基于知识与 AW-ESN 融合的烧结过程 FeO 含量预测

方怡静 [1] 蒋朝辉 [1, 2] 黄 良 [1] 桂卫华 [1, 2] 潘 冬 [1]

摘 要 氧化亚铁 (FeO) 含量是衡量烧结矿强度和还原性的重要指标, 烧结过程 FeO 含量的实时准确预测对于提升烧结质量、优化烧结工艺具有重要意义. 然而烧结过程热状态参数缺失、过程参数波动频繁给 FeO 含量的高精度预测带来巨大的挑战, 为此, 提出一种基于知识与变权重回声状态网络融合 (Fusion of data-knowledge and adaptive weight echo state network, DK-AWESN) 的烧结过程 FeO 含量预测方法. 首先, 针对烧结过程热状态参数缺失的问题, 建立烧结料层最高温度分布模型, 实现基于料层温度分布特征的 FeO 含量等级划分; 其次, 针对烧结过程参数波动频繁的问题, 提出基于核函数高维映射的多尺度数据配准方法, 有效抑制离群点的影响, 提升建模数据的质量; 最后, 针对烧结过程数据驱动模型缺乏机理认知致使模型预测精度不高的问题, 将过程数据中提取得到的 FeO 含量等级知识与 AW-ESN (Adaptive weight echo state network) 结合, 建立 DK-AWESN 模型, 有效提升复杂工况下 FeO 含量的预测精度. 现场工业数据试验表明, 所提方法能实时准确地预测烧结过程 FeO 含量, 为烧结过程的智能化调控提供实时有效的 FeO 含量反馈信息.

关键词 FeO 含量预测, 烧结过程, 数据知识, 变权重回声状态网络, 信息融合

引用格式 方怡静, 蒋朝辉, 黄良, 桂卫华, 潘冬. 基于知识与 AW-ESN 融合的烧结过程 FeO 含量预测. 自动化学报, 2024, **50**(2): 282−294

DOI 10.16383/j.aas.c211013

FeO Content Prediction in Sintering Process Based on Fusion of Data-Knowledge and AW-ESN

FANG Yi-Jing[1] JIANG Zhao-Hui[1, 2] HUANG Liang[1] GUI Wei-Hua[1, 2] PAN Dong[1]

Abstract FeO content is an important index to characterize the strength and reducibility of sinter. Real-time and accurate prediction of FeO content in sintering process is of great significance for improving sintering quality and optimizing sintering process. However, the lack of thermal state parameters in sintering process and the frequent fluctuation of process parameters bring great challenges to the high-precision prediction of FeO content. In order to alleviate these problems, a method of FeO content prediction in sintering process by fusing data-knowledge and adaptive weight echo state network (DK-AWESN) is proposed in this paper. Firstly, aiming at the problem of lacking thermal state parameters in sintering process, the temperature distribution model of sinter bed is established, and the state of FeO content can be obtained based on the temperature distribution characteristics of sinter bed; Secondly, aiming at the frequent fluctuation of sintering process parameters, a multi-scale data registration method based on kernel function high-dimensional mapping is proposed, which effectively suppresses the influence of outliers and improves the quality of modeling data; Finally, to alleviate the problem of low prediction accuracy of data-driven model due to the lack of mechanism knowledge, the expert knowledge extracted from the process data is fused with adaptive weight echo state network (AW-ESN) to establish DK-AWESN, which improves the FeO content prediction performance of the model under complex working conditions. Industrial verification shows that the proposed method can accurately predict the FeO content in real time and provide effective FeO content information for the intelligent control of the sintering process.

Key words FeO content prediction, sintering process, data-knowledge, adaptive weight echo state network (AW-ESN), information fusion

Citation Fang Yi-Jing, Jiang Zhao-Hui, Huang Liang, Gui Wei-Hua, Pan Dong. FeO content prediction in sintering process based on fusion of data-knowledge and AW-ESN. *Acta Automatica Sinica*, 2024, **50**(2): 282−294

收稿日期 2021-10-26 录用日期 2022-01-11
Manuscript received October 26, 2021; accepted January 11, 2022
国家自然科学基金 (61773406, 61927803), 中南大学中央高校基本科研任务业务费专项资金 (2020zzts572), 长沙市自然科学基金 (kq2202075) 资助
Supported by National Natural Science Foundation of China (61773406, 61927803), Central South University Central University Basic Scientific Research Task Business Expenses Special Funds (2020zzts572), and Changsha Natural Science Foundation Project (kq2202075)
本文责任编委 杨涛
Recommended by Associate Editor YANG Tao
1. 中南大学自动化学院 长沙 410000 2. 鹏城实验室 深圳 518000
1. School of Automation, Central South University, Changsha 410000 2. Pengcheng Laboratory, Shenzhen 518000

随着钢铁冶金行业的不断发展, 铁矿石资源日益紧缺且禀赋恶化, 已难以满足高炉绿色高效低碳冶炼的需求[1−2]. 烧结是将贫铁矿加工成富铁矿, 有利于高炉冶炼的过程, 为高炉炼铁提供主要原料, 其烧结矿质量对高炉的稳定顺行至关重要.

烧结矿的 FeO 含量不仅是衡量烧结矿质量的重要指标, 而且是影响高炉冶炼能耗、排放的重要因素. 因此, 实时准确获取 FeO 含量对烧结过程的智能化调控、提升烧结矿质量、保证高炉平稳顺行和绿色低碳高效生产具有重要意义[3−6].

由于烧结过程中存在高温、高尘、多相共存、多场耦合等特点, 烧结矿 FeO 含量难以直接在线检测. 通常工业现场对 FeO 含量的检测, 主要是采用人工定期采样, 再利用重铬酸钾化学分析法、X 射线光谱分析法等方法对采样样本进行离线分析[7−9]. 这些方法存在检测速度慢、设备成本高、操作复杂等局限性, 且检测结果时间滞后大, 导致烧结矿的质量信息不能得到及时反馈, 严重制约了烧结过程的精细化调控, 无法满足烧结现场实时检测的需求. 因此建立 FeO 含量的预测模型, 实现 FeO 含量的高精度在线预测对于烧结过程的优化具有重要意义. 目前, 烧结过程 FeO 含量建模方法可以总结为以下三种: 1) 基于物料守恒的建模方法, 主要是通过对过程的其他相关参数进行在线检测, 基于物料守恒的原理, 建立机理模型, 计算 FeO 的含量[10−12], 该思路适用范围广、可解释性强, 但所需的检测设备费用高昂, 且各烧结厂冶炼环境和原材料各异, 烧结过程发生的物理化学反应复杂多变, 难以通过机理模型准确地计算出 FeO 含量. 2) 基于烧结机尾断面图像信息, 结合现场专家经验建立的软测量模型[13−15]. 这一类方法基于专家经验建立模型, 提取到的图像信息一定程度上也能反映 FeO 的含量信息. 然而烧结机尾高温、多粉尘的生产环境, 会极大地影响图片获取的质量, 仅利用图像信息难以获取精准的 FeO 含量. 3) 基于烧结过程生产数据建立的数据驱动模型[16−21]. 这一类方法不需要了解烧结过程发生的复杂反应, 仅通过数学工具和智能算法对历史时刻的过程数据中包含的规律进行挖掘, 就可以建立烧结矿质量指标的预测模型, 因此数据驱动模型成为近年烧结过程 FeO 含量建模研究的热点.

国内外学者在基于数据驱动的 FeO 含量预测上做了许多相关的研究. 文献 [19] 和文献 [20] 分别利用 BP 神经网络和前馈神经网络建立 FeO 含量的预测模型, 由于上述网络存在过拟合和易陷入局部最小值的问题, 取得的预测效果并不理想. 文献 [21] 采用深度信念网络 (Deep belief network, DBN) 进行 FeO 含量的预测, 然而 DBN 作为一种深度网络, 需要大量训练样本且计算成本较高, 难以应用于实际的烧结过程中. 由于烧结过程具有动态性和时序性, 烧结矿的 FeO 含量不仅与当前的工艺参数有关, 同时受历史时刻的工艺参数影响, 这要求网络具有较强的时间序列数据处理能力. 循环神经网络 (Recurrent neural network, RNN) 在时间序列建模上展现了良好的性能, 但收敛速度慢、易陷入局部最小值和计算复杂度高等问题限制了其在实际工业过程中的应用[22−23]. 回声状态网络 (Echo state network, ESN) 作为一种特殊的 RNN, 具有短期记忆的显著潜力, 并且对于非线性系统的动态预测表现出了良好的性能[24−26]. ESN 的输入层和储藏层的权值采用随机值初始化的方式确定, 只有输出层的权值需要通过训练获得, 一定程度上避免了预测模型陷入局部极小值, 提高了学习速率.

然而, 作为一种数据驱动模型, ESN 应用于烧结过程的 FeO 含量建模仍存在一定的局限性, 由于烧结过程热状态参数缺失, 且数据驱动模型对机理缺乏认知, 易致使模型的泛化能力不足, 而工业过程存在的变量漂移等问题也会导致模型的预测精度降低. 针对上述问题, 本文提出了一种将机理知识与数据驱动模型相结合的建模方法. 通过对烧结过程的传热机理进行分析, 建立了料层最高温度分布模型, 从而获取烧结过程的温度分布特征, 结合过程数据和专家经验, 挖掘过程数据中的专家知识, 实现基于数据知识的 FeO 含量等级划分. 获取的 FeO 含量知识用于对 ESN 模型输出函数的改进, 实现机理知识与 ESN 的融合, 降低了过程扰动和噪声对预测结果的影响, 同时提出了一种新的基于梯度的权重调整策略 (Adaptive weight strategy) 用于 ESN 输出权重的学习, 最终建立基于知识与 AW-ESN (Adaptive weight echo state network) 融合的烧结过程 FeO 含量预测模型——基于知识与变权重回声状态网络融合的模型 (Fusion of data-knowledge and adaptive weight echo state network, DK-AWESN). 基于某钢铁厂的烧结厂的实际生产数据验证了本文所提的基于知识与 AW-ESN 融合的烧结过程 FeO 含量预测方法的有效性.

