

5-15-2024

Prediction of Converter Gas Generation Based on Intermission Production Improved Elman

Jiajie Fei

College of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China, 04623746@qq.com

Dinghui Wu

College of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China, wdh123@jiangnan.edu.cn

Junyan Fan

College of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China

Jing Wang

Shanghai Baosight Software Co. Ltd, Shanghai 201203, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Prediction of Converter Gas Generation Based on Intermission Production Improved Elman

Abstract

Abstract: Aiming at large fluctuations of intermission and low prediction accuracy in iron and steel industry, based on the classification of intermission characteristics, a converter gas generation predicting model(CPSO-Elman) based on Elman neural network(ENN) optimized by chaotic PSO(CPSO) algorithm is proposed. The intermittent characteristics of converter gas generation time series are extracted and raw data is classified according to intermittent duration. The PSO algorithm improved by chaotic disturbance is introduced to optimize the initial weight and threshold of ENN and inertia weight of nonlinear updating is designed to balance global search ability and local search ability. Construct the combined prediction model of CPSO-Elman converter gas generation. Converter gas generation is predicted on the basis of predicting the intermission in the future time. Simulation results show that prediction accuracy of the proposed method is about 5% higher than that of the method without optimization.

Keywords

converter gas, generation prediction, PSO algorithm, chaotic perturbation, Elman neural network, intermission classification

Recommended Citation

Fei Jiajie, Wu Dinghui, Fan Junyan, et al. Prediction of Converter Gas Generation Based on Intermission Production Improved Elman[J]. Journal of System Simulation, 2024, 36(5): 1179-1188.

基于生产间歇改进 Elman 的转炉煤气发生量预测

费佳杰¹, 吴定会^{1*}, 范俊岩¹, 汪晶²

(1. 江南大学 物联网工程学院, 江苏 无锡 214122; 2. 上海宝信软件股份有限公司, 上海 201203)

摘要: 针对钢铁企业转炉煤气发生量间歇时长波动大, 预测精度低的问题, 基于生产间歇特征分类, 提出基于混沌映射粒子群算法 (CPSO) 优化 Elman 神经网络的转炉煤气发生量预测模型 (CPSO-Elman)。提取转炉煤气发生量时间序列中生产间歇特征, 并根据间歇时长进行分类; 引入混沌扰动改进的 PSO 算法优化 ENN 的初始权值和阈值, 利用非线性更新的惯性权重以平衡全局搜索与局部搜索能力, 并在粒子初始化中添加了混沌映射; 构建 CPSO-Elman 转炉煤气发生量组合预测模型; 在预测未来时间内间歇时长基础上, 预测转炉煤气发生量。仿真结果表明: 所提方法在预测精度上比未经过优化而预测的方法提高了 5% 左右。

关键词: 转炉煤气; 发生量预测; PSO 算法; 混沌扰动; Elman 神经网络; 间歇分类

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2024)05-1179-10

DOI: 10.16182/j.issn1004731x.joss.23-0022

引用格式: 费佳杰, 吴定会, 范俊岩, 等. 基于生产间歇改进 Elman 的转炉煤气发生量预测[J]. 系统仿真学报, 2024, 36(5): 1179-1188.

Reference format: Fei Jiajie, Wu Dinghui, Fan Junyan, et al. Prediction of Converter Gas Generation Based on Intermission Production Improved Elman[J]. Journal of System Simulation, 2024, 36(5): 1179-1188.

Prediction of Converter Gas Generation Based on Intermission Production Improved Elman

Fei Jiajie¹, Wu Dinghui^{1*}, Fan Junyan¹, Wang Jing²

(1. College of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China;

2. Shanghai Baosight Software Co. Ltd, Shanghai 201203, China)

Abstract: Aiming at large fluctuations of intermission and low prediction accuracy in iron and steel industry, based on the classification of intermission characteristics, a converter gas generation predicting model (CPSO-Elman) based on Elman neural network (ENN) optimized by chaotic PSO (CPSO) algorithm is proposed. The intermittent characteristics of converter gas generation time series are extracted and raw data is classified according to intermittent duration. The PSO algorithm improved by chaotic disturbance is introduced to optimize the initial weight and threshold of ENN and inertia weight of nonlinear updating is designed to balance global search ability and local search ability. Construct the combined prediction model of CPSO-Elman converter gas generation. Converter gas generation is predicted on the basis of predicting the intermission in the future time. Simulation results show that prediction accuracy of the proposed method is about 5% higher than that of the method without optimization.

