

控制与决策

Control and Decision

复杂工业过程特征建模方法及应用研究

乔俊飞, 黄卫民, 丁海旭, 于涛

引用本文:

乔俊飞, 黄卫民, 丁海旭, 于涛. 复杂工业过程特征建模方法及应用研究[J]. 控制与决策, 2023, 38(8): 2063–2078.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0370>

您可能感兴趣的其他文章

Articles you may be interested in

[基于稀疏化神经网络的浮选泡沫图像特征选择](#)

Selection method for froth image characters based on sparse neural network

控制与决策. 2021, 36(7): 1627–1636 <https://doi.org/10.13195/j.kzyjc.2019.1788>

[基于马尔可夫过程的多部件系统劣化状态空间划分模型](#)

Multi-component system state space partition model based on Markov process

控制与决策. 2021, 36(2): 418–428 <https://doi.org/10.13195/j.kzyjc.2019.0480>

[面向工业软测量应用的定制化生成对抗数据填补模型](#)

Customized generative adversarial data imputation model for industrial soft sensing

控制与决策. 2021, 36(12): 2929–2936 <https://doi.org/10.13195/j.kzyjc.2020.0974>

[车辆跟随控制策略的状态可达集建模及验证方法](#)

A modeling and verification method of state reachable set for vehicle following control strategy

控制与决策. 2021, 36(7): 1679–1685 <https://doi.org/10.13195/j.kzyjc.2019.1562>

[基于核典型相关性-熵成分分析的工业过程质量监测方法](#)

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

复杂工业过程特征建模方法及应用研究

乔俊飞^{1,2†}, 黄卫民^{1,2}, 丁海旭^{1,2}, 于涛^{1,2}

(1. 北京工业大学 信息学部, 北京 100124; 2. 智慧环保北京实验室, 北京 100124)

摘要: 针对复杂工业过程的特征建模是研究其优化控制的基础. 复杂工业过程普遍具有强干扰、非线性、大时变等诸多不确定性特征, 部分工艺涉及复杂的生化反应并伴有强污染和高危性, 检测数据具有维度高、噪声大等特性, 这均为建立精准的工业模型提出了更迫切的需求和更高的标准. 鉴于此, 总结并归纳当前复杂工业过程的建模思路和研究进展, 旨在从多个视角分析不同建模方法的适用性和有效性, 为先进的优化控制理论指导实际工业生产奠定模型基础. 首先, 从机理建模、数据驱动建模和混合建模 3 个方面对目前主流的工业建模方法进行划分和综述; 然后, 阐述各类建模方法的具体设计思路, 并分析模型结构和算法特点; 接着, 调研不同建模策略在解决实际工业过程中的指标建模、被控对象建模、全流程建模等问题的具体应用情况; 最后, 结合目前工业智能化建设趋势及其面临的挑战性问题, 指出未来的研究思路和发展方向.

关键词: 复杂工业过程; 特征建模; 不确定性特征; 指标模型; 被控对象模型; 全流程模型

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.0370

引用格式: 乔俊飞, 黄卫民, 丁海旭, 等. 复杂工业过程特征建模方法及应用研究[J]. 控制与决策, 2023, 38(8): 2063-2078.

Research on feature modeling method for complex industrial process and its application

QIAO Jun-fei^{1,2†}, HUANG Wei-min^{1,2}, DING Hai-xu^{1,2}, YU Tao^{1,2}

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 2. Beijing Laboratory of Smart Environmental Protection, Beijing 100124, China)

Abstract: Feature modeling for complex industrial processes is the basis for studying their optimal control. Complex industrial processes generally have uncertain characteristics such as strong interference, nonlinearity, and large time-varying. Some of the processes involve complex biochemical reactions with strong contamination and high risk, and the detection data is highly dimensional and noisy, which all put forward more urgent needs and higher standards for the establishment of accurate industrial models. This paper summarizes the current modeling ideas and research progress of complex industrial processes, and aims to analyze the applicability and effectiveness of different modeling methods from multiple perspectives, so as to lay the modeling foundation for the advanced optimal control theory to guide the actual industrial production. First, the main industrial modeling methods are divided and summarized from three aspects: mechanism modeling, data-driven modeling and hybrid modeling. Second, the specific design ideas of various modeling methods are described, and the model structure and algorithm characteristics are analyzed. Then, the specific applications of different modeling strategies in solving the problems of index modeling, controlled object modeling, and full-scale modeling in the actual industrial processes are investigated. Finally, combined with the current trend of industrial intelligent construction and its challenging problems, the future research ideas and development directions are pointed out.