1 基于料层温度分布特征的 FeO 含量等级划分

烧结矿中 FeO 主要以磁铁矿和含铁硅酸盐的形式存在, 如铁橄榄石、钙铁橄榄石, 而含 FeO 的液相铁橄榄石、钙铁橄榄石的生成温度要求极高, 因此烧结料层内部热状态与烧结矿的 FeO 含量关系密切, 但是烧结过程的工艺特性导致实际烧结过程不能直接观察, 现有的检测手段无法准确获取烧结过程各阶段的料层温度. 为了建立准确的烧结过

程 FeO 含量预测模型, 需要在建模前对烧结料层内部热状态进行深入分析. 烧结料层内部热状态的变化体现为温度变化, 不同时刻的温度特征信息可以反映烧结料层中 FeO 的含量. 因此, 本节通过对烧结过程气–固传热机理分析建立烧结料层的最高温度分布模型, 获取各料层的温度分布特征, 结合专家经验, 从过程数据中提取出一系列规则作为专家知识, 利用模糊推理的方法, 实现对烧结矿 FeO 含量等级的划分.

1.1 烧结料层温度分布特征提取

如图 1 所示, 将带式烧结台车当作由若干个固定单元串联形成的整体, 混合料沿 y 方向横向铺在烧结机上, 同时在沿 x 方向水平缓慢移动, 风箱作业使得空气垂直混合料表面竖向沿 z 方向流动. 本节利用现场工艺参数结合传热学理论, 建立基于微元 $\mathrm{d}z$ 的烧结过程热状态模型用以计算烧结矿各层温度的最大值, 实现烧结料层温度分布特征的提取.

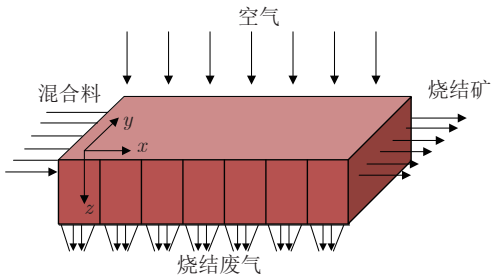

图 1 烧结过程示意图

Fig. 1 Schematic diagram of sintering process

为方便模型计算, 假设烧结过程在每一层的横向烧结状况相同, 在纵向对每个无穷小厚度 $\mathrm{d}z$ 进行气体、固体的热平衡计算[27]. 首先针对固体在单位体积、单位时间的热增量等于气–固单位时间、体积热交换值与反应热增量之和建立热平衡方程, 其次针对气体在同样的单位时间、体积的热变化等于气–固热交换与反应热之和建立热平衡方程, 即

$$\begin{cases} \rho_g\varepsilon\overline{C}_g\left(\dfrac{\partial T_g}{\partial t}\right)-R_c\Delta H_c+hs\left(T_g-T_s\right)+ \\ \qquad v_g\rho_g\overline{C}_g\left(\dfrac{\partial T_g}{\partial z}\right)=0 \\ \rho_s(1-\varepsilon)\overline{C}_s\left(\dfrac{\partial T_s}{\partial t}\right)-R_c\Delta H_c+hs\left(T_g-T_s\right)+ \\ \qquad v_s\rho_s\overline{C}_s(1-\varepsilon)\left(\dfrac{\partial T_s}{\partial z}\right)-\dfrac{\partial}{\partial z}\left(\tau\dfrac{\partial T_s}{\partial z}\right)=0 \end{cases} \tag{1}$$

式中, v_g 和 v_s 分别表示气体流速和固体流速, ρ_g 和 ρ_s 分别表示气体密度和固体密度, $\overline{C}_g$ 和 $\overline{C}_s$ 分别表示气体比热容和固体比热容, ε 表示料层孔隙率, T_g 和 T_s 分别表示料层气相温度和固相温度, h 为气–固相间对流传热系数, s 为单位体积颗粒总表面积, τ 为料层的有效导热系数, R_c 表示化学反应的综合反应速率, ΔH_c 表示反应的反应焓, 此处反应指焦粉的燃烧反应.

烧结过程按燃料的燃烧程度可以分为两个阶段: 1) 当燃料未燃尽时, 烧结域内的热源主要来自燃料的燃烧放热, 由式 (1) 可知烧结过程固相的热量主要由内部热源和上部气体传热供给. 假设气体只在 z 方向上均匀流动, 对于微小料层 $\mathrm{d}z$, 可以认为其处于静止状态的非稳态传热 ($v_s=0$). 假设烧结料层不导热, 料层内部只进行气固热交换, 传热系数足够大使得空间内任何点有相同固相–气相温度, 则有 $T_s=T_g=T$, $\frac{\partial T_g}{\partial z}=\frac{\partial T_s}{\partial z}$, $\frac{\partial T_g}{\partial t}=\frac{\partial T_s}{\partial t}$, 热平衡方程为

$$\begin{cases} \rho_g\varepsilon\overline{C}_g\left(\dfrac{\partial T_g}{\partial t}\right)-R_c\Delta H_c+v_g\rho_g\overline{C}_g\left(\dfrac{\partial T_g}{\partial z}\right)=0 \\ \rho_s(1-\varepsilon)\overline{C}_s\left(\dfrac{\partial T_g}{\partial t}\right)=0 \end{cases} \tag{2}$$

2) 当烧结过程进行到燃料耗尽的成矿区域时, 假设此时只存在上层气体与下层物料的热交换, 无其他反应热供给 (消耗), 则此时的化学反应热值 $q=R_c\Delta H_c$ 为 0, 此时料层内部的热平衡方程为

$$\begin{cases} \rho_g\varepsilon\overline{C}_g\left(\dfrac{\partial T_g}{\partial t}\right)+v_g\rho_g\overline{C}_g\left(\dfrac{\partial T_g}{\partial z}\right)=0 \\ \rho_s(1-\varepsilon)\overline{C}_s\left(\dfrac{\partial T_g}{\partial t}\right)=0 \end{cases} \tag{3}$$

根据上述分析, 为了完善建立的热交换模型, 需要建立一个合适的燃料燃烧模型及判断两式转折的临界点模型.

1) 燃料燃烧模型

对于烧结过程而言, 焦粉在料层中以焦炭颗粒形式存在, 其作为燃料在单位时间、体积内的反应热为

$$q=R_c\times\Delta H_c \tag{4}$$

式中, R_c 为反应速率, ΔH_c 为反应焓. 焦炭的燃烧过程采用一级化学反应式表示, 即

$$\mathrm{C}+\mathrm{O_2}=\mathrm{CO_2},\quad \Delta H_c=-393.5\ \mathrm{kJ/mol} \tag{5}$$

焦炭颗粒在燃烧时会由外向内逐步燃尽, 原粒径为 r 的焦炭颗粒在燃烧一段时间后剩余部分的粒径为 r_c. 因此在燃烧过程中, 焦炭颗粒的粒径可以直接反映燃料剩余量, 焦炭颗粒的反应速率可以表

示为

$$\begin{cases} k_c = k\mathrm{e}^{-\frac{E}{RT}}\sqrt{T} \\ k_m = 0.066\dfrac{PD_{\mathrm{O}_2}Re^{\frac{4}{5}}Sc^{\frac{1}{3}}\ln\frac{P_{\mathrm{O}_2 2}}{P_{\mathrm{O}_2 1}}}{(P_{\mathrm{O}_2 2}-P_{\mathrm{O}_2 1})RT} \\ k_o = \dfrac{(r-r_c)D_{\mathrm{O}_2}}{\varepsilon_c \mathrm{e}^{-0.006(r-Br_c)}} \\ R_c = \dfrac{4\pi {r_c}^2 C_{\mathrm{O}_2}}{\frac{1}{k_c}+\frac{1}{k_m}+k_o} \end{cases} \tag{6}$$

由上述参数计算可知在每个时刻 $\mathrm{d}z$ 内的综合反应速率 R_c, 计算所需的参数取值如表 1 所示. 假设单位体积的料层包含 n 个焦炭颗粒, 则

$$n = \frac{4(1-\varepsilon_c)\beta_c}{3\pi r^3} \tag{7}$$

式中, β_c 为燃料的百分含量, 若已知单位体积料层中燃料颗粒个数, 则可以通过计算得到每层烧结料中燃烧热为

$$q_n = \frac{16(1-\varepsilon_c)\beta_c {r_c}^2 C_{\mathrm{O}_2}\Delta H_c}{3r^3\left(\frac{1}{k_c}+\frac{1}{k_m}+k_o\right)} \tag{8}$$

式中, k_c, k_m, k_o 的计算方式见式 (6).