Keywords: converter gas; generation prediction; PSO algorithm; chaotic perturbation; Elman neural network; intermission classification

收稿日期: 2023-01-06 修回日期: 2023-02-13

基金项目: 国家重点研发计划(2020YFB1711102)

第一作者: 费佳杰(1999-), 男, 硕士生, 研究方向为能源预测。E-mail: 404623746@qq.com

通讯作者: 吴定会(1970-), 男, 教授, 博士, 研究方向为能源控制与优化。E-mail: wdh123@jiangnan.edu.cn

0 引言

钢铁企业炼钢产生的转炉煤气(linz-donanz converter gas, LDG)是转炉炼钢的副产品,其利用率较高,可用作其他生产过程的燃料。然而,该二次能源经常出现供需不平衡的问题,影响企业生产成本和能源消耗水平。钢铁生产过程中节能降耗任务是重中之重^[1-3],因此,建立有效的LDG发生量预测模型,为分析煤气供需状况提供依据,对高效利用LDG和减少其放散都具有重要意义^[4]。

针对钢铁企业气体二次能源的预测问题,最常用的研究方法是基于数据驱动进行预测^[5],如基于深度学习的方法和基于支持向量机预测的方法。基于深度学习的方法中,BP(back propagation)作为一种经典的预测模型可以处理非线性问题。文献[6]中,基于BP神经网络和支持向量机相结合的副产煤气预测模型保证了预测精度,但BP神经网络有着样本依赖性的特点,易受到一些随机因素的影响,故难以选取典型实例数据作为训练数据。文献[7]提出了一种用于高炉煤气预测的改进回声状态网络(echo state network, ESN)和时滞灰色关联相结合的两阶段预测模型,首先使用ESN对高炉煤气的产生和消耗进行预测,然后使用时滞灰色关联确定与高炉煤气柜位关联较高的影响因素,构建煤气柜预测模型。文献[8]针对副产煤气产消不平衡情况,基于Elman神经网络(Elman neural network, ENN)与最小二乘支持向量机(least squares support vector machine, LSSVM)建立了混合预测模型,但ENN的初始权值和阈值是随机生成的,模型在训练过程中容易因为权值和阈值的选取不当而陷入局部最优,影响预测效果。基于支持向量机的预测方法中,文献[9]提出了一种基于支持向量机的LDG煤气柜在线预测方法,与传统方法不同的是,该方法实现了自适应估计模型参数以适应LDG系统的数据动态,并在参数优化阶段建立了一种多子群PSO算法优化参数,模型具有较高的计算效率与预测精度。文献[10]针对LDG系统多个煤气柜柜位,提出了一个多输出

LSSVM回归模型,在单输出拟合误差的基础上,考虑了多个输出的组合拟合误差,并提出基于PSO算法的参数优化方法,预测精度较高。

上述预测方法难以有效解决LDG时序中生产间歇的波动对预测精度造成的影响,为避免此问题,本文提出了一种两步式分类预测组合模型。启发式算法可以提高解的质量并提高求解的效率,为减少权值与阈值随机初始化对模型训练带来的不足,本文使用改进的PSO算法对权值矩阵和阈值矩阵进行优化,引入改进的混沌映射对粒子种群进行优化,引入逻辑自映射函数产生混沌序列对PSO算法的惯性权重进行改进,以提高其全局搜索与局部搜索的能力。提取LDG时序数据中生产间歇特征,根据间歇长短和其频数将间歇划分为短间歇、中间歇和长间歇等3类。根据分类后的历史数据建立ENN预测模型,并使用改进的PSO算法(CPSO)对ENN的初始权值和阈值进行优化。根据提取的生产间歇时长建立间歇预测模型,用于预测未来生产周期内LDG时序数据中生产间歇时长;根据间歇时长的预测结果选取对应每一炼钢周期生产间歇特征的预测模型进行预测,避免了当炼钢节奏发生改变时对预测精度造成的不利影响。以某钢铁企业转炉炼钢的实际生产数据进行仿真实验,验证了该模型预测LDG发生量的有效性。

1 转炉煤气发生量特征分析

转炉炼钢过程中产生的转炉煤气回收具有间歇性波动的特征,对于其发生量的预测增加了许多随机性扰动。转炉煤气回收量受较多因素的影响,每个炼钢周期中煤气回收的时间点和间歇时长不相同,导致相邻回收曲线之间的间歇时间波动较大,但对于产气值而言,为了获得质量稳定的产品,每一炉钢的转炉煤气发生量变化大致相同。LDG回收量曲线如图1所示。

图1中选取300 min转炉煤气发生量的典型时序数据进行分析,200 min之前,炼钢生产间歇稳

定, 相邻生产间歇时长相近, 都保持在 30~35 min 这个区间内, 易预测且准确率高; 从 200~300 min, 生产间歇从 33 min 延长至 52 min, 再缩短至 23 min, 炼钢生产间歇变化大。生产间歇的随机性波动, 导致预测模型难以根据历史数据提前预知, 其预测精度将随着波动的产生而降低。