Keywords: complex industrial process; feature modeling; uncertain characteristic; index model; controlled object model; full-scale model

0 引言

特征建模是研究优化控制的基础, 尤其是面向一些不可间断且具有高危、高污染的复杂工业过程, 建

立可靠准确的对象模型是验证先进智能控制策略有效性并保障其落地应用的基础. 为了使得领域的研究学者和技术工作者对现有建模方法具有全面清

收稿日期: 2023-03-29; 录用日期: 2023-05-29.

基金项目: 科技创新 2030—“新一代人工智能”重大项目(2021ZD0112300); 国家自然科学基金创新群体项目(62021003); 国家科技重大专项项目(61890930); 国家自然科学基金项目(62073006).

责任编辑: 郭戈.

†通讯作者. E-mail: adqiao@bjut.edu.cn.

晰的了解,本文对复杂工业过程的特征建模研究进行综述,旨在实现:1)为机理建模、数据驱动建模以及混合建模在复杂工业过程中的发展提供系统和全面的概述;2)以典型复杂工业过程为例,从指标模型、被控对象模型、全流程模型等方面概述各类建模方法应用现状,并分析在不同应用环境下的适用性和面临的挑战;3)从复杂工业过程的特点出发,对其建模方法的发展趋势进行展望,对亟待解决的关键问题进行分析,并指出未来的研究方向。

复杂工业涉及能源、化工、冶金、加工制造和资源回收等多个国民支柱产业,是保障国家产业链供应链完整和经济稳定发展的关键。在当前国际环境复杂多变、不确定性因素增长和地缘冲突加剧的背景下,各国对本国工业发展日益重视^[1-3]。复杂工业过程普遍具有强干扰、非线性、大时变等诸多不确定性特征,对其过程分析是一项复杂且繁重的工作,这也为特征建模工作带来了诸多挑战^[4-5]。近年来,国内外学者围绕此类问题开展了大量研究,并取得了丰硕成果。根据设计思路,可将现有工业过程模型分为机理模型(白箱模型)、数据驱动模型(黑箱模型)以及混合模型(灰箱模型)。

机理模型也称为第一性原理模型,其主要是根据基本的物化定律,结合工业过程中涉及的动力学、热力学以及材料性质等推导建立的模型^[6]。机理模型能够清晰地描述工艺过程,其形式一般为常微分或偏微分方程组^[7],相关参数具有明确的物理意义,过程变量具有可解释性,可根据过程分析模型结果^[8]。然而,由于复杂工业过程通常包含多个工艺环节,数学规律推导复杂^[9-10]。

数据驱动模型以实际工业过程数据为建模基础,通过提取数据中的有效信息,建立能够表征工业过程的模型,其对于实际工业过程的分析需求较低,且具有灵活性,已在工业过程中获得实际应用^[11-12]。然而,由于实际采集的工业数据通常存在强噪声、大时滞、高维度等问题,这就对依赖数据质量的建模方法提出了巨大的挑战。此外,由于数据驱动模型的黑箱属性,其缺乏对工艺过程的分析,模型可解释性较低且不具备工艺特征的物理意义,外推性也较差^[13]。

混合模型将机理分析与数据驱动相结合,通过取长补短,使得模型在具有可解释性的同时,避免了对部分繁杂工艺过程的推导。与机理模型相比,混合模型可有效降低复杂工业过程的建模难度,采用数据驱动取代部分参数未知或边界难以确定的工艺过程,降低了机理分析的难度^[14];与数据驱动模型相比,混合

模型的结构和参数具有实际的物理意义,能够更有针对性地与优化控制方法相结合^[15]。针对不同复杂工业过程的特点,混合模型通过不同的机理与数据驱动组合方式实现对模型性能的提升。

综上所述,本文从不同类型的建模方法和实际应用出发,对近年来复杂工业过程的建模研究展开综述。本文的主要内容如下:首先,介绍3种建模策略的主要方法和实现方式,并针对不同建模方案的优缺点进行深入探讨,归纳模型的核心设计思想和特性,明确现有解决思路下面临的挑战;然后,根据实际建模需求,从具体应用层面调研不同建模方法的应用现状,并分析其建模方法的适用性;最后,讨论目前复杂工业建模中存在的重大问题,并对未来的研究方向提出建议。