2) 燃料是否耗尽的分界判据

当燃料颗粒未耗尽时, 空气中氧气由于传质作用透过燃尽的灰层进一步与焦炭燃料接触, 此时外界温度已达到焦炭 700 ℃ 的燃点, 所以仍然存在式 (5) 所示的一级反应. 由于化学反应导致的焦炭消耗将使得焦炭粒径减少, 在整个过程中单位体积内焦炭的摩尔数为

$$V_{\mathrm{mol}} = \frac{(1-\varepsilon_c)\beta_c\rho_c}{M_{\mathrm{mol}}} \tag{9}$$

表 1　反应速率计算参数表

Table 1　Reaction rate parameters

参数名称	符号	值
指前因子	k	$6.89\times10^5 \sim 8.3\times10^5\ \mathrm{s}^{-1}$
反应活化能	E	125.61 ~ 137.16 kJ/ mol
比例系数	R	8.314 kJ/(mol · K)
抽风负压	P	1.2×10^4 Pa
料前氧分压	$P_{\mathrm{O}_2 1}$	0.21 P
料后氧分压	$P_{\mathrm{O}_2 2}$	0.09 ~ 0.11 P
总氧气扩散系数	$D_{\mathrm{O}2}$	$2.03\times10^{-5}T^{1.87}$
雷诺数	Re	$2\times10^3 \sim 3.5\times10^4$
燃料孔隙率	ε_c	0.39
有效孔隙率	B	0.15
施密特数	Sc	0.6 ~ 2.5
氧气浓度	C_{O_2}	9.735%

式中, ρ_c 为焦炭密度, M_{mol} 为碳的摩尔质量, 所以在单位体积料层内包含的燃料量可以用 V_{mol} 表示, 当燃料量小于 V_{mol} 时则可以判断燃料被消耗完毕. 根据推导得到的燃料燃烧综合反应速率 R_c, 可以计算出燃烧反应 t 时刻后燃料的总消耗量为

$$V_{\mathrm{sum}} = \sum R_c \mathrm{d}t \tag{10}$$

易知当 $V_{\mathrm{sum}} = V_{\mathrm{mol}}$ 时, 热交换方程中燃料燃烧的部分不再作用. 利用烧结过程中基于燃料是否耗尽的有、无热源分界判据结合燃料燃烧热模型可以代入式 (2) 和式 (3) 所示的两阶段的燃烧热平衡方程, 最终得到的解析式为

$$\begin{cases} v_g\rho_g\overline{C}_g\left(\dfrac{\partial T_g}{\partial z}\right)+\rho_g\overline{C}_g\varepsilon\left(\dfrac{\partial T_g}{\partial t}\right)- \\ \qquad \dfrac{16(1-\varepsilon_c)\beta_c {r_c}^2 C_{\mathrm{O}_2}\Delta H_c}{3r^3\left(\frac{1}{k_c}+\frac{1}{k_m}+k_o\right)}=0, & V_{\mathrm{sum}} \le V_{\mathrm{mol}} \\ \rho_s\overline{C}_s(1-\varepsilon)\left(\dfrac{\partial T_g}{\partial t}\right)=0, & V_{\mathrm{sum}} \le V_{\mathrm{mol}} \\ v_g\rho_g\overline{C}_g\left(\dfrac{\partial T_g}{\partial z}\right)+\rho_g\overline{C}_g\varepsilon\left(\dfrac{\partial T_g}{\partial t}\right)=0, & V_{\mathrm{sum}} > V_{\mathrm{mol}} \\ \rho_s\overline{C}_s(1-\varepsilon)\left(\dfrac{\partial T_g}{\partial t}\right)=0, & V_{\mathrm{sum}} > V_{\mathrm{mol}} \end{cases} \tag{11}$$

经推导, 得到了在一定假设下的完整烧结热交换模型, 在满足判据的条件下分别按照有热源、无热源的固–气偏微分方程进行计算. 由于模型为气–固两相的热交换偏微分方程, 本文利用偏微分方程的数值解方法求解.

根据模型计算得到整个烧结料层的最高温度分布在时间维度上的变化, 如图 2 所示. 随着吸风烧结过程的进行, 烧结过程前 30% 阶段燃烧带的最高温度快速增加, 但是在后 70% 阶段燃烧带最高温度增长速度变慢, 尤其是后 30% 阶段温度基本不再增加. 这是由于气固流动带来的显热增量逐渐达到饱和值, 饱和温度在 1 420 ℃ 左右, 与理论分析的情况相符合.

根据图 3 所示的烧结料层的全时空温度分布图可清晰地看出, 在整个烧结过程中, 随着蓄热作用的不断进行, 料层中燃烧层的温度会持续攀升, 燃烧区域会持续扩大, 这说明本文建立的模型能够较好地还原烧结过程的全时空传热状态. 且从图 3 中可以看出, 烧结料层在不同时刻下的最高温度值是变化的, 料层内部发生的物理化学反应也必然会存在差异, 因此烧结料层最高温度是影响烧结矿 FeO 含量的重要热状态参数.

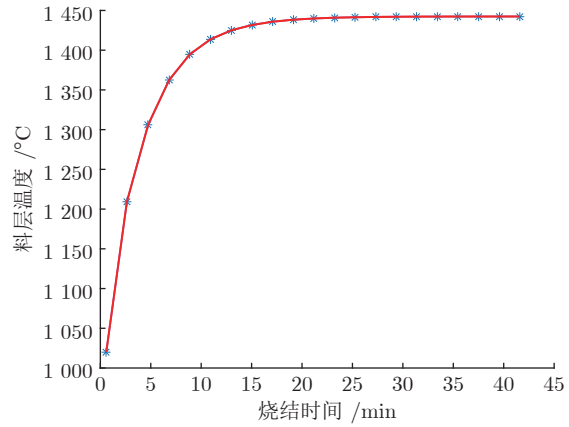

图 2 料层全时空最高温度分布

Fig. 2 Maximum temperature distribution of sinter bed in whole time and space

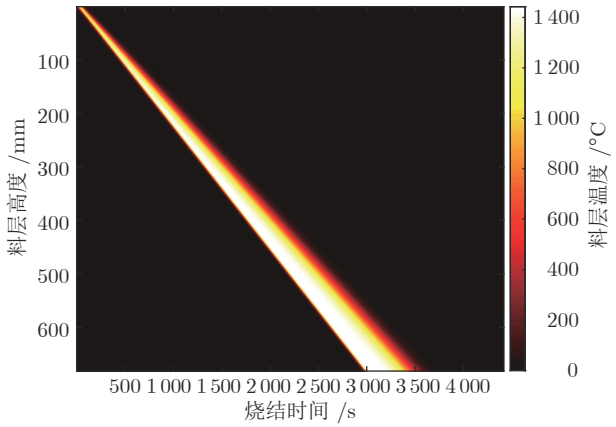

图 3 料层全时空温度分布图

Fig. 3 Temperature distribution of sinter bed in whole time and space

1.2 烧结过程 FeO 含量等级划分

烧结过程是一个机理复杂、非线性的动态时变过程. 影响烧结过程的因素众多, 难以通过机理分析获取准确的 FeO 含量, 而烧结现场的专家通常能够基于经验和生产数据大致判断 FeO 含量的区间. 因此, 本节根据专家经验, 从过程数据中提取出一系列规则作为专家知识, 利用模糊推理的方法, 实现对烧结矿 FeO 含量等级的划分.

为了从过程数据和专家经验中获取知识, 基于模糊规则对过程数据进行规则提取, 提取得到的规则可以表示如下:

R_1: IF x_1 is A_{11} and x_2 is A_{21} and x_3 is A_{31} and x_4 is A_{41} THEN y is f_1.

R_2: IF x_1 is A_{12} and x_2 is A_{22} and x_3 is A_{32} and x_4 is A_{42} THEN y is f_2.

⋮

R_q: IF x_1 is A_{1q} and x_2 is A_{2q} and x_3 is A_{3q} and x_4 is A_{4q} THEN y is f_q.

在上述规则中, x_1 表示烧结料层最高温度, x_2 表示料层高度, x_3 表示混合料燃料比, x_4 表示全铁, y 表示烧结过程烧结矿 FeO 含量等级, A_{1q}, A_{2q}, A_{3q}, A_{4q}, f_q 分别是 x_1, x_2, x_3, x_4, y 的模糊集合, 且各规则的模糊蕴含关系都已知, 现在根据 x_1, x_2, x_3, x_4, y 上的模糊集合 A_1^*, A_2^*, A_3^*, A_4^* 推出新的模糊集合 f^*.

基于某钢铁集团烧结厂数据库中的历史数据和料层最高温度模型的计算结果, 可以获得各过程参数的变化范围. 基于隶属度, 各参数的变化范围划分为 4 个区间, 即最大合适区间、中等合适区间、小合适区间以及不适合区间, 各参数的隶属度函数如图 4 所示.

