解. 具体步骤如下:

步骤 1. 获取混合精矿的成分指标 $[A]_{C \max}^g$ 和 $[A]_{C \min}^g$. 混合精矿的成分指标是根据烧结块成分指标要求由专家推理进行反推得到. 以混合精矿成分指标为例, 设 $[Pb]_{M \max}^g$ 和 $[Pb]_{M \min}^g$ 为专家系统基于式 (26) 的烧结块成分模型采用诸如 $R_1 \sim R_4$ 的一类规则推出的混合料 Pb 成分指标.

R_1 : 若 $[Pb]_S > [Pb]_{S \max}^g$ 且 $[S]_M$ 较大, 则减少 $[Pb]_M$.

R_2 : 若 $[Pb]_S < [Pb]_{S \min}^g$ 且 $[S]_M$ 较大, 则增加 $[Pb]_M$, 减少 $[S]_M$.

R_3 : 若 $[Zn]_S > [Zn]_{S \min}^g$ 且 $[S]_M$ 较小, 则减少 $[Zn]_M$, 增加 $[S]_M$.

R_4 : 若 $[Zn]_S < [Zn]_{S \min}^g$ 且 $[S]_M$ 较大, 则增加 $[Zn]_M$, 减少 $[S]_M$.

由式 (25) 有

$$[Pb]_C = \frac{[Pb]_M - (1 - \mu)[Pb]_R}{\mu} \quad (27)$$

根据初始设定的二配优化区间 $[\mu_{\min}, \mu_{\max}]$, 则

$$[Pb]_{C \max}^g = \max \left\{ \frac{[Pb]_{M \max}^g - (1 - \mu_{\max})[Pb]_R}{\mu_{\max}}, \frac{[Pb]_{M \max}^g - (1 - \mu_{\min})[Pb]_R}{\mu_{\min}} \right\} \quad (28)$$

$$[Pb]_{C \min}^g = \min \left\{ \frac{[Pb]_{M \min}^g - (1 - \mu_{\max})[Pb]_R}{\mu_{\max}}, \frac{[Pb]_{M \min}^g - (1 - \mu_{\min})[Pb]_R}{\mu_{\min}} \right\} \quad (29)$$

步骤 2. 从知识库中选择一组适当的 x_q 值作为其初始值.

步骤 3. 基于选择的 x_q , 计算混合精矿成分 $[A]_C$:

$$[A]_C = \sum_{q=1}^Q x_q [A]_q \quad (30)$$

步骤 4. 检查 $[A]_C$ 是否满足式 (28) 和 (29) 得到的混合精矿成分指标, 如果满足则转步骤 5, 否则使用诸如 $R_5 \sim R_8$ 的一类规则进行调整.

R_5 : 若 $[Pb]_C > [Pb]_{C \max}^g$ 且 $[Pb]_q > [Pb]_{C \max}^g$, 则减少 x_q .

R_6 : 若 $[Zn]_C < [Zn]_{C \max}^g$ 且 $[Zn]_q > [Zn]_{C \max}^g$, 则减少 x_q .

R_7 : 若 $[S]_C < [S]_{C \max}^g$ 且 $[S]_q < [S]_{C \min}^g$, 则增加 x_q .

R_8 : 若 $[Fe]_C < 3.5[SiO_2]_C$ 且 $[Fe]_C < 2.0[SiO_2]_C$, 则减少 x_q .

以上述规则 R_5 中的情况为例, 当 $[Pb]_C > [Pb]_{C \max}^g$ 且 $[Pb]_q > [Pb]_{C \max}^g$ 时, x_q 按照下式进行调整:

$$x_q = x_q + \delta([Pb]_{C \max}^g - [Pb]_C) \frac{\partial f(x)}{\partial x_q} \quad (31)$$

然后返回步骤 3. 其中 δ 是一个经验系数, 它决定迭代的速度.

步骤 5. 检查获得的 x_q 是否在经验范围内, 如果是则把获得的 x_q 作为初始次优解; 否则从知识库中选择 x_q 的其他经验值作为 x_q 的初始值, 然后返回步骤 3.