图 1 转炉煤气发生量回收图
Fig. 1 Converter gas generation diagram

针对上述问题, 本文提出一种数据特征匹配的方法, 用于提取 LDG 时序中的生产间歇特征。使用小波变换提取 LDG 时序的生产间歇。连续情况下的小波序列为

$$\varphi_{a,b}(t) = |a|^{-1/2} \varphi\left(\frac{t-b}{a}\right) \quad (1)$$

式中: a 为尺度因子; b 为时移因子。 $a, b \in R$, 且 $a \neq 0$ 。

设转炉煤气发生量为初始信号, 记为 $s(t)$, 连续小波变换定义为

$$W_s(a,b) = |a|^{-1/2} \int s(t) \varphi\left(\frac{t-b}{a}\right) dt = \langle s(t), \varphi_{a,b}(t) \rangle \quad (2)$$

对于离散的情况, 小波序列为

$$\varphi_{a,\beta}(t) = a_0^{-a/2} \int s(t) \varphi(a_0^{-a} t - \beta b_0) \cdot dt, a, \beta, \in Z \quad (3)$$

通常取 $a_0 = 2, b_0 = 1$, 代入式(3)为

$$\varphi_{a,\beta}(t) = 2^{-a/2} \int s(t) \varphi(2^{-a} t - \beta) \cdot dt, a, \beta, \in Z \quad (4)$$

式中: a, β 用于指定尺度因子; a 为时移因子; b 取值的整数; Z 为整数集。

使用小波变换提取生产间歇的过程是将母函数与 LDG 信号的初始段进行比较, 改变时移因子

与尺度因子, 从而适应 LDG 信号中生产间歇并提取。生产间歇频数分布情况如图 2 所示。




图 2 产气间歇持续时长分布图
Fig. 2 Gas generation intermittent duration distribution diagram

图 2 中纵坐标代表某间歇时长在 LDG 历史数据中分布次数, 最短间歇为 20 min; 间歇时长为 25~45 min 的生产间歇次数最多, 该间歇时长也是转炉正常生产时每炉钢之间的间歇时长范围。由于现场生产节奏的变更, 间歇时长可能在 45~100 min 范围内。由此可见, 生产间歇的波动具有随机性。

针对从历史 LDG 时序中提取的间歇特征, 根据生产间歇持续时长进行分类。如表 1 所示, 基于间歇持续时间的分类确定了短间歇、中间歇和长间歇 3 个类别。

表 1 基于持续时长的间歇分类
Table 1 Intermittent classification based on duration

间歇类别	个数	占比/%	持续时间/min
短间歇	6	0.4	<25
中间歇	971	69.9	25~45
长间歇	413	29.7	>45
总间歇	1 390	100	20~100

2 基于 CPSO-Elman 预测模型

针对 LDG 发生量这类间歇性波动数据, 为了避免间歇的随机性波动对预测的干扰, 本文提出在预测前提取原始序列中的生产间歇时长特征, 并根据间歇时长类别分离出不同类别的数据, 用于训练不同的预测模型, 加强模型对包含特定生

产间歇数据的特有性。ENN是预测模型的核心，其初始权值阈值是由随机初始化获得，容易在训练中陷入局部最优。针对上述问题，本文引入CPSO算法优化上述参数。

2.1 Elman神经网络

ENN属于反馈式神经网络，相比于前馈神经网络，ENN在隐含层中增加了一个承接层作为延迟算子^[11]。在训练网络时，承接层可以将上一时刻数据保留至下一时刻，记忆历史数据特征，使得网络保留更完整的数据信息^[12]。

转炉煤气系统影响因素众多，采用经过重构的LDG发生量历史数据作为模型输入，将原始时序转炉煤气时序 $s(t)$ 中 T 个训练样本变为如下形式作为预测模型的输入：

$$s(t) = \begin{bmatrix} s(1) & s(1+\tau) & \cdots & s[1+(\sigma-1)\tau] \\ s(2) & s(2+\tau) & \cdots & s[2+(\sigma-1)\tau] \\ \vdots & \vdots & & \vdots \\ s(\sigma+\tau) & s(\sigma+2\tau) & \cdots & s(T) \end{bmatrix} \quad (5)$$

ENN结构如图3所示，将LDG原始时序 $s(t)$

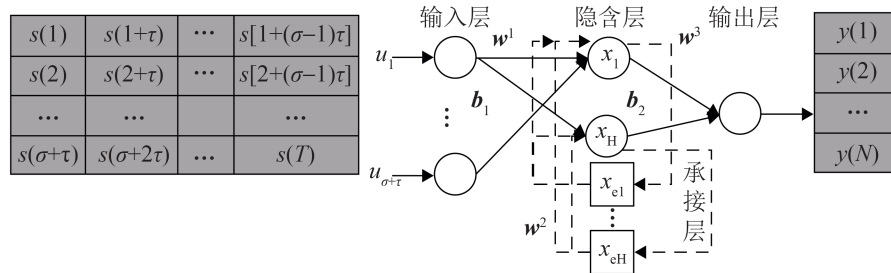


图3 Elman神经网络结构图

Fig. 3 Elman neural network structure diagram

2.2 CPSO算法

PSO算法是一种基于种群搜索的优化算法^[13]。本文用于优化ENN的初始权值矩阵 w^1 、 w^2 、 w^3 和初始阈值矩阵 b_1 、 b_2 。其优化流程为将ENN的初始权值矩阵 w^1 、 w^2 、 w^3 和初始阈值矩阵 b_1 、 b_2 作为算法寻优目标。每一组初始权值与阈值由PSO算法种群中的粒子个体表示，通过计算个体适应