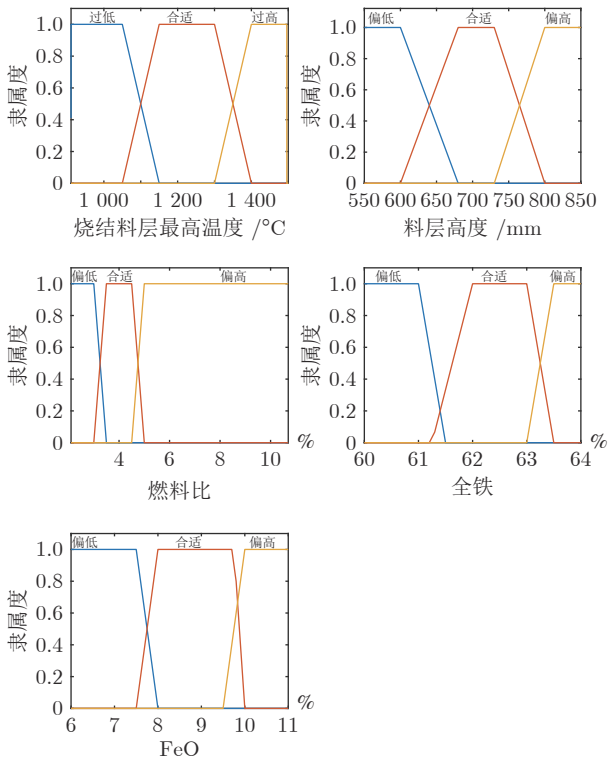

图 4 各参数隶属函数

Fig. 4 Membership function of each parameter

推算值与数据库中 FeO 含量化验值对比如表 2 所示. 通过对 600 组样本的实验结果进行统计, 烧结矿 FeO 含量“偏大”数据有 153 组、“正常”有 396 组, “偏小”有 51 组, 对比推理结果与实际化验数据, 仅仅 29 组数据的推理结果与化验数据不符. 本文建立的 FeO 含量等级推理模型准确率高达 95.17%, 实际生产允许的误差范围为 5% 以内, 因此, 所提基于烧结料层温度分布特征提取的烧结过

表 2　FeO 含量等级推理结果与实际值对比

Table 2　Comparison of the inference results with measured values of FeO content

序号	料层最高温度 (℃)	料层高度 (mm)	燃料比 (%)	全铁 (%)	推理结果	化验数据
1	1 278.55	749.129	4.187	61.874	正常	正常 (8.96)
2	1 127.32	736.383	4.496	60.899	正常	正常 (9.27)
3	1 158.76	761.918	4.492	61.854	正常	正常 (9.06)
4	1 211.36	718.536	4.331	61.715	正常	正常 (9.47)
5	1 274.22	717.253	4.162	60.706	偏小	偏小 (7.37)
⋮	⋮	⋮	⋮	⋮	⋮	⋮
558	1 160.56	649.579	4.561	63.755	正常	正常 (9.47)
559	1 176.76	650.864	4.305	60.802	偏大	偏大 (10.60)
600	1 308.99	710.711	4.286	61.067	正常	正常 (8.16)

程 FeO 含量等级划分方法的精度符合现场需求, 且能为后续建立准确高效的预测模型奠定基础.

2　基于 DK-AWESN 的烧结过程 FeO 含量预测

面对烧结过程的强耦合性和动态复杂性, 本文提出一种基于知识与 AW-ESN 融合的烧结过程 FeO 含量预测方法. 首先, 提出一种基于核函数高维映射的多尺度数据配准方法, 用于构造建模样本集; 其次, 提出一种新的权重调整策略用于 ESN 的输出权重调整; 最终, 基于模糊规则从过程数据中提取的 FeO 含量知识融入到 AW-ESN, 建立 DK-AWESN 模型用于 FeO 含量的预测. 本文所提方法的总体框图如图 5 所示.

2.1　FeO 含量相关变量确定及输入数据集的构建

烧结矿的 FeO 含量与配料参数、烧结过程检测参数和设备状态参数等过程参数息息相关. 本文采用灰色关联分析法 (Grey relational analysis, GRA), 通过定量计算 FeO 含量序列的曲线与过程参数序列的曲线之间的相似程度判断 FeO 含量与过程参数的相关性, 从而确定预测模型的输入变量.

在计算参数与 FeO 含量之间的关联度之前, 对工艺参数序列进行归一化处理, 即

$$\{x_i(k)\}=\frac{\{z_i(k)\}}{\frac{1}{n}\sum_{k=1}^{n}\{z_i(k)\}} \tag{12}$$

式中, $i=0, 1, 2, \cdots, m$, $k=1, 2, 3, \cdots, n$, $\{z_i(k)\}$ 表示归一化前的第 i 个参数序列, $z_i(k)$ 表示序列中的第 k 个元素, $\{x_i(k)\}$ 表示归一化后的序列. $\{z_0(k)\}$ 代表参考序列, 为 FeO 含量的序列, $\{z_i(k)\}$ 代表比较序列, 为各工艺参数的序列.

完成归一化后, 计算每个比较序列与参考序列的关联系数, 即

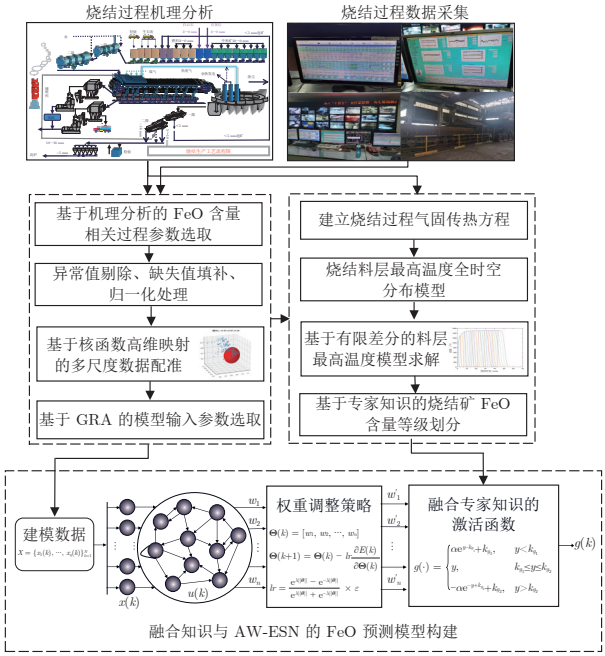

图 5　基于 DK-AWESN 的 FeO 含量预测方法框图

Fig. 5　Schematic of FeO content prediction method based on DK-AWESN

$$\xi_i(k)=\frac{\min\limits_i\min\limits_k\{|x_0(k)-x_i(k)|\}+\rho\max\limits_i\min\limits_k\{|x_0(k)-x_i(k)|\}}{|x_0(k)-x_i(k)|+\rho\max\limits_i\min\limits_k\{|x_0(k)-x_i(k)|\}} \tag{13}$$

式中, ρ 表示分辨系数, 取值范围为 [0, 1], 本文取 $\rho=0.5$, $\xi_i(k)$ 表示第 i 个参数的灰色关联系数.

在计算每一个参数值的关联度系数后, 根据式 (14) 计算烧结过程各工艺参数的灰色关联度 r_i.

$$r_i=\frac{1}{m}\sum_{k=1}^{n}\xi_i(k) \tag{14}$$

以烧结矿 FeO 含量为参考序列, 烧结过程工艺

参数为比较序列, 从烧结数据中心选取 300 组样本数据用于计算各过程参数与 FeO 含量之间的灰色关联度. 根据计算结果, 表 3 列出了灰色关联度较高的 20 个参数.

当过程变量与 FeO 含量之间的灰色关联度大于 0.5 时, 可以认为变量与 FeO 含量之间存在较强相关性. 从表 3 可以看出, 燃料配比、料层高度、原料中氧化镁含量 (C_{MgO}) 等配料参数在灰色关联分析下与 FeO 含量存在较强相关性. 除了配料参数, 还有风箱废气温度、空支流量、烧结机机速、返矿比等 10 个过程参数也具有较高相关性, 因此将这 15 个变量作为预测模型的输入.

烧结数据中心 FeO 含量的数据记录间隔为 2 h, 而这 2 h 内对应的工艺参数的采样频率远高于 FeO 含量, 数据量不平衡将导致预测模型无法正常训练, 且过程参数的频繁波动会造成模型精度的下降. 为解决这一问题, 本节提出了基于核函数高维映射的多尺度数据配准方法, 对不同时间尺度的数据进行匹配, 通过提高输入样本集的质量, 从而提升模型的预测精度. 该方法的具体步骤如下:

步骤 1. 从历史数据库中收集风箱废气温度、料层透气性等 q 个过程参数数据以及对应历史时刻的 FeO 采样数据. 初始化集合 $X=\{B_i\}_{i=1}^{q}=\emptyset$.

步骤 2. 假定第 i 个过程参数在第 t 个 FeO 采样时间间隔内的数据集为 $\{x_i(k)\}_{k=1}^{n}$. 通过核函数 $\varphi(\cdot)$, $\{x_i(k)\}_{k=1}^{n}$ 映射到高维空间, 其映射集为 $A=\{\varphi(x_i(k))\}_{k=1}^{n}$, 式中 $\varphi(\cdot)$ 为高斯函数, 其定义为

$$K(x,x_i(k))=\mathrm{e}^{-\frac{\|x-x_i(k)\|^2}{2\sigma^2}} \tag{15}$$

其中, $x_i(k)$ 表示第 i 个输入参数序列中第 k 个数据点, n 表示第 i 个过程参数序列的样本数, σ 表示高斯函数的伸缩量.

步骤 3. 定义 $N_\gamma^k=\{\varphi(x_i(l))\in A\,|dist(\varphi(x_i(k)),\varphi(x_i(l)))\le\gamma\}$, 式中, γ 为距离阈值, $dist(\varphi(x_i(k)),\varphi(x_i(l)))$ 为映射点 $\varphi(x_i(k))$ 和 $\varphi(x_i(l))$ 的欧氏距离, 计算式为

$$\gamma=\sqrt[m]{\sum_{p=1}^{m}\varepsilon_i(X_{\max}^p-X_{\min}^p)^2} \tag{16}$$

$$dist(\varphi(x_i(k)),\varphi(x_i(l)))=\sqrt{(\varphi(x_i(k))-\varphi(x_i(l)))^2} \tag{17}$$

式中, ε_i 表示距离系数, 取值范围 [0.1, 0.2], $X_{\max}^P$, $X_{\min}^P$ 分别表示映射集在第 p 维的最大值和最小值, m 表示映射维度.