步骤 6. 将烧结配料优化目标函数和约束条件作为抗原. 调用上述步骤获得的初始次优解 x_q 作为抗体, 并从中抽取疫苗.

步骤 7. 计算适值, 并判断算法收敛准则是否满足. 如满足, 则转步骤 11.

步骤 8. 若算法收敛准则不满足, 执行交叉和变异操作, 在进行交叉和变异操作时, 应用静态繁殖理论, 判断子代染色体的适值是否高于父代. 如果是, 则用子代替父代; 否则, 保留父代, 然后进行疫苗接种.

步骤 9. 进行疫苗更新, 判断新种群中最优解适值是否优于当前抗体. 若是, 则将当前最优解作为抗体抽取疫苗; 否则, 不更新疫苗.

步骤 10. 进行种群替代并转步骤 7.

步骤 11. 将当前种群和最优解分类存储到数据库中并输出结果.

上述算法的改进主要体现在:

1) 引入静态繁殖理论. 在进行交叉和变异操作后, 将生成的子代染色体适值和父代进行比较. 如果子代染色体适值高于父代, 则利用子代染色体取代父代染色体, 否则保留父代染色体, 这样可防止进化操作对优异个体性能的破坏, 进而有效防止最优解的丢失.

2) 疫苗的实时更新. 传统的免疫遗传算法中, 疫苗的提取是通过先验知识给出的, 而且固定不变, 因此很难保证疫苗在进化过程中的先进性^[13]. 本文所提算法中, 每进行一次迭代都要判断当前抗体中所提取疫苗的先进性, 如果出现了新的更优的抗体, 则利用最优抗体进行疫苗提取, 这样就保证了每次迭代过程中所用的疫苗都是最优的, 从而保证了疫苗的先进性.

对于免疫遗传算法^[14]而言, 其状态转移情况可以用“ A_k (交叉) B_k (变异) C_k (接种疫苗) D_k (疫

苗选择) A_{k+1} ”这样的随机过程来表示, 其中 A_k 到 D_k 的状态转移构成一个马尔可夫链. 本文所提改进免疫遗传算法并没有改变算法的迭代过程, 即没有改变算法的马尔可夫链. 由文献 [15] 中的相关定理可知, 本文所提改进免疫遗传算法可以保证以概率 1 收敛. 同时, 由于采用了静态繁殖理论, 从而在每次迭代后保留了最优解, 根据文献 [15] 中的相关定理, 本算法也以概率 1 收敛到全局最优解.

4 仿真结果分析

针对某冶炼厂烧结块铅锌含量实际生产历史数据, 考虑到生产过程中存在的干扰噪声, 本文采用均值滤波方法对烧结块成分数据进行预处理, 以剔除异常数据和尖峰脉冲. 在建立过程神经网络 (Process neural network, PNN) 预测模型和改进灰色系统 (Improved gray system, IGS) 预测模型并分别对烧结块的铅锌成分含量进行预测的基础上, 依照上述步骤分别计算得到铅锌成分含量集成预测模型中两个单一模型的加权系数. 这里以铅成分含量预测为例给出了两个单一模型预测相对误差 (Recursive prediction error, RPE)、相对误差比重 (Relative error of prediction, REP) 及 $\ln p_{it}$ 的曲线, 如图 1~3 所示.