变换为 $t-(\sigma+\tau)+1$ 个数据序列，每一列数据长度为 $(\sigma+\tau)\min$ 。输入层接收发生量时序数据后，将数据传送至隐含层，承接层将上一时刻隐含层数据 $x(t-1)$ 存储，记为 $x_c(t)$ 。通过对承接层记忆的上一时刻发生量数据和输入层的发生量数据按各自对应权值进行相加，并加入阈值矩阵 b_1 ，得到Elman神经网络的隐含层输出向量 $x(t)$ ，具体的非线性空间计算式为

$$x_c(t) = x(t-1) \quad (6)$$

$$x(t) = f(w^1 x_c(t) + w^2 (u(t-1)) + b_1) \quad (7)$$

最后将隐含层输出向量加权并加上阈值矩阵 b_2 ，得到Elman神经网络的输出为

$$y(t) = g(w^3 x(t) + b_2) \quad (8)$$

式中： w^1 、 w^2 、 w^3 分别是输入层到隐含层、隐含层到承接层、隐含层到输出层的权值矩阵； $g(\cdot)$ 和 $f(\cdot)$ 分别为输入层和隐含层使用的传递函数。

ENN根据随机初始化生成的权值矩阵与阈值矩阵进行模型训练，初始化所得权值与阈值的优劣影响着模型的训练效果。因此，初始权值与阈值的选择对预测精度有较大影响。

度函数进行迭代，更新个体最优值和全局最优值，最终将算法结束时的最优解赋值给ENN作为初始权值和初始阈值。

选取算法求解的目标函数为ENN训练集的均方根预测误差：

$$f = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2} \quad (9)$$

式中： T 为训练集样本数目； y_t 为训练集的实际

值; \hat{y}_i 为训练集的预测值, 通过最小化适应度函数求得最优权值矩阵与阈值矩阵。

将 ENN 的权值矩阵和阈值矩阵从左至右, 头尾相接展开。CPSO 维数的计算公式为

$$D = N_i \cdot N_h + N_h \cdot N_o + N_h + N_o + N_h \cdot N_h \quad (10)$$

式中: N_i 、 N_h 和 N_o 分别为输入层、隐含层和承接层神经元个数。

假设在 D 维搜索空间中有 n 个粒子组成的种群 $X = (X_1, X_2, \dots, X_n)$ 运动, $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$ 为粒子 i 在 D 维搜索空间中的位置, 亦为潜在最优解。 $v_i = (v_{i1}, v_{i2}, \dots, v_{id})$ 表示第 i 个粒子的飞行速度, 粒子的速度与位置更新公式为^[14]

$$g_{id}^{k+1} = \omega g_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{gd}^k) \quad (11)$$

$$X_{id}^{k+1} = X_{id}^k + g_{id}^{k+1} \quad (12)$$

式中: k 为迭代次数; i 为粒子群的粒子个数, $i = 1, 2, \dots, n$; d 为搜索空间的维数, $d = 1, 2, \dots, D$; g_{id}^k 为粒子 i 迭代 k 次后的速度; X_{id}^k 为粒子 i 迭代 k 次后的位置; P_{id}^k 为粒子 i 迭代 k 次后的个体最优位置; P_{gd}^k 为粒子 i 迭代 k 次后的全局最优位置; c_1 和 c_2 为学习因子; r_1 和 r_2 为 $(0, 1)$ 内的随机数; ω 为惯性权重。

PSO 算法在初始化种群时粒子个体初始化分布需要满足 Elman 神经网络的训练特征。然而常规的初始化方式分布粒子不均匀, 所得初始值优劣影响着算法寻优的结果。为了使算法初期粒子种群在解空间中的分布更具有多样性, CPSO 算法采用混沌映射^[15]初始化种群, 改善初始种群分布不均匀带来的不足。首先, 引入改进的 Tent 混沌映射, 利用混沌变量的随机性在解空间中产生分布均匀粒子种群。然后, 将初始种群和反向种群合并得到改进种群, 提高预测模型的预测精度。

由于 Tent 混沌映射存在小周期和不稳定点, 最优解在非边缘区域时无法求解到, 为了避免出现此类问题, 引入随机变量 $\text{rand}(0, 1) \cdot \frac{1}{N_T}$ 改进 Tent 混沌映射。引入 rand 随机变量后的混沌映射表达式为

$$y_{i+1,d} = \begin{cases} 2y_{id} + \text{rand}(0, 1) \cdot \frac{1}{N_T}, & y_{id} < 0.5 \\ 2(1 - y_{id}) + \text{rand}(0, 1) \cdot \frac{1}{N_T}, & y_{id} \geq 0.5 \end{cases} \quad (13)$$