步骤 4. 若存在 $\varsigma(N_\gamma^k)\ge\varsigma(N_\gamma^l)$, $\varsigma(N_\gamma^k)$ 表示 N_γ^k 中包含的样本个数, 则称 $\varphi(x_i(k))$ 为核心对象 $M_{\varphi(x_i(k))}$, 若 $M_{\varphi(x_i(k))}$ 不唯一, 再进行一次高维映射, 重复步骤 3 和步骤 4, 直至核心对象 $M_{\varphi(x_i(k))}$ 唯一, 则令 $x_i(k)\in B_i$.

步骤 5. 重复步骤 2 ~ 4, 直至计算得到所有 FeO 采样时间间隔内的 $M_{\varphi(x_i(k))}$, 此时, $B_i=\{x_i(k)\}_{k=1}^{N}$, N 为 FeO 样本个数.

步骤 6. 重复步骤 2 ~ 5, 直至计算得到全部过程变量的核心数据集 B_i, 最终得到输入样本集 $X=\{B_1,\cdots,B_q\}=\{x_1(k),\cdots,x_q(k)\}_{k=1}^{N}$.

2.2 DK-AWESN 预测模型搭建

由于烧结过程是一个动态的、时变的过程, 具有强耦合、大时滞等特点. 烧结过程参数在时间和空间维度上互相耦合, 致使当前时刻烧结矿的质量不仅与历史的烧结矿质量相关, 同时影响着未来的烧结矿质量. 因此, 烧结矿的 FeO 含量不仅与当前的工艺参数有关, 而且受历史时刻的工艺参数影响.

表 3 各过程参数的灰色关联度

Table 3 The grey relational degree of process parameters

序号	变量名称	关联度	序号	变量名称	关联度
1	风箱废气温度	0.803	11	空支流量	0.559
2	烧结机机速	0.798	12	C_{MgO}	0.557
3	料层高度	0.778	13	透气性	0.549
4	烧结终点	0.737	14	返矿比	0.539
5	C_{SiO_2}	0.733	15	风箱负压	0.527
6	碱度	0.703	16	C_{CaO}	0.459
7	燃料配比	0.669	17	烟道压力	0.337
8	环冷机速度	0.641	18	风机入口温度	0.327
9	点火温度	0.618	19	混一温度	0.271
10	煤支流量	0.574	20	圆辊速度	0.249

这就要求所建模型具有动态记忆历史信息的能力, 在学习新信息的同时存储历史信息. 回声状态网络 (ESN) 具有大规模随机稀疏网络 (储备池) 作为信息存储和处理的单元, 因此非常适合用于烧结过程 FeO 含量预测. 一个无输出反馈的 ESN 由三个基本单元组成: 一个输入层、一个大型的循环隐藏层 (储备池) 以及一个输出层. 输入层是随机连接到储备池的, 而储备池包含稀疏随机连接的神经元用于存储相关的信息和保存时间特性[28]. 假定网络的输入为 $\boldsymbol{x}(k) \in \mathbf{R}^M$, k–1 时刻储存库的状态变量为 $\boldsymbol{u}(k-1) \in \mathbf{R}^N$, 标准的 ESN 离散模型可以表示为

$$\boldsymbol{u}(k) = f\left(\boldsymbol{W}^{\text{res}}\boldsymbol{u}(k-1) + \boldsymbol{W}^{\text{in}}\boldsymbol{x}(k)\right) \tag{18}$$

$$y(k) = f^{\text{out}}\left(\boldsymbol{W}^{\text{out}}(\boldsymbol{u}(k), \boldsymbol{x}(k))\right) \tag{19}$$

式中, $y(k) \in \mathbf{R}^L$ 是 k 时刻的模型输出, $\boldsymbol{W}^{\text{in}}$, $\boldsymbol{W}^{\text{res}}$, $\boldsymbol{W}^{\text{out}}$ 分别表示模型的输入权重、储存池的连接权重以及输出权重. 其中, $\boldsymbol{W}^{\text{in}}$, $\boldsymbol{W}^{\text{res}}$ 是随机生成的, $\boldsymbol{W}^{\text{out}}$ 通常通过训练算法来计算和更新. $f(\cdot)$ 是存储层的激活函数, 本文选择 tanh 函数; $f^{\text{out}}(\cdot)$ 是输出层的激活函数.

模型性能与输入数据的选择方法和网络参数的确定方法具有强相关性. 本文在第 2.1 节中提出了基于核函数高维映射的多尺度数据配准方法, 用于建模数据集的构建. 本节中, 提出了一种基于梯度的权重调整策略用于 ESN 输出权重的更新. 首先定义网络的误差函数 $E(k)$ 为李雅普诺夫函数, 即

$$E(k) = \frac{1}{2}e^2(k) = \frac{1}{2}(y_t(k) - y(k))^2 \tag{20}$$

式中, $e(k)$ 为预测结果的误差, $y_t(k)$ 表示实测值, $y(k)$ 表示模型的预测值. 网络参数的学习算法为

$$\boldsymbol{\Theta}(k+1) = \boldsymbol{\Theta}(k) - lr\frac{\partial E(k)}{\partial \boldsymbol{\Theta}(k)} = \boldsymbol{\Theta}(k) + lr \times e(k)\frac{\partial y(k)}{\partial \boldsymbol{\Theta}(k)} \tag{21}$$

式中

$$\boldsymbol{\Theta}(k) = \boldsymbol{W}^{\text{out}} = [w_1, w_2, \cdots, w_n]$$

$$\frac{\partial y(k)}{\partial \boldsymbol{\Theta}(k)} = \left[\frac{\partial y(k)}{\partial w_1(k)}, \frac{\partial y(k)}{\partial w_2(k)}, \cdots, \frac{\partial y(k)}{\partial w_n(k)}\right]$$

lr 表示算法的学习率.

为了更好地证明所提模型的收敛性, 对误差函数 $e(k)$ 进行泰勒展开, 可得

$$e(k+1) = e(k) + \left[\frac{\partial e(k)}{\partial \boldsymbol{\Theta}(k)}\right]^{\text{T}}\Delta\boldsymbol{\Theta}(k) + R(\boldsymbol{\Theta}(k)) \tag{22}$$

式中, $R(\boldsymbol{\Theta}(k))$ 为皮亚诺余项.

根据皮亚诺余项的性质, 可以推导得到

$$\lim_{\|\Delta\boldsymbol{\Theta}(k)\|\to 0}\frac{|R(\boldsymbol{\Theta}(k))|}{\|\Delta\boldsymbol{\Theta}(k)\|} = 0 \tag{23}$$

即存在 $\varphi > 0$, 使得 $\|\Delta\boldsymbol{\Theta}(k)\| < \varphi$ 时, $|R(\boldsymbol{\Theta}(k))| < \|\Delta\boldsymbol{\Theta}(k)\|$. 由式 (21) 可知

$$\|\Delta\boldsymbol{\Theta}(k)\| = \left\|lr \times e(k)\frac{\partial y(k)}{\partial \boldsymbol{\Theta}(k)}\right\| \tag{24}$$

所以, 当 $\|\Delta\boldsymbol{\Theta}(k)\| < \varphi$ 时, 可得

$$|R(\boldsymbol{\Theta}(k))| < lr \times |e(k)|\,\boldsymbol{\theta}^{\text{T}}\boldsymbol{\theta} \tag{25}$$

其中, $\boldsymbol{\theta} = \frac{\partial y}{\partial \boldsymbol{\Theta}(k)}$.

定理 1 给出了参数学习算法的收敛性分析.

定理 1. 若 $\|\Delta\boldsymbol{\Theta}(k)\|$ 是有界的, 且 $\left\|\frac{\partial y}{\partial \boldsymbol{\Theta}(k)}\right\|$ 也是有界的, 按照式 (21) 训练 AW-ESN 的网络参数, 则存在一个满足式 (26) 的学习率使得网络收敛.

$$lr = \frac{\text{e}^{\lambda\|\boldsymbol{\theta}\|} - \text{e}^{-\lambda\|\boldsymbol{\theta}\|}}{\text{e}^{\lambda\|\boldsymbol{\theta}\|} + \text{e}^{-\lambda\|\boldsymbol{\theta}\|}} \times \varepsilon \tag{26}$$

式中,

$$\varepsilon = \min\left\{\frac{1}{\max\limits_k\left\|\frac{\partial y(k)}{\partial \boldsymbol{\Theta}(k)}\right\|^2}, \frac{\varphi}{\max\limits_k\left\|\frac{\partial E(k)}{\partial \boldsymbol{\Theta}(k)}\right\|}\right\}$$

$\boldsymbol{\theta} = \frac{\partial y}{\partial \boldsymbol{\Theta}(k)}$, $\lambda > 0$, 由经验给定.