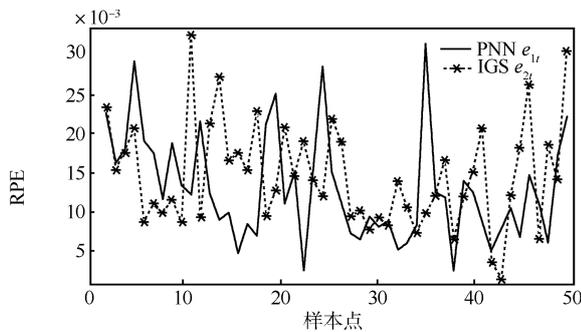


图 1 两个单一模型铅成分预测相对误差
Fig. 1 RPE of two single models for Pb component prediction

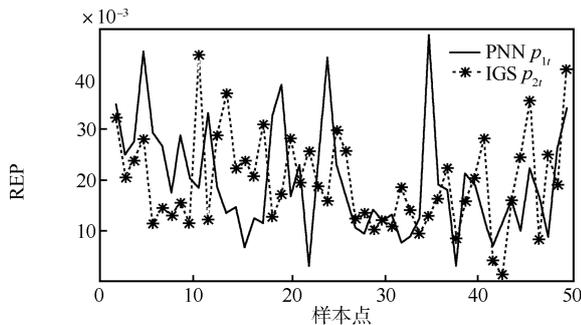


图 2 两个单一模型铅成分预测相对误差比重
Fig. 2 REP of two single models for Pb component prediction

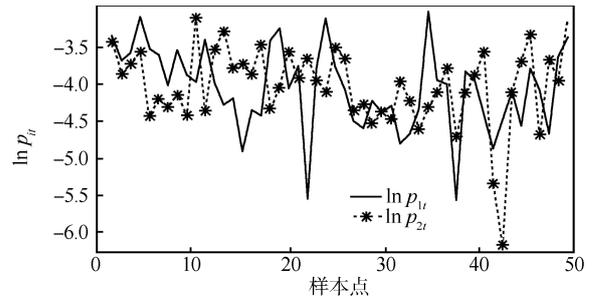


图 3 两个单一模型铅成分预测 $\ln p_{it}$
Fig. 3 $\ln p_{it}$ of two single models for Pb component prediction

根据第 2.3 节确定加权系数的步骤, 可以得到过程神经网络和改进灰色系统预测模型的加权系数分别为: $w_1 = 0.4401$, $w_2 = 0.5599$, 则铅成分含量预测的集成模型为: $\hat{x}_t = 0.4401\hat{x}_{1t} + 0.5599\hat{x}_{2t}$. 同理, 锌成分含量集成预测模型为: $\hat{x}_t = 0.4882\hat{x}_{1t} + 0.5118\hat{x}_{2t}$. 铅锌成分含量的预测结果如图 4 和图 5 所示.

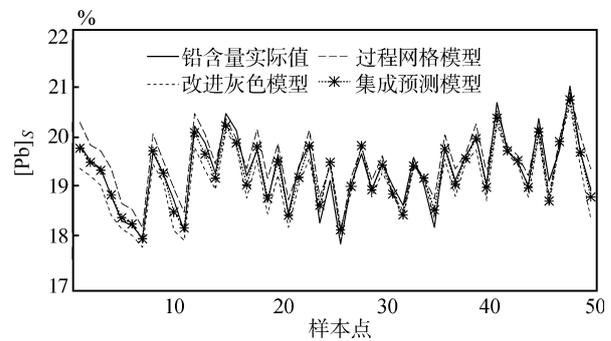


图 4 铅含量预测结果
Fig. 4 Results for Pb component prediction

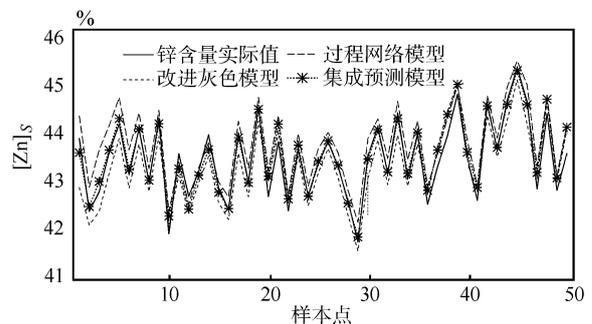


图 5 锌含量预测结果
Fig. 5 Results for Zn component prediction

按上述优化方法进行仿真实验, 其中表 1 为一组实验的原料情况, 表 2 为根据表 1 的原料情况得到的配料优化结果, 表 3 为二配配比区间以及返粉成分确定情况下混合精矿成分指标.