式中: N_T 为混沌序列中粒子个数; $\text{rand}(0, 1)$ 为 $[0, 1]$ 之间的随机数。

将混沌序列反向映射, 得到初始粒子种群个体的位置:

$$X_{id} = d_{\min} + (d_{\max} - d_{\min}) \cdot y_{id} \quad (14)$$

式中: X_{id} 为第 i 个种群个体的 d 维编码值; d_{\min} 和 d_{\max} 分别为 X_{id} 搜索的上下限。

反向粒子种群个体为

$$RX_{id} = d_{\min} + d_{\max} - X_{id} \quad (15)$$

将种群 X 和经过反向映射的种群 RX 合并后, 即得到改进的种群 $\{X \cup RX\}$ 。

惯性权重 ω 决定了当前粒子速度对下一代粒子速度的影响大小, 影响粒子不同时刻下在解空间中的搜寻能力。在求解过程中, 粒子在搜寻初期, 需要尽可能扩大搜索空间, 寻找更多的候选解, 因此惯性权重 ω 需要较大, 提高粒子的全局搜索能力。而到求解后期, 粒子开始在搜索确定下的小范围区域飞行, 此时需要减小粒子的飞行速度以提高在小范围内的搜索能力, 因此需要减少 ω 值。

针对 PSO 算法的惯性权重引入逻辑自映射函数, 利用其产生混沌序列对惯性权重进行扰动改进, 经过非线性更新后的惯性权重为

$$\omega^* = \omega_{\max} \cdot |y^k| - \frac{\omega_{\max} - \omega_{\min}}{k_{\max}} \cdot k \quad (16)$$

式中: ω_{\max} 为 ω 的初始值; ω_{\min} 为 ω 的最终值; k_{\max} 为最大迭代次数; $|y^k|$ 为自逻辑映射函数产生的混沌序列, $|y^k| = 1 - 2(y^{k-1})^2, y^k \in (-1, 1)$ 。

由式(10)可知, 本文使用 PSO 算法优化 Elman 神经网络的 3 组权值和 2 组阈值, 每组都是多维矩阵, 维度较大, 导致算法求解能力较差。本文对 PSO 算法的粒子随迭代次数的更新公式做出改进, 位置与速度的更新公式为

$$X_{id}^{k+1} = \omega^* \cdot X_{id}^k + V_{id}^{k+1} \quad (17)$$

$$V_{id}^{k+1} = \omega^* \cdot V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k) \quad (18)$$

式中： ω^* 为经过混沌扰动改进的惯性权重。

2.3 CPSO算法优化Elman神经网络

在Elman神经网络进行训练前优化更新，进而获得预测模型，流程如图4所示。

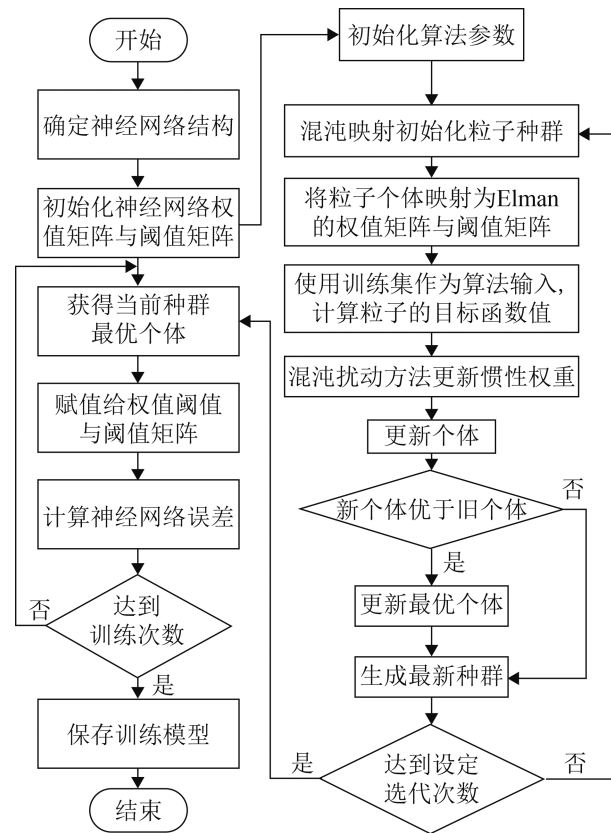


图4 算法流程图

Fig. 4 Flow chart of algorithm

3 算例分析

本文以某钢铁企业LDG实际生产数据为样本，在生产间歇未波动情况下和生产间歇发生波动情况下验证本文提出的模型对于1#转炉发生量360 min的预测效果。本文算法运行的软硬件环境为Intel Core i7 7700HQ、内存8 GB和Windows10操作系统。