1 面向复杂工业过程的建模策略

本节针对面向复杂工业过程的机理模型、数据驱动模型、混合模型的建模方案展开描述,三者间的关系如图1所示。




图1 机理模型、数据驱动模型以及混合模型的关系

1.1 机理模型

机理模型具有清晰的数学表达,可获得工艺环节的中间变量关系,这更益于在此模型的基础上进一步开展优化控制策略的研究工作。本节以城市固废焚烧(municipal solid waste incineration, MSWI)、污水处理(wastewater treatment, WWT)和高炉炼铁(blast furnace ironmaking, BFI)等复杂工业过程为例,对其机理建模过程描述如下。

1) 基于数学分析的机理模型。

基于数学分析的机理模型通常依据物质和能量守恒定律将工业过程涉及的物理化学过程用严谨的数学表达进行描述,具有明确的变量定义和详细的推导过程。Yang等^[16]构建了一种数学模型用于描述基于移动炉排的MSWI过程,该研究包括了对燃烧过程中涉及的水分蒸发、挥发分析及燃烧、固定碳氧化等过程的分析,并从气相和固相两个方面分别给出了MSWI过程所涉及的热力学方程。与之类似,Zhou等^[17]针对固定床型的MSWI过程进行了研究,建立了基于物质能量平衡的数学模型。Wu等^[18]基于化学

反应动力学方程构建了BFI过程的机理模型,该模型确立了 O_2 、 CO_2 、 CO 和 H_2O 等物质的质量变化关系以及相关的能量转化关系.与MSWI和BFI过程不同,WWT的机理模型经过多年的研究,已逐步建成了技术成熟的基准模型.由国际水协会和欧盟科学技术合作组织共同开发的基准仿真模型(benchmark simulation model no.1, BSM 1)^[19]已在WWT相关研究中获得广泛认可. BSM 1采用多个反应步骤描述有机物降解过程和厌氧消化过程,采用动态平衡过程描述微生物的生长和死亡以及污泥沉降速度和污泥颗粒大小分布. BSM 1通过推导WWT过程中的生物、化学和物理过程,进而计算出WWT过程中的污染物去除效率、污泥产生量、能耗等重要参数.

2) 基于仿真软件开发的机理模型.

随着计算机科学的发展,一些专业软件为复杂工业过程建模提供了更多的解决方案.计算流体力学(computational fluid dynamic, CFD)软件能够模拟和

分析流体流动、传热和化学反应等现象,其具有建模范围广和可视化效果好等优势,已获得了部分实际应用. Wissing等^[20]使用CFD软件对MSWI过程进行了建模,该模型将机理分析结果与CFD软件相结合,建立了基于离散元法的CFD仿真模型,如图2所示,最后,根据所建立的模型分析了固废分布、炉排和炉膛结构等因素对焚烧效果的影响. Cho等^[21]基于CFD软件建立了泵送循环式光生物反应器的耦合光生物反应运输模型,该模型包括流体动力计算、生物动力学计算、解算器设计以及CFD不确定性传播等方面,实验结果表明,该模型能够在不确定性条件下优化泵送循环式光生物反应器的流量和生物氢生产率. Merten等^[22]将BFI过程中不同时间尺度上的流动效应、能量传输、碳溶解与高炉出铁过程间的相互作用集合至数值模拟,采用CFD软件建立了三维炉膛多相流模型,该模型考虑了热金属、炉渣和气体流动以及能量和碳的附加标量场.




图2 不同炉膛温度下MSWI过程的CFD仿真模型^[20]

虽然机理模型具有清晰的数学表达,且具有一定的通用性,但是,其建立过程中涉及多学科交叉知识,需要确定多种参数,消耗高昂的人力和时间成本.而基于CFD软件的数值仿真技术计算量大,其本质仍然为对工艺过程的定量计算,主要为流体力学过程提供专业计算和可视化仿真结果,通常用于工程规划的可行性分析或工艺结构设计,难以直接与在线动态优化控制策略相结合.目前,复杂工业过程机理建模方法面临的主要挑战为关键变量检测成本高或检测缺失、部分工艺环节的数学分析困难.当前的主要解决方案为对工艺过程的理想化假设和近似替代.以MSWI过程为例:一方面,由于无法实时准确地测量

废物的成分和热值,仅能够依据工厂长期处理的经验结果进行替代;另一方面,由于炉内燃烧过程的复杂性,许多工艺环节难以进行精确的定量计算,仅能够使用近似的简化过程替代.这导致机理模型难以与实际工业过程吻合,模型准确率较低.