证明. 当学习率 lr 被选择满足式 (26), 能够推得

$$lr < \min_k\left\{\frac{\varphi}{\frac{\partial E(k)}{\partial \boldsymbol{\Theta}(k)}}\right\} \tag{27}$$

通过式 (21), 可以得到

$$\|\Delta\boldsymbol{\Theta}(k)\| = \left\|lr\frac{\partial E(k)}{\partial \boldsymbol{\Theta}(k)}\right\| < \frac{\varphi}{\left\|\frac{\partial E(k)}{\partial \boldsymbol{\Theta}(k)}\right\|} \times \left\|\frac{\partial E(k)}{\partial \boldsymbol{\Theta}(k)}\right\| = \varphi \tag{28}$$

根据式 (20) 和式 (22), 可得

$$\Delta E(k) = \frac{1}{2}e^2(k+1) - \frac{1}{2}e^2(k) = -e^2(k)\,\boldsymbol{\theta}^{\text{T}}lr\boldsymbol{\theta}\left(1 - \frac{1}{2}\boldsymbol{\theta}^{\text{T}}lr\boldsymbol{\theta}\right) + R(\boldsymbol{\Theta}(k))\left[\frac{1}{2}R(\boldsymbol{\Theta}(k)) + e(k)\left(1 - \boldsymbol{\theta}^{\text{T}}lr\boldsymbol{\theta}\right)\right] \tag{29}$$

通过式 (25), 可以推导得到

$$\Delta E(k) < -e^2(k)\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\left(1-\frac{1}{2}\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\right)+ |e(k)|\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\left[\frac{1}{2}|e(k)|\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}+e(k)\left(1-\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\right)\right] \tag{30}$$

当 $e(k)>0$, 式 (30) 可以推得

$$\Delta E(k) < -e^2(k)\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\left(1-\frac{1}{2}\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\right)+ e^2(k)\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\left[1-\frac{1}{2}\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\right] \tag{31}$$

当 $e(k)<0$, 式 (30) 可以推得

$$\Delta E(k) < 2e^2(k)\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}\left(\boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta}-1\right) \tag{32}$$

当选择的学习率 lr 满足式 (26) 时, 可以推得

$$0 < \boldsymbol{\theta}^{\mathrm{T}} lr\boldsymbol{\theta} < 1 \tag{33}$$

由式 (32) 和式 (33) 可知, 当 $e(k)<0$ 时, 可以推得

$$E(k) < 0 \tag{34}$$

通过上述推导过程可知, 根据李雅普诺夫稳定性原理, 如果选择合适的学习率, AW-ESN 的收敛性可以得到保证. □

2.3 知识与 AW-ESN 模型的融合

由于缺乏机理认知, 当数据驱动模型应用于实际工业过程, 面对复杂多变的工况时, 模型会出现泛化性能差, 从而导致预测精度下降等问题. 尽管本文已经从改善建模数据质量和提出新的训练算法两个方向上开展了一定的工作, 力求实现模型预测性能的提升. 但是由于样本的特征量多, 工业过程的数据波动仍会对模型预测性能的稳定性造成干扰. 机理分析和专家经验能够反映烧结过程的本质规律, 因此, 通过对烧结过程机理进行分析, 将过程数据中包含的专家知识与数据驱动模型相结合, 能够有效弥补数据驱动模型缺失的过程信息. 根据上述问题和解决策略, 本节基于过程数据中提取得到的 FeO 含量等级知识, 将提取得到的知识与 AW-ESN 融合, 建立 DK-AWESN 模型, 从而减少复杂工况造成的模型泛化性能下降.

如图 5 所示, 在 DK-AWESN 中, 烧结过程的专家知识被用于改进输出层中的激活函数 $f_{\mathrm{out}}(\cdot)$. 基于料层温度分布特征和专家经验获取的 FeO 等级知识用于构建新的激活函数 $g(\cdot)$, 从而取代原本激活函数 $f_{\mathrm{out}}(\cdot)$. $g(\cdot)$ 的表达式为

$$g(\cdot)=\begin{cases}\alpha \mathrm{e}^{y-k_{g_1}}+k_{g_1}, & y<k_{g_1}\\ y, & k_{g_1}\le y\le k_{g_2}\\ -\alpha \mathrm{e}^{-y+k_{g_2}}+k_{g_2}, & y>k_{g_2}\end{cases} \tag{35}$$

式中, y 表示模型的输出; k_{g_1}, k_{g_2} 分别表示根据专家知识得到的 FeO 含量等级的下限值和上限值; α 表示等级系数, 在本文中取值为 0.5.

通过上述融合策略, 机理知识被融入到 AW-ESN 的输出激活函数中, 改进后的激活函数由于融入了基于过程机理划分的 FeO 等级知识, 能够有效地降低由于工况波动造成的模型预测结果过高或者过低的现象. 由改进的激活函数 $g(\cdot)$ 可以看出, 当预测结果超出专家知识划分的等级范围时, 模型能够综合专家知识和预测结果, 将最终的预测值调整回到正确的范围, 从而减少预测误差、提升预测精度.

3 实例验证

为验证所提方法的有效性, 本文采用我国华南地区某钢铁集团 3#烧结厂数据中心 2019 年 1 月 1 日 ~ 2019 年 10 月 30 日记录的生产数据进行仿真实验. 表 4 中列出了模型的输入变量, 确定输入变量后, 依据基于核函数高维映射的多尺度数据配准方法构建了建模的样本集. 利用箱线图法剔除了异常值后, 获得了 800 个样本, 其中 740 个样本作为训练集, 60 个样本作为测试集. 为避免输入变量量纲不同导致的建模样本集构建不合理, 输入变量归一化到 [–1, 1] 之间. 为更好地展示所提模型在动态的烧结过程建模上的优势, DK-ESN、AW-ESN 以及 ESN 模型被用于与所提模型进行实例比较验证.

为更直观地对模型预测性能进行比较, 选择多次实验的测试集平均命中率 (Hit rate, HR) 以及平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean square error, RMSE) 等标准统

表 4 模型输入变量

Table 4 The input variables of the model

序号	变量名称	序号	变量名称
1	风箱废气温度	9	空支流量
2	烧结机机速	10	C_{MgO}
3	料层高度	11	透气性
4	烧结终点	12	返矿比
5	C_{SiO_2}	13	风箱负压
6	碱度	14	燃料配比
7	环冷机速度	15	点火温度
8	煤支流量		

计指标作为定量评估模型性能的指标. 上述指标的计算式为

$$\begin{cases} RMSE = \sqrt{\dfrac{1}{n}\sum\limits_{k=1}^{n} err_k^2} \\ MAE = \dfrac{1}{n}\sum\limits_{k=1}^{n} |err_k| \\ HR = \dfrac{\sum\limits_{k=1}^{n} H_k}{n} \times 100\%, \quad H_k = \begin{cases} 1, & |err_k| \le 0.4 \\ 0, & \text{其他} \end{cases} \end{cases} \tag{36}$$

式中, $err_k = y(k) - \hat{y}^{(k)}$, $y(k)$ 和 $\hat{y}(k)$ 分别表示 FeO 含量的检测值和预测值; n 表示测试样本个数; 考虑到过程数据存在噪声干扰, 本文将允许误差定为 0.4 以内. 为研究储备池规模对模型预测性能的影响, 本文选择了不同大小的储备池参数用于测试所提 DK-AWESN 模型. 对于不同储备池参数, 分别进行 30 次独立仿真, 并对结果进行统计, 统计结果如表 5 所示. 表中, NRMSE 表示多次仿真结果 RMSE 的均值. 从表 5 可以看出, 当储备池神经元个数为 200 时, 模型的预测效果最好. 最终得到模型的参数为储备池神经元数 $N = 200$, 谱半径 $\rho = 0.88$, 稀疏度 $SD = 5\%$.

表 5　储备池规模对 DK-AWESN 性能的影响

Table 5　Influence of reservoir size on the performance of DK-AWESN

储备池规模	训练时间 (s)	测试 NRMSE	
		平均值	标准差
50	21.821	0.425	0.0332
100	21.832	0.371	0.0258
150	21.840	0.332	0.0254
200	21.841	0.301	0.0218
250	21.850	0.343	0.0262
300	21.864	0.399	0.0246
350	21.866	0.435	0.0321
400	21.891	0.482	0.0326

为提升模型的预测精度, 本文提出一种基于梯度的权重调整策略, 建立了 AW-ESN. 为更直观地展示所提 AW-ESN 相较于 ESN 在 FeO 含量预测上的优越性, 图 6 展示了本文所提出的 AW-ESN 与 ESN 在同一个测试集上的预测结果. 从图 6 中可以看出, AW-ESN 相较于 ESN 具有更好的跟踪性能, 在工况出现波动时, 如 12、13、26、27、28 样本点, AW-ESN 均能实现较好的预测效果, 而

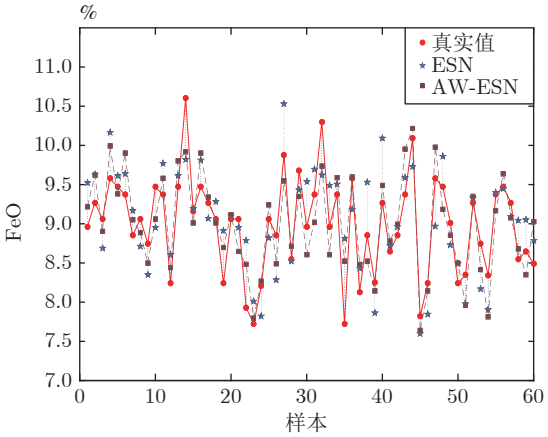

图 6　ESN 和 AW-ESN 预测值与实际值对比

Fig. 6　Comparison between predicted values and actual values of ESN and AW-ESN

ESN 在第 27 个样本点处出现了较大的预测误差. 虽然当工况出现波动时, AW-ESN 的预测误差相较于工况平稳时也增加了, 但是 AW-ESN 仍然能够较好地跟踪实测值的变化趋势, 展示了更好的预测性能.