3.1 数据选取及评价

算例采用某钢铁企业的2015-04-18—06-18中1#炼钢单元1#转炉的88 637条LDG发生量数据，采样间隔为1 min。提取历史数据中的产气间歇特征，由间歇种类将数据分为3类，每类样本数为1 440 min。根据间歇类别将原始时序数据转换为多维序列，并经过归一化处理输入预测模型，训练集和测试集的比例为4:1。选取平均绝对误差(E_{MA})和平均绝对百分比误差(E_{MAP})为评价指标，以评价本文所提出模型对转炉煤气发生量的预测精度。

$$E_{MA} = \frac{1}{T} \sum_{t=1}^T |\hat{y}_t - y_t| \quad (19)$$

$$E_{MAP} = \frac{100\%}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{\hat{y}_t} \right| \quad (20)$$

3.2 模型训练

针对1#LDG发生量的88 637 min数据提取其生产间歇，根据生产间歇时长划分类别，分类结果如表1所示，选取包含特定间歇时长的LDG时序数据训练预测模型。根据历史间歇数据训练间歇预测模型，用于预测实际生产中LDG时序的间歇。在生产间歇未波动情况下和生产间歇发生波动情况下验证本文提出模型对于1#转炉发生量360 min的预测效果。

CPSO算法优化Elman神经网络的权值和阈值，由神经网络结构设置CPSO的维数，求解粒子个数为

$$n = \lfloor 10 + 2\sqrt{D} \rfloor \quad (21)$$

各类生产间歇预测模型仿真参数设置如表2所示。

表2 主要仿真参数设置
Table 2 Main simulation parameter settings

参数	短	中	长
输入层节点	35	45	55
隐含层节点	7	9	12
粒子维数	260	504	685

经过多次仿真实验, 个体目标函数值在 30 次迭代计算后不再变化, 为节省计算时间, 设置最大迭代次数 k_{max} 为 50。确定 CPSO 算法的惯性权重初始值 ω_{max} 为 0.9, 惯性权重最终值 ω_{min} 为 0。PSO 算法的参数还包括种群规模、学习因子等, 此类参数的选取影响着模型预测结果。在原始 PSO 算法中, c_1 和 c_2 一般设置为 2, 但无法保证算法在任何情况下均全局收敛。考虑到平衡全局收敛与局部收敛, 文献[16]建议设置 c_1 和 c_2 为 1.49。因此, 以 LDG 中间歇预测模型为例, 选取不同种群规模, 在不同学习因子下进行仿真实验, 分析结果并选取效果最好的一组参数。算法参数仿真分析部分如表 3 所示。

表 3 算法参数实验结果

种群规模	c_1, c_2	MAE/(km ³ /h)	MAPE/%
30	2.00	8.46	3.35
	1.49	7.89	2.46
40	2.00	7.44	1.98
	1.49	7.49	2.42
50	2.00	10.10	4.54
	1.49	9.49	1.99

由表 3 可知, 中间歇情况下, 当种群规模设置为 40, 学习因子 c_1 和 c_2 设置为 2 时, 模型的预测效果最佳。

各类别生产间歇预测模型设置参数如表 4 所示。

表 4 各类别间歇下算法参数设置

参数	短	中	长
种群规模	30	40	50
c_1, c_2	1.49	2.00	1.49

根据式(9)的目标函数进行迭代寻优, 中间歇情况下 PSO 和 CPSO 的迭代过程如图 5 所示, CPSO 算法具有更好的初始值。

由表 5 可知, CPSO 算法相比于标准 PSO 算法适应度值低 2.839。迭代次数降低至 23。




图 5 目标函数值变化曲线

Fig. 5 Objective function value change curve

表 5 不同优化方法下优化结果

优化算法	迭代次数	适应度值
PSO	26	464.68
CPSO	23	451.55

3.3 算例仿真及分析

3.3.1 间歇时长未变动下预测模型的比较

由表 1 可见, 正常生产的 LDG 时序数据占据总时序数据的 69.9%, 因此对于间歇时长未变动下时序的预测尤为重要。使用 CPSO-Elman 预测模型预测 LDG 时序间歇时长, 预测结果如图 6 所示。




图 6 生产节奏未变动下间歇预测结果

Fig. 6 Intermittent prediction results without change in production rhythm

由图 6 可见, 对于包含正常间歇的 LDG 时序数据进行间歇的预测, 预测结果较好。根据图 6 间歇预测结果, 选取对应预测模型进行预测, 并分别使用 Elman 神经网络、PSO-Elman 预测模型和 CPSO-Elman 预测模型进行预测对比。不同模型的预测值和实际值预测曲线如图 7 所示。