1.2 数据驱动模型

数据驱动模型以实际采集的工业运行数据为基础,从中挖掘输入输出间的联系和规律,进而构建能够替代或预测实际工业过程的特征模型.数据驱动模型通常不需要对工艺过程进行深入分析,而是通过统计学或机器学习的方式提取出有用的信息和知识,帮助理解和预测结果.数据驱动建模方法包括统计

方法和机器学习方法。

1.2.1 统计方法

统计模型是包含关于样本数据假设的数学模型,其通常以较理想化的形式表示数据生成过程。统计模型的代表方法为线性回归(linear regression, LR)和时间序列分析(time series analysis, TSA)方法。

1) 线性回归。

LR是分析因变量与一个或多个独立变量间线性关系的统计方法。通常可引入多项式、自然对数等激活函数以扩展LR的适用性,增强其解决非线性问题的能力。

LR的主要优点为简单易懂,单个变量对预测结果的贡献可直接从权重矩阵中获取。然而,LR的预测性能过于依赖激活函数的选择,使其在复杂工业过程中难以应用。此外,输入特征的多元线性对LR的结果影响较大。因此,近年来仅使用LR方法用于复杂工业过程的建模研究鲜有报道。

2) 时间序列分析。

TSA是一种基于随机过程理论和数理统计学的动态数据处理统计方法,其主要研究随机数据序列所遵从的统计规律,一般用于系统描述、系统分析、结果预测等。

常用的TSA方法为自回归移动平均模型及其变种模型,其基础数学表达式为

$$y_t = c + \epsilon + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{i=1}^q \theta_i \epsilon_{t-i}. \quad (1)$$

其中: ϕ 为自回归权值, θ 为移动平均权值, ϵ 为白噪声, c 为常数, p 和 q 为自回归和移动平均模型阶数。

TSA在部分具有时间序列特性的流程工业具有实际应用,以BFI过程为例,铁水温度和成分是评价铁水质量的重要指标且受先前时刻结果的影响。为了实现铁水质量的实时预测,Östermark等^[23]提出了一种向量自回归移动平均模型,预测BFI过程中铁水的硅含量和温度。TSA模型考虑了当前输出与先前输出的关联度。然而,对于噪声大、时滞不确定、真值难以实时检测的工业过程,TSA存在一定局限性。此外,如何确定合适模型阶数也是TSA的建模难点。

1.2.2 机器学习方法

针对不同的工业过程,可采用不同的学习器或多类学习器的组合方案解决实际问题。按照模型结构可将基于机器学习方法的数据驱动建模方案分为单个学习器建模策略、集成学习建模策略以及多学习器组合建模3种类型,下面分别对其展开描述。

1) 单个学习器建模策略。

单个学习器建模就是使用独立的学习器进行特征建模,其特点是计算量小,灵活性高,适用于对模型在线更新速度要求高或工况较简单的工业过程。本节以人工神经网络(artificial neural network, ANN)、支持向量机(support vector machine, SVM)和决策树(decision tree, DT)等算法为例进行分析。

① 基于ANN的数据驱动模型。

ANN种类繁多且各具特点,其对非线性系统的逼近能力是建立复杂工业过程模型的基础。Sun等^[24]设计了一种改进的长短期记忆(long short term memory, LSTM)网络,并将其应用于MSWI过程中的氧浓度预测,模型使用加权的主成分分析(principal component analysis, PCA)以降低模型的复杂度,并结合粒子群优化(particle swarm optimization, PSO)算法优化网络参数以提高模型的泛化能力。Yang等^[25]提出了一种基于稀疏递归最小二乘算法的在线序列回声状态神经网络,用于预测WWT过程中的氨氮($\text{NH}_4\text{-N}$)浓度,在确保预测精度的同时能够获得紧凑的网络结构。Zhou等^[26]构建了一种具有鲁棒性的在线顺序随机向量函数链神经网络用于BFI过程的建模,所提出算法分别从计算效率、鲁棒性、在线学习3个方面进行了改进,可使用时变动态系统的数据进行在线模型更新。