表 1 烧结原料成分 (%) 与价格 (元/t)

Table 1 Sintering material component (%) and price (yuan/t)

原料	Pb	Zn	S	CaO	SiO ₂	Fe	价格
K ₁	15.25	28.69	27.68	4.52	3.27	11.63	3 120
K ₂	15.03	35.86	28.80	3.64	3.89	11.45	3 640
K ₃	1.42	46.40	32.04	3.75	2.95	11.34	5 300
K ₄	18.98	33.46	27.78	0.53	4.83	11.53	3 500
K ₅	1.18	46.82	32.95	4.22	1.12	10.62	5 120
K ₆	58.69	3.63	22.95	2.63	1.37	8.37	2 120
K ₇	2.22	50.78	30.89	2.66	1.09	10.05	4 880
K ₈	55.66	5.79	19.62	1.66	1.47	8.11	1 700
K ₉	21.48	28.15	28.36	3.98	1.66	5.82	3 700
K ₁₀	68.12	5.99	16.89	0.83	0.96	2.98	2 510

表 2 配比优化成本结果比较

Table 2 Comparison of results of the blending optimization

	K ₂	K ₃	K ₅	K ₆	K ₇	K ₉	价格
人工配比	0.30	0.12	0.08	—	0.14	0.36	4178
优化配比	0.294	—	—	0.03	0.29	0.392	4003.04

表 3 混合矿成分指标要求及优化结果比较 (%)

Table 3 Requirement of the mixture component index and the optimization results comparison (%)

混合精矿指标	[Pb] _C	[Zn] _C	[S] _C	[CaO] _C	[SiO ₂] _C	[Fe] _C
指标上限	16	39.5	31	5.5	3.5	9
指标下限	13	35	29	3	2	7
人工配比	12.82	38.06	29.66	3.69	2.36	9.37
优化配比	15.12	36.20	29.06	3.40	2.15	8.76

从仿真结果看, 集成预测模型的预测精度高于单一预测模型; 按优化配比进行配料所得混合矿成分达标率高于人工配比的达标率, 提高了配料的准确率; 同时每次按优化配比进行配料所耗成本都小于人工配比, 降低了生产成本, 较好地解决了传统配料方法中存在的准确率低和成本高的问题。

5 结论

本文从智能集成建模和优化的角度出发, 针对铅锌烧结配料过程中存在的问题开展研究, 论文的主要工作和结论如下:

1) 在建立过程神经网络和改进灰色预测模型的基础上, 通过引入信息熵的概念, 提出了一种铅锌烧

结块成分智能集成预测模型。仿真结果表明集成预测模型的预测精度高于单一预测模型, 验证了所提建模方法的有效性。

2) 在建立烧结配料优化模型的基础上, 提出了一种基于专家推理优化策略和改进免疫遗传算法的定性定量综合集成优化方法。

3) 仿真结果验证了所提方法的有效性。运用上述综合集成优化方法可以得到铅锌烧结配料的优化配比, 降低了烧结生产成本, 提高了配料的准确率, 较好地解决了传统烧结配料方法中存在的成本高、准确率低的问题, 为铅锌烧结生产企业配料提供了有效途径。