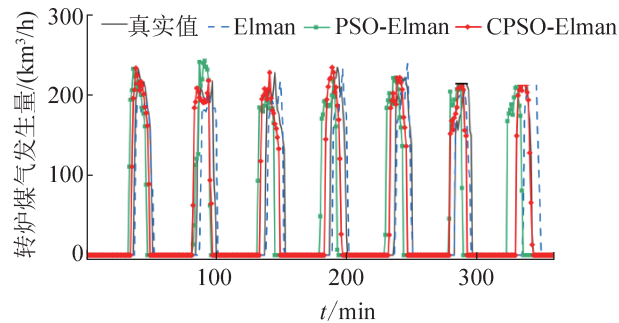


图7 生产节奏未变动下转炉煤气发生量预测结果
Fig. 7 Prediction results of converter gas generation without change in production rhythm

由图7可知,当系统处于正常生产节奏,生产间歇没有出现大波动时,未经过间歇分类预测的Elman神经网络并未出现大范围的波形错位现象,3个预测模型精度均良好。

为了对比分析3种预测模型在间歇时长未变动下的预测效果,各个模型的预测误差如表6所示。

表6 间歇时长未变动下LDG发生量预测误差
Table 6 Prediction error of LDG generation with no change of intermittent duration

模型	MAE/(km ³ /h)	MAPE/%
Elman	7.66	7.28
PSO-Elman	5.45	5.32
CPSO-Elman	4.28	4.13

由于经过间歇分类的预测模型提前预测了生产间歇时长,再进行LDG发生量的预测,所以在预测产气起点上相较于ENN更精确,误差更小。

3.3.2 间歇时长变动下预测模型比较

受生产节奏的影响,产气间歇会发生波动,当LDG产气间歇发生变动,单一神经网络预测模型无法抵抗时序数据随机性波动对预测带来的影响,预测效果差。提前预测间歇时长,然后将间歇时长结果提供给预测模型进行预测,可以有效提高预测准确率,避免生产间歇随机性波动带来的影响。间歇预测结果如图8所示。

根据间歇值预测结果选取间歇对应的预测模型进行预测,发生量预测值和实际值曲线图如图9所示。

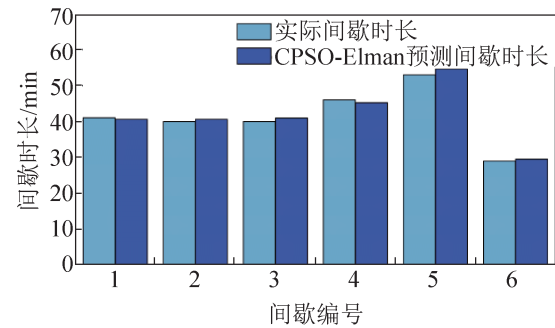


图8 生产节奏变动下间歇预测结果
Fig. 8 Intermittent prediction results under the change of production rhythm

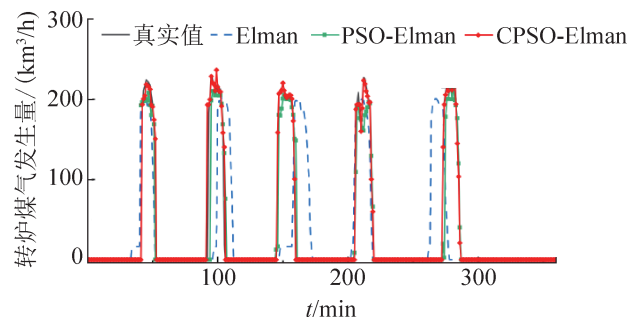


图9 生产节奏变动下转炉煤气发生量预测结果
Fig. 9 Prediction results of converter gas generation under changing production rhythm

通过图9可以看出,未经过分类训练而直接进行发生量预测的Elman预测模型,随着间歇时长的波动,出现了预测值与实际值错位的问题。而经过间歇特征提取并分类进行预测的PSO-Elman和CPSO-Elman预测模型很好的避免了这个,因为有着间歇预测结果作为输入,可以避免间歇随机性波动带来的波形错位问题。进一步的,CPSO-Elman预测模型相比于PSO-Elman预测模型具有更好的预测精度,与实际发生量变化趋势相似。

为了比较不同预测模型的效果,对比分析3种预测方法的平均误差和平均百分比值,如表7所示。

表7 间歇时长变动下LDG发生量预测误差
Table 7 Prediction error of LDG generation under intermittent duration variation

模型	MAE/(km ³ /h)	MAPE/%
Elman	10.01	9.16
PSO-Elman	7.55	6.79
CPSO-Elman	6.47	5.14

由表7可知, 由于ENN在预测前没有间歇分类的原因, 导致其无法应对间歇的随机性波动, 所以预测精度较差。PSO-Elman算法与CPSO-Elman算法由于在预测前加入了间歇特征提取并分类预测的步骤, 所以对间歇的随机性波动有着较好的鲁棒性, 预测精度良好。CPSO-Elman预测模型在算法优化参数前进行了粒子的随机扰动, 提高了随机性的分布, 对其惯性权重进行了混沌扰动, 使其呈现先大后小的变化, 所得解相较于标准PSO具有明显优势。