② 基于SVM的数据驱动模型。

SVM对于数据中的噪声和异常值具有较强的抗干扰能力,且能够通过核函数将数据映射至高维空间以避免小样本问题。Vincent等^[27]基于支持向量回归(support vector regression, SVR)算法建立了连续工业过程模型,并将所提出方法用于预测流化床锅炉的马氏体初始温度。Zhou等^[28]提出了一种多输入多输出的最小二乘SVR用于建立BFI过程的数据驱动模型,其使用PCA选取模型的输入特征,并结合非线性回归外生建模方法对铁水质量进行动态评估。在模型学习方面,提出了多任务迁移学习策略对非线性回归外生模型进行参数更新。

③ 基于DT的数据驱动模型。

DT是数据挖掘技术中一种基本的分类和回归方法。DT模型呈树形结构,其主要优点是模型具有可读性,且计算速度快。于涛等^[29]基于分类回归树(classification and regression tree, CART)建模框架,建立了BFI过程铁水硅含量的预测模型,该模型的适应性较强,且无需炉况稳定等强数学假设。

单个学习器的数据驱动建模策略,由于其具有结构简单、易于实现、与优化控制算法结合性好等特点,

已在实际工业过程中取得了广泛应用.然而,在面对多工况、多环节、多源多模态等复杂问题时,使用单个学习器建模存在一定的局限性.

2) 集成学习建模策略.

集成学习通过构建和组合多个学习器共同完成学习任务,即将具有独立决策能力的多个学习器按照一定的策略进行组合,以共同做出决策.集成学习的基本思想如图3所示.根据学习器的不同集成方式,可将其分为Bagging、Boosting、Stacking以及Blending等4种集成学习策略.

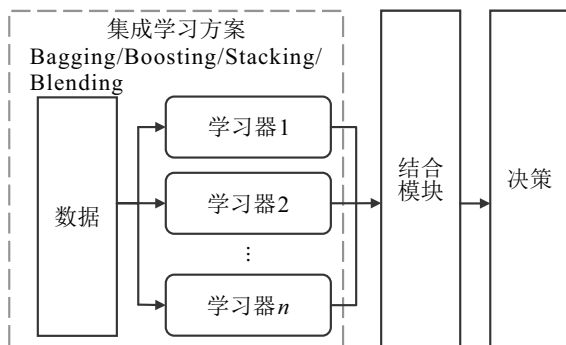


图3 集成学习的基本思想

① Bagging集成学习方法.

Bagging全称为Bootstrap aggregating,是一种常见的集成学习方案. Bagging通过对原始训练集进行有放回的Bootstrap抽样,形成多个大小相同、训练个体不同的训练集以供多个学习器进行训练,并使用投票法或加权平均法将多个学习器进行组合,以提高模型的准确性. 随机森林(random forest, RF)是一种基于DT的典型Bagging集成学习算法,一些学者在其基础上进行了应用研究. Mousavi等^[30]提出了一种基于贝叶斯优化的RF算法,建立了多输入单输出模型,用于估计WWT过程中的UV₂₅₄含量. Liu等^[31]提出了一种基于分层聚类选择的加权RF方案,用于复杂工业过程中的故障分类检测.

除RF,采用ANN等算法作为学习器的Bagging集成学习方案同样获得了广泛关注. Yan等^[32]采用随机配置网络作为基学习器,建立了准确性高、泛化能力强的MSWI炉膛温度模型; Zhang等^[33]设计了一种基于集合模式树的高炉铁水温度预测模型; Zhao等^[34]提出了一种以极限学习机(extreme learning machine, ELM)作为基学习器的Bagging集成学习方案,并建立了生化需氧量(biochemical oxygen demand, BOD)和NH₄-N的水质指标模型; Su等^[35]采用Bootstrap划分数据集,并基于改进的多层ELM建立了Bagging集成数据驱动模型,用于预测高炉冶炼过程的热金属温度.

② Boosting集成学习方法.

Boosting是一种通过组合弱学习器进而产生强学习器的方法,其核心思想是通过增大每次训练误差的样本权重,使得训练效果较差的样本能够被重视. Boosting训练过程为阶梯状,基模型的训练是有顺序的,每个基模型均会在前一个基模型学习的基础上进行学习,综合所有基模型结果获得最终结果.