针对数据驱动模型缺乏机理知识致使模型泛化性能差的问题, 本文将机理知识融入 AW-ESN, 提出了 DK-AWESN. 为验证融入机理知识对模型预测性能的提升, 图 7 和图 8 分别展示了 AW-ESN 和 DK-AWESN、ESN 和 DK-ESN 在同一个测试集上的预测结果. 从图 7 和图 8 可以看出, DK-ESN 和 DK-AWESN 由于融入了基于过程机理划分的 FeO 等级知识, 能够有效地降低由于工况波动造成的模型预测结果过高或者过低的现象. 当 FeO 含量偏高或者偏低时, 模型预测结果与实测值之间易出现较大偏差, 在这种情况下, 相较于 ESN 和 AW-ESN, DK-ESN 和 DK-AWESN 能够将预测结果调整回到正确的范围内, 从而减少预测误差、提升预测精度. 当工况平稳, 预测模型预测效果较好时, 融入机理知识也不会对原本的预测效果造成影响, 从而保证工况平稳期的预测精度. 根据上述分析可知, 融入烧结过程机理知识后的数据模型能够在保证工况平稳期模型预测精度的同时, 兼顾工况波动期模型预测值跟踪实测值变化趋势的能力, 避免出现预测值大幅度偏离实测值的状况, 实现模型预测性能的提升.

通过上述实验结果与分析可知, 所提 DK-AWESN 在 FeO 含量预测上展现出良好的预测性能. 为进一步比较各模型的预测效果, 图 9 展示了各模型的预测误差, 预测误差越小说明预测性能越好. 从图 9 中可以看出, 所提 DK-AWESN 的预测误差相较于

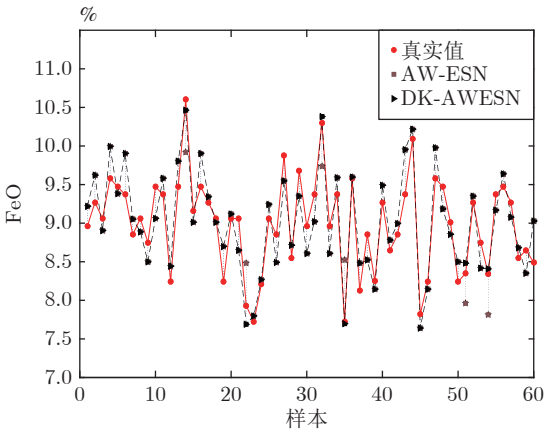

图 7 AW-ESN 和 DK-AWESN 预测值与实际值对比

Fig. 7 Comparison between predicted values and actual values of AW-ESN and DK-AWESN

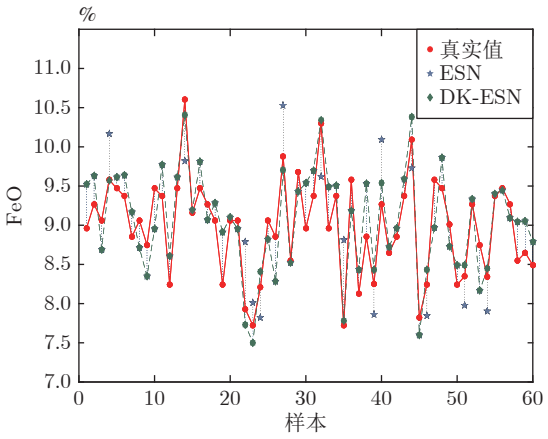

图 8 ESN 和 DK-ESN 预测值与实际值对比

Fig. 8 Comparison between predicted values and actual values of ESN and DK-ESN

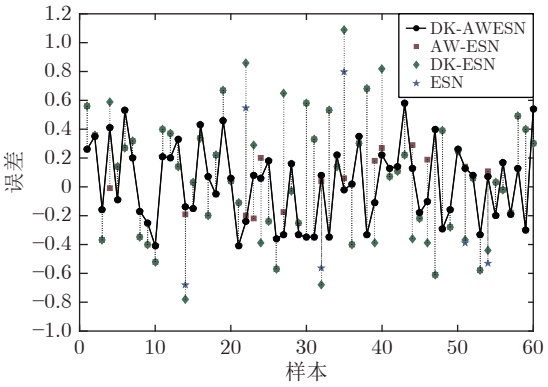

图 9 不同方法的预测误差对比

Fig. 9 Comparison of prediction errors of different methods

另外三种方法较小, 预测误差的波动也更稳定, 说明本文所提方法面对复杂的烧结工况具有更好的泛化性能. 当工况波动较大时, 所提方法的预测误差也会显著增加, 但是相较于其他几种方法, 本文所提 DK-AWESN 受到过程数据波动的影响更小, 预测性能更好.

为进一步比较不同模型的预测性能, 图 10 绘制了不同方法得到的 FeO 含量预测值和实测值的散点图. 从图 10 中可以看出, 所提 DK-AWESN 的圆形散点的分布更接近对角线, 而当预测值和实测相等时, 散点会处于对角线上, 因此说明所提 DK-AWESN 模型得到的预测结果与实测值更接近. 虽然仍然存在少数点偏离对角线, 但与 ESN 和 AW-ESN 相比, DK-AWESN 能够较好地跟踪实测值的变化.

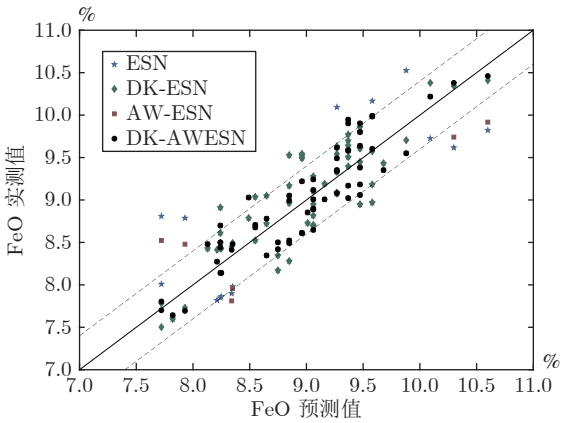

图 10 不同方法预测值和实测值的散点图

Fig. 10 Scatter plot of predicted values and measured values by different methods

表 6 列出了上述预测模型的预测结果评价指标, 从表 6 数据可以看出, AW-ESN 和 DK-ESN 的预测性能相较于 ESN 都有明显的提升, 而 DK-AWESN 的综合预测性能是最好的, 相较 ESN 而言, 在测试集上的预测命中率有较大幅度的提升, 达到了 86.67%. 相较 AW-ESN 而言, 平均测试命中率提升了 8.34%, 平均绝对误差降低了 0.047, 均方根误差减少了 0.044. 通过以上实验及其分析证明, 所提 DK-AWESN 方法通过将 FeO 等级知识融入 AW-ESN 使得预测值的波动区间减小, 一定

表 6 各模型的预测性能指标比较

Table 6 Comparison of prediction performance indicators for different algorithms

性能指标	ESN	DK-ESN	AW-ESN	DK-AWESN
MAE	0.351	0.254	0.298	0.251
RMSE	0.420	0.316	0.345	0.301
HR (%)	70.00	83.33	78.33	86.67

程度上避免了由于缺乏机理认知导致模型泛化能力差的问题. 采用所提方法建立的模型的精度和泛化性能相较于另外三种数据驱动模型得到了增强, 能够较好地进行实际工程应用.

4 结束语

本文提出了一种基于知识与 AW-ESN 融合 (DK-AWESN) 的烧结矿 FeO 含量预测方法. 在所提 DK-AWESN 中, 过程传热机理和专家经验中提取得到的知识与 AW-ESN 相结合, 实现了良好的 FeO 含量预测性能. 工业验证表明, 本文所建模型的命中率可达到 86.67%, 模型预测精度受过程变量波动影响较小, 具有较好的泛化能力和建模精度. 通过统计分析, 利用均方根误差、命中率等统计指标对所提预测模型和其他数据驱动模型的预测精度进行对比. 结果表明, 所提方法有效提升了模型在复杂工况下的预测精度, 能够为烧结现场操作人员提供更可靠的信息, 从而提高烧结过程的调控能力和现场操作人员的操作准确率, 对实现烧结过程的稳定控制、提升烧结矿质量具有重要作用.