References

- Liang Zhong-Yu, Hu Lin, Deng Neng-Yun, Zhou Jiu-An, Yu Xing-Yuan, Tao Zheng-Chun. Analysis of sinter charge proportioning by linear optimization. *Iron and Steel*, 2001, **36**(10): 12-14
(梁中渝, 胡林, 邓能运, 周久安, 余兴元, 陶正春. 优化烧结矿配料分析. *钢铁*, 2001, **36**(10): 12-14)
- Wu Min, Wang Chun-Sheng, Cao Wei-Hua. Integrated synthesis methodology for optimization of sinter mix proportions based on predictive models and adjustment rules. *Journal of System Simulation*, 2008, **20**(9): 2423-2428
(吴敏, 王春生, 曹卫华. 基于预测模型与调整规则的烧结配料配料优化综合集成方法. *系统仿真学报*, 2008, **20**(9): 2423-2428)
- Wang Y L, Ma J, Gui W H, Yang C H, Zhang C F. Multi-objective intelligent coordinating optimization blending system based on qualitative and quantitative synthetic model. *Journal of Central South University of Technology (English Edition)*, 2006, **13**(5): 552-557
- Yu Jing-Yuan, Tu Yuan-Ji. Meta-synthesis-study of case. *System Engineering — Theory and Practice*, 2002, **22**(5): 1-8
(于景元, 涂元季. 从定性到定量综合集成方法 — 案例研究. *系统工程理论与实践*, 2002, **22**(5): 1-8)
- Wu Min, Xu Chen-Hua, Wang Chun-Sheng. Synthetical permeability state prediction based fuzzy coefficient-variable for Lead-Zinc sintering process. *Journal of East China University of Science and Technology (Natural Science Edition)*, 2006, **32**(7): 825-828
(吴敏, 徐辰华, 王春生. 基于模糊分类变系数的铅锌烧结过程综合透气性状态预测. *华东理工大学学报 (自然科学版)*, 2006, **32**(7): 825-828)
- Wan Yu-Cheng, He Ya-Qun, Sheng Zhao-Han. Generalized weighted functional proportional mean combing forecasting model of air material consumption. *Acta Automatica Sinica*, 2004, **30**(4): 619-623
(万玉成, 何亚群, 盛昭瀚. 航材消耗广义加权函数比例平均组合预测模型. *自动化学报*, 2004, **30**(4): 619-623)
- Chan W L, Fu M W, Lu J. An integrated FEM and ANN methodology for metal-formed product design. *Engineering Applications of Artificial Intelligence*, 2008, **21**(8): 1170-1181
- He Xin-Gui, Liang Jiu-Zhen. Some theoretical issues on process neural networks. *Engineering Science*, 2000, **2**(12): 40-44

(何新贵, 梁久帧. 过程神经网络的若干理论问题. 中国工程科学, 2000, **2**(12): 40–44)

- 9 Yao A W L, Chi S C, Chen J H. An improved grey-based approach for electricity demand forecasting. *Electric Power Systems Research*, 2003, **67**(3): 217–224
- 10 Lin Y H, Lee P C. Novel high-precision grey forecasting model. *Automation in Construction*, 2007, **16**(6): 771–777
- 11 Mohamed S. Estimating market shares in each market segment using the information entropy concept. *Applied Mathematics and Computation*, 2007, **190**(2): 1735–1739
- 12 Palpanas T, Koudas N, Mendelzon A. Using datacube aggregate for approximate querying and deviation detection. *IEEE Transactions on Knowledge and Data Engineering*, 2005, **17**(11): 1465–1477
- 13 McCall J. Genetic algorithms for modelling and optimization. *Journal Computational and Applied Mathematics*, 2005, **184**(1): 205–222
- 14 Balicki J. Multi-criterion evolutionary algorithm with model of the immune system to handle constraints for task assignments. In: Proceedings of the 7th International Conference on Artificial Intelligence and Soft Computing. Zakopane, Poland: Springer, 2004. 394–399
- 15 Jiao L C, Wang L. A novel genetic algorithm based on immunity. *IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Human*, 2000, **30**(5): 552–561



王春生 中南大学信息科学与工程学院副教授. 主要研究方向为过程控制和智能控制.

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

(**WANG Chun-Sheng** Associate professor at the School of Information Science and Engineering, Central

South University. 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. 主要研究方向为过程控制、鲁棒控制和智能系统. 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. His research interest covers process control, robust control, and intelligent system. Corresponding author of this paper.)



曹卫华 中南大学信息科学与工程学院副教授. 主要研究方向为多智能体系统、机器人技术和生产过程智能控制.

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

(**CAO Wei-Hua** Associate professor at the School of Information Science and Engineering, Central South University. His research interest covers multi-agent system, robot technology, and intelligent control for production process.)



何勇 中南大学信息科学与工程学院教授. 主要研究方向为时滞控制系统、鲁棒控制和过程控制.

E-mail: heyong08@yahoo.com.cn

(**HE Yong** Professor at the School of Information Science and Engineering, Central South University. His research interest covers time-delay systems, robust control, and process control.)