以Boosting集成学习策略为基础的改进算法陆续被提出,如AdaBoost(adaptive boosting)、GBDT(gradient boosting decision tree)以及XGBoost(extreme gradient boosting)等,这些算法也在复杂工业过程中得到了应用. Luo等^[36]提出了一种基于加权SVM的AdaBoost集成建模算法,用于预测BFI过程中内部铁水的热状态. Yu等^[37]提出了一种基于PSO算法的GBDT集成学习建模方法,用于计算农业残留物和废水污泥的热解质量损失率. Kheimi等^[38]提出了一种采用CART作为基学习器的XGBoost集成学习方案,并建立了评估重金属对WWT过程影响的预测模型. Ching等^[39]为了更准确地检测WWT过程的BOD₅,提出了一种基于CART的XGBoost集成学习模型.

③ Stacking集成学习方法.

Stacking集成学习的主要思想是将不同模型相结合,充分结合它们的优点,以获得最好的建模效果. Stacking使用全部数据训练基学习器,每个基学习器的输出将作为训练样本的特征值,进而得到新的训练样本,然后,基于新的训练样本进行训练得到模型. Xia等^[40]基于改进的深度森林算法建立了MSWI过程的二噁英预测模型,该研究使用了XGboost、GBDT、完全随机森林以及RF等多种集成学习方案. Chen等^[41]提出了一种基学习器为极限随机树、XGBoost、多元线性回归以及RF的Stacking集成学习模型,实现了对钢包精炼过程的钢水温度预测.

④ Blending集成学习方法.

Blending最早出现在Netflix数据挖掘比赛中,其本质是一种多层的串行学习系统. Blending是从Stacking派生出来的另一种形式的集成学习技术,两者间的区别是Blending使用来自一个训练集的保留(验证)集来进行预测.

3) 多学习器组合建模策略.

与传统意义的集成学习策略不同,多学习器组合建模更关注于多种异构学习器的混合使用,并对复杂工业过程中所包含的多源多模态信息,如数值、图像和声音等数据进行特征提取,结合不同学习器算法以

提升模型性能。

多学习器组合建模策略在工业过程中已有广泛应用,针对熔融镁熔炼过程中异常情况难以有效监测和准确识别的问题,Zhou等^[42]提出了一种基于深度学习和SVM的多源信息融合建模方案,建模过程中引入了熔融镁熔炼过程的图像信息,实现了对工况的准确识别;Nourani等^[43]基于前馈ANN、SVR以及ANFIS(adaptive neuro fuzzy inference system)建立了WWT过程中BOD和COD(chemical oxygen demand)的预测模型;Chen等^[44]使用ANN结合RF建立了MSWI过程中多氯代二苯并呋喃的在线检测模型。

数据驱动模型的准确性和可靠性取决于所使用的数据质量。数据驱动建模面临的主要挑战如下:部分复杂工业的数据结构复杂,具有维度高、波动大等特性;数据驱动模型仅能够适应训练数据所涵盖的工况范围,难以适应新的数据和场景。针对数据结构复杂的问题,一些学者致力于对数据预处理的相关研究,如异常值剔除、数据降噪、特征提取和融合等算法的研究^[45]。然而,由于复杂工业过程部分重要变量的变化频率较低,挖掘数据特征间的关系困难,仅使用数据预处理算法处理数据获得的结果可能导致部分重要数据特征被忽略。针对数据驱动模型难以适应新的数据和场景问题,一些学者尝试将模型的重要信息保留并在此基础上采用新的数据对模型进行二次在线调整^[46]。然而,在数据结构差异较大的情况下,保留的模型信息可能对二次训练意义较小。

1.3 混合模型

混合建模策略旨在结合机理模型和数据驱动模型的优势,以获得更好的建模性能。现有混合模型的类型包括:直接混合模型、反演模型、降阶模型、不确定性量化等子类别。

1.3.1 直接混合建模

根据机理模型和数据驱动模型的作用,直接混合模型可分为机理分析增强数据驱动的混合模型、数据驱动协助机理分析的混合模型以及基于并行输出修正的混合模型等,对其详细描述如下。

1) 机理分析增强数据驱动的混合模型。

针对一些过程数据获取困难或存在数据特征缺失的复杂工业过程,可采用机理分析增强数据驱动的混合建模方法,通过建立机理模型产生所需的工况数据,并将数据作为建立数据驱动模型的基础^[47-48],其结构如图4所示。