References

1 Usamentiaga R, García D F, Molleda J, Bulnes F G, Orgeira V G. Temperature tracking system for sinter material in a rotatory cooler based on infrared thermography. *IEEE Transactions on Industry Applications*, 2014, **50**(5): 3095−3102

2 Li Y X, Yang C J, Sun Y X. Dynamic time features expanding and extracting method for prediction model of sintering process quality index. *IEEE Transactions on Industrial Informatics*, 2022, **18**(3): 1737−1745

3 Fernández-González D, Ruiz-Bustinza I, Mochón J, González-Gasca C, Verdeja L F. Iron ore sintering: Process. *Mineral Processing and Extractive Metallurgy Review*, 2017, **38**(4): 215−227

4 Fernández-González D, Ruiz-Bustinza I, Mochón I, González-Gasca C, Verdeja L F. Iron ore sintering: Raw materials and granulation. *Mineral Processing and Extractive Metallurgy Review*, 2017, **38**(1): 36−46

5 Huang Z C, Yi L Y, Jiang T, Zhang Y B. Hot airflow ignition with microwave heating for iron ore sintering. *ISIJ International*, 2012, **52**(10): 1750−1756

6 Li Wen-Peng, Zhou Ping. Robust regularized RVFLNs modeling of molten iron quality in blast furnace ironmaking. *Acta Automatica Sinca*, 2020, **46**(4): 721−733
(李温鹏, 周平. 高炉铁水质量鲁棒正则化随机权神经网络建模. 自动化学报, 2020, **46**(4): 721−733)

7 Chen X X, Shi X H, Lan T. A semi-supervised linear-nonlinear prediction system for tumbler strength of iron ore sintering process with imbalanced data in multiple working modes. *Control Engineering Practice*, 2021, **110**: Article No. 104766

8 Umadevi T, Karthik P, Mahapatra P C, Prabhu M, Ranjan M. Optimisation of FeO in iron ore sinter at JSW steel limited. *Ironmaking and Steelmaking*, 2012, **39**(3): 180−189

9 Liao Ji-Yong, He Guo-Qiang. Progress and development of sintering technologies during the last five years. *Sintering and Pelletizing*, 2018, **43**(5): 1−11
(廖继勇, 何国强. 近五年烧结技术的进步与发展. 烧结球团, 2018, **43**(5): 1−11)

10 Kawaguchi T, Sato S, Takata K. Development and application of an integrated simulation model for iron ore sintering. *Iron Making Proceeding*, 1987, **73**(15): 1940−1947

11 Yamaoka H, Kawaguchi T. Development of a 3-D sinter process mathematical simulation model. *ISIJ International*, 2005, **45**(4): 522−531

12 Wang Yue-Xiang. *Sinter and Pellet Production*. Beijing: Metallurgical Industry Press, 2006.
(王悦祥. 烧结矿与球团矿生产. 北京: 冶金工业出版社, 2006.)

13 Jiang Z H, Guo Y H, Pan D, Gui W H, Maldague X. Polymorphic measurement method of FeO content of sinter based on heterogeneous features of infrared thermal images. *IEEE Sensors Journal*, 2021, **21**(10): 12036−12047

14 Wu C, Wang F B, Chen X Z, Hou Q W, Chen Z K, Zhang M, et al. RGB color decomposition and image feature extraction of flame image in rear of sintering machine. In: Proceedings of the 36th Chinese Control Conference. Dalian, China: IEEE, 2017. 5640−5463

15 Zhou Yu-Run. The Research on Online Evaluation System for Sintering Quality Grade Based on Tail Section Image and Bellows Temperature [Master thesis], Anhui University, China, 2013.
(周雨润. 基于机尾断面图像和风箱温度的烧结质量等级在线评测系统的研究 [硕士学位论文], 安徽大学, 中国, 2013.)

16 Zhou H, Zhang H F, Yang C J. Hybrid-model-based intelligent optimization of ironmaking process. *IEEE Transactions on Industrial Electronics*, 2020, **67**(3): 2469−2479

17 Du S, Wu M, Chen L F, Zhou K L, Hu J, Cao W H, et al. A fuzzy control strategy of burn-through point based on the feature extraction of time-series trend for iron ore sintering process. *IEEE Transactions on Industrial Informatics*, 2020, **16**(4): 2357−2368

18 Zhou Ping, Zhang Li, Li Wen-Peng, Dai Peng, Chai Tian-You. Autoencoder and PCA based RVFLNs modeling for multivariate molten iron quality in blast furnace ironmaking. *Acta Automatica Sinica*, 2018, **44**(10): 1799−1811
(周平, 张丽, 李温鹏, 戴鹏, 柴天佑. 集成自编码与 PCA 的高炉多元铁水质量随机权神经网络建模. 自动化学报, 2018, **44**(10): 1799−1811)

19 Zhang Shu, Gao Wei-Min. Application of neural networks in the prediction of sinter quality. *Sintering and Pelletizing*, 2001, **26**(4): 6−10
(张舒, 高为民. 人工神经网络在烧结矿指标预测中的应用. 烧结球团, 2001, **26**(4): 6−10)

20 Laitinen P J, Saxén H. A neural network based model of sinter quality and sinter plant performance indices. *Ironmaking and Steelmaking*, 2007, **34**(2): 109−114

21 Yuan Zhi-Qiang. Study on Prediction Modeling of the Sinter Chemical Component Based on Deep Learning [Master thesis], Wuhan University of Science and Technology, China, 2018.
(袁致强. 基于深度置信网络的烧结矿化学成分预测模型研究 [硕士学位论文], 武汉科技大学, 中国, 2018.)

22 Jiang Zhao-Hui, Xu Chuan, Gui Wei-Hua, Jiang Ke. Prediction method of hot metal silicon content in blast furnace based on optimal smelting condition migration. *Acta Automatica Sinica*, 2022, **48**(1): 194−206
(蒋朝辉, 许川, 桂卫华, 蒋珂. 基于最优工况迁移的高炉铁水硅含量预测方法. 自动化学报, 2022, **48**(1): 194−206)

23 Li Ze-Long, Yang Chun-Jie, Liu Wen-Hui, Zhou Heng, Li Yu-Xuan. Research on hot metal Si-content prediction based on LSTM-RNN. *CIESC Journal*, 2018, **69**(3): 992−997
(李泽龙, 杨春节, 刘文辉, 周恒, 李宇轩. 基于 LSTM-RNN 模型的铁水硅含量预测. 化工学报, 2018, **69**(3): 992−997)

24 Wu Gao-Chang, Liu Qiang, Chai Tian-You, Qin S. Joe. Abnormal condition diagnosis through deep learning of image sequences for fused magnesium furnaces. *Acta Automatica Sinica*, 2019, **45**(8): 1475−1485
(吴高昌, 刘强, 柴天佑, 秦泗钊. 基于时序图像深度学习的电熔镁

炉异常工况诊断. 自动化学报, 2019, **45**(8): 1475−1485)

25 Fang Y J, Jiang Z H, Pan D, Gui W H, Chen Z P. Soft sensors based on adaptive stacked polymorphic model for silicon content prediction in ironmaking process. *IEEE Transactions on Instrumentation and Measurement*, 2021, **70**: Article No. 2503412

26 Wang Lei, Qiao Jun-Fei, Yang Cui-Li, Zhu Xin-Xin. Pruning algorithm for modular echo state network based on sensitivity analysis. *Acta Automatica Sinica*, 2019, **45**(6): 1136−1145
(王磊, 乔俊飞, 杨翠丽, 朱心新. 基于灵敏度分析的模块化回声状态网络修剪算法. 自动化学报, 2019, **45**(6): 1136−1145)

27 Jiang Tao. *Principle and Technology of Agglomeration of Iron Ores*. Changsha: Central South University Press, 2016.
(姜涛. 铁矿造块学. 长沙: 中南大学出版社, 2016.)

28 Yao X S, Wang Z S. Broad echo state network for multivariate time series prediction. *Journal of Franklin Institute*, 2019, **356**(9): 4888−4906

方怡静 中南大学自动化学院博士研究生. 2016 年和 2019 年分别获得中南大学学士学位和硕士学位. 主要研究方向为数据驱动的工业过程建模和控制, 工业过程数据分析和机器学习.
E-mail: yijingfang@csu.edu.cn
(**FANG Yi-Jing** Ph.D. candidate at the School of Automation, Central South University. She received her bachelor and master degrees from Central South University in 2016 and 2019, respectively. Her research interest covers data-based modeling and control of industrial process, industrial process data analysis, and machine learning.)

蒋朝辉 中南大学自动化学院教授. 2011 年获得中南大学博士学位. 主要研究方向为光电信息感知与图像处理, 人工智能与工业虚拟现实, 智能优化控制. 本文通信作者.
E-mail: jzh0903@csu.edu.cn
(**JIANG Zhao-Hui** Professor at the School of Automation, Central South University. He received his Ph.D. degree from Central South University in 2011. His research interest covers photoelectric information perception and image processing, artificial intelligence and industrial virtual reality, and intelligent optimization control. Corresponding author of this paper.)

黄 良 中南大学自动化学院硕士研究生. 主要研究方向为工业过程建模与优化控制.
E-mail: huangliangcsu@163.com
(**HUANG Liang** Master student at the School of Automation, Central South University. His main research interest is modeling and optimal control of industrial process.)

桂卫华 中国工程院院士, 中南大学自动化学院教授. 1981 年获得中南矿冶学院硕士学位. 主要研究方向为复杂工业过程建模, 优化与控制应用, 故障诊断与分布式鲁棒控制.
E-mail: gwh@outlook.com
(**GUI Wei-Hua** Academician of Chinese Academy of Engineering, and professor at the School of Automation, Central South University. He received his master degree from Central South Institute of Mining and Metallurgy in 1981. His research interest covers complex industrial process modeling, optimization and control applications, fault diagnosis, and distributed robust control.)

潘 冬 中南大学自动化学院讲师. 2021 年获得中南大学控制科学与工程专业博士学位. 主要研究方向为红外机器视觉, 图像处理, 工业过程检测和控制.
E-mail: panda@csu.edu.cn
(**PAN Dong** Lecturer at the School of Automation, Central South University. He received his Ph.D. degree in control science and engineering from Central South University in 2021. His research interest covers infrared computer vision, image processing, and detection and control in industrial process.)