4 结论

针对LDG回收间歇波动性大, 预测精度低的问题, 本文提出了一种基于间歇分类CPSO-Elman的LDG回收量预测方法, 实现先生产间歇时长后转炉煤气发生量的“两步式”预测。针对LDG时序间歇波动大的特点, 该模型提取间歇特征, 根据间歇特征对历史LDG时序数据进行分类, 输入至不同模型训练, 提高了LDG时序数据的稳定性、降低了模型的复杂度; 采用混沌反向学习和混沌映射对粒子群算法进行改进, 用于优化ENN的初始权值矩阵和阈值矩阵, 提高了求解能力, 加快了收敛速度。实验结果表明: 本文所提预测模型的误差低于未经间歇分类的Elman模型, 相比于PSO-Elman模型具有更快的收敛速度。利用该混合预测算法对钢铁企业的LDG进行预测, 获得了较好的预测效果, 同时也可用于高炉煤气发生量等其他介质的预测。

参考文献:

- [1] Ishaq H, Dincer I, Naterer G F. Exergy-based Thermal Management of a Steelmaking Process Linked with a Multi-generation Power and Desalination System[J]. Energy, 2018, 159: 1206-1217.
- [2] Wen Zongguo, Wang Yihan, Zhang Chenkai, et al. Uncertainty Analysis of Industrial Energy Conservation Management in China's Iron and Steel Industry[J]. Journal of Environmental Management, 2018, 225: 205-214.
- [3] An Runying, Yu Biying, Li Ru, et al. Potential of Energy Savings and CO₂ Emission Reduction in China's Iron and Steel Industry[J]. Applied Energy, 2018, 226: 862-880.
- [4] Jin Feng, Zhao Jun, Liu Ying, et al. A Scheduling Approach with Uncertainties in Generation and Consumption for Converter Gas System in Steel Industry[J]. Information Sciences, 2021, 546: 312-328.
- [5] 徐化岩, 马家琳. 基于数据驱动的高炉煤气复合预测模型[J]. 中国冶金, 2019, 29(7): 56-60.
Xu Huayan, Ma Jialin. Composite Prediction Model of Blast Furnace Gas Based on Data Driven[J]. China Metallurgy, 2019, 29(7): 56-60.
- [6] Zhang Qi, Li Hui, Ma Jialin, et al. Dynamic Forecasting and Optimal Scheduling of By-product Gases in Integrated Iron and Steel Works[J]. Journal of Iron and Steel Research International, 2019, 26(5): 529-546.
- [7] Zhao Jun, Wang Wei, Liu Ying, et al. A Two-stage Online Prediction Method for a Blast Furnace Gas System and Its Application[J]. IEEE Transactions on Control Systems Technology, 2011, 19(3): 507-520.
- [8] Li Lei, Li Hongjuan. Forecasting and Optimal Probabilistic Scheduling of Surplus Gas Systems in Iron and Steel Industry[J]. Journal of Central South University, 2015, 22(4): 1437-1447.
- [9] Zhao Jun, Wang Wei, Witold Pedrycz, et al. Online Parameter Optimization-based Prediction for Converter Gas System by Parallel Strategies[J]. IEEE Transactions on Control Systems Technology, 2012, 20(3): 835-845.
- [10] Han Zhongyang, Liu Ying, Zhao Jun, et al. Real Time Prediction for Converter Gas Tank Levels Based on Multi-output Least Square Support Vector Regressor[J]. Control Engineering Practice, 2012, 20(12): 1400-1409.
- [11] Wang Jibin. A Deep Learning Approach for Atrial Fibrillation Signals Classification Based on Convolutional and Modified Elman Neural Network[J]. Future Generation Computer Systems, 2020, 102: 670-679.
- [12] Zhang Ying, Wang Xiaoping, Tang Huiming. An Improved Elman Neural Network with Piecewise Weighted Gradient for Time Series Prediction[J]. Neurocomputing, 2019, 359: 199-208.
- [13] Li Guoqing, Wang Wanliang, Zhang Weiwei, et al. Grid Search Based Multi-population Particle Swarm Optimization Algorithm for Multimodal Multi-objective Optimization[J]. Swarm and Evolutionary Computation, 2021, 62: 100843.
- [14] Zeng Nianyin, Wang Zidong, Liu Weibo, et al. A Dynamic Neighborhood-based Switching Particle Swarm Optimization Algorithm[J]. IEEE Transactions on

- Cybernetics, 2022, 52(9): 9290-9301.
- [15] 曾艳阳, 冯云霞, 赵文涛. 基于 logistic 映射的自适应尺度混沌粒子群算法[J]. 系统仿真学报, 2017, 29(10): 2241-2246.
Zeng Yanyang, Feng Yunxia, Zhao Wentao. Adaptive Mutative Scale Chaos Particles Swarm Optimization Based on Logistic Mapping[J]. Journal of System Simulation, 2017, 29(10): 2241-2246.
- [16] Frans van den Bergh. An Analysis of Particle Swarm Optimizers[D]. Pretoria: University of Pretoria, 2006.