Le等^[47]基于CFD软件和ANN建立了旋风分离器的混合模型,采用CFD仿真和实际实验获得数据




图4 一种基于机理分析增强数据驱动的混合模型结构

集,随后使用神经网络建立了数据驱动模型。华丰等^[48]设计了一种智能混合模型用于模拟乙烯裂解炉反应过程,首先根据区域间换热的能量衡算公式构建了乙烯裂解炉管外传热计算模型,并利用该模型产生数据,结合神经网络学习机理模型的经验,从而建立起乙烯裂解炉管外传热的数据驱动模型。利用机理分析增强数据驱动的混合模型,避免了因耦合迭代的复杂求解。

2) 数据驱动协助机理分析的混合模型。

针对数据驱动模型可将历史数据转换为离线知识的特性,一类使用数据驱动协助机理分析的建模策略被提出。该方法将数据驱动模型嵌入至机理模型,用于求解机理模型中难以分析的复杂部分,或估计难以确定的参数,其结构如图5所示。




图5 一种数据驱动协助机理分析的混合模型结构

Yang等^[49]设计了一种混合模型用于熔融氧化镁熔炼过程的智能需求预测,该模型首先建立了冶炼过程平均功率需求预测的机理模型,其根据最大信息数和规则推理方法确定机理计算中难以获得的非线性项阶数,并采用径向基神经网络对非线性项的数值进行估计,从而现实对平均功率需求的智能预测,所提出模型的结构如图6所示。Azarpour等^[50]提出了一种通用混合建模方案用于工业固定床催化反应器过程分析,其根据质量和能量平衡方程建立了机理模型,并针对反应动力学计算中的催化剂失活率计算复杂且不准确的问题,采用反向传播神经网络替代机理推导,对催化剂失活率进行了预测。

3) 基于并行输出修正的混合模型。

针对机理模型难以在工况发生变化时与实际工业过程结果相吻合的问题,一类基于修正思想的混合建模方案被提出,其利用数据驱动模型对历史知识的积累和良好的在线学习能力,在机理模型的误差较大时对其输出进行修正,其结构如图7所示。

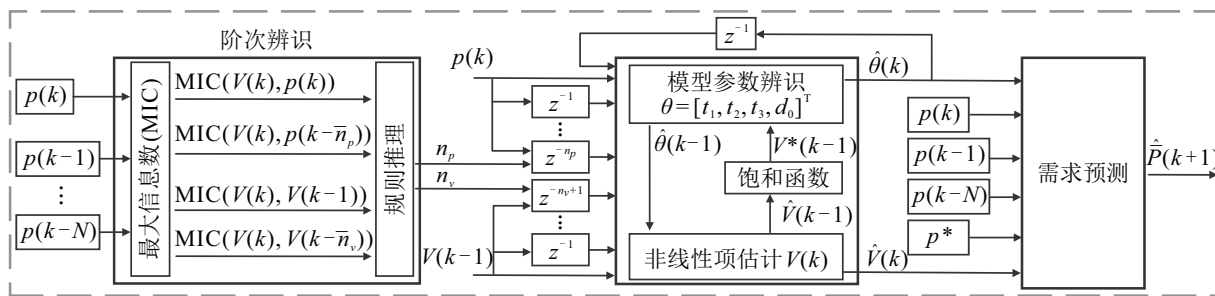


图6 熔融氧化镁熔炼过程平均功率预测混合模型^[49]




图7 一种基于并行输出修正的混合模型结构

郭晶晶等^[51]针对碳二加氢过程建立了一种自适应迭代混合模型方案,由于催化剂活性随系统运行过程发生变化,机理模型难以准确建立催化剂活性的关系,这导致机理模型在不同工况下的误差差距较大,所提出混合模型采用深度循环神经网络建立了数据驱动模型以动态补偿机理模型的误差。Azadi等^[52]提出了一种混合模型对BFI过程中的铁水和炉渣质量进行预测,该模型采用基于质量和能量守恒以及热力学代数方程建立了机理模型,并采用外生输入的线性自回归以及全连接ANN建立了BFI过程的数据驱动模型,使用数据驱动模型的输出补偿机理模型输出以获得最终的模型结果。

1.3.2 反演模型

一般建模方法是使用系统的物理参数(如质量、温度、电荷、物理尺寸或结构)预测该系统的下一个状态或其输出,即正演模型。与之相反,使用系统的输出推断系统物理参数的建模方法称为反演建模。反演建模可能揭示系统无法直接观察到的信息,对于建模具有重要意义。由于估计器评估或机理参数后验分布的表征可能需要数百万次正演模型评估,反演模型的求解在计算上较为昂贵。选择基于数据驱动的代理模型,能够通过大量数据建立高维模型,且模型计算速度比大多数机理模型更快。

在化工领域,通过反演模型发现材料的生成条件成为最有效的手段之一。Raccuglia等^[53]使用反应数据训练机器学习模型,预测模板化亚硒酸钒结晶的反应条件,该研究利用不成功或失败的材料合成实验数据,建立了基于数据驱动的反演模型,成功预测了亚硒酸钒结晶新的有机模板以及对应的形成条件。

1.3.3 降阶模型

降阶模型(reduce order model, ROM)是降低复杂模型计算成本的一种方法。常见的ROM是使用动态模态分解等方法将系统的控制方程映射至原始状态空间的子空间内,从而将模型限制在较低维度。数据驱动模型具有较快的执行速度和利用数据对高维现象建模的能力,可有效增强ROM的能力。基于传统降阶方法^[54]为已建立的ROM建立基于数据驱动的替代模型,或建立数据驱动模型模拟从全阶模型到降阶模型的降维映射^[55]。ROM通常对其所代表的系统内参数变化缺乏鲁棒性^[56],机理分析与数据驱动相结合可实现ROM更稳健的训练且能够使用更少的数据训练模型。

在快速变化的环境中,精确的动态降阶模型对于化学过程的最佳操作至关重要。Schäfer等^[57]提出了一种简化的精馏塔建模方法,该模型将减少微分方程数量的分区化与ANN相结合,以表达分区内的非线性输入-输出关系。该模型将微分方程系统的大小缩减了90%,同时将产品纯度的额外误差限制在1 ppm以下。此外,与全阶模型相比,所提出降阶模型使得最优控制问题的计算时间节省了约95%。

1.3.4 不确定性量化

基于机理分析的模型可能产生具有一定不确定性的结果,其不确定性主要源于模型参数、边界条件和初始条件等。机理模型中由参数或先验知识等引起的不确定性可使用数据驱动的方法构建代理模型或校准模型,通过模型的预测结果量化不确定性。

Sharma等^[58]量化了化学过程模型在预测工业高密度聚乙烯的熔体指数时的不确定性,其不确定性源于对过程动力学参数的估计。该研究使用预测区间的概念来确定模型预测的范围,利用化学过程模型的模拟数据,使用分位数回归损失和Boosting模型获得预测区间。实验结果表明,该模型的预测结果有90%的概率在给定范围内。

混合模型的结构设计与功能紧密相关,其旨在充

分利用过程数据的基础上引入机理分析,以将复杂的问题简单化.与机理模型和数据驱动不同,混合模型需要根据研究对象的特点,选择不同的机理分析与数据驱动混合方案,从而实现最大化模型优势.复杂工业过程的混合建模面临的主要挑战为模型结构复杂、子模型数量难以确定、模型外推性较差.通过分布式

建模策略将整体模型转化为多个子模型的组合,以提高混合模型的外推性并降低工况变化时的再训练难度和成本.混合模型建模方法仍然处于探索和发展阶段,目前鲜有明确的指导方案,需要通过不断地论证和尝试以获得最佳建模方案.

综上所述,总结各类建模策略特性如表1所示.

表1 面向复杂工业过程的建模策略特性分析

建模方法	模型类型	模型原理	文献和年份	优点和不足	
机理建模	基于一般数学分析	机理分析	2002 ^[16] , 2005 ^[17] , 2021 ^[18] , 2008 ^[19] , 2021 ^[59] , 2022 ^[60] , 2023 ^[61] , 2020 ^[62]	优点: 模型具有可解释性 不足: 模型需要理想条件、参数辨识难度大	
	基于CFD软件实现	机理分析+CFD软件	2017 ^[20] , 2023 ^[21] , 2023 ^[22] , 2007 ^[63] , 2013 ^[64] , 2012 ^[65] , 2015 ^[66] , 2022 ^[67]	优点: 模型具有可解释性、可视化仿真结果 不足: 仿真过程计算成本高、难以在线更新	
数据驱动建模	统计方法	线性回归	2008 ^[68] , 2014 ^[69]	优点: 建模简单、计算成本低 不足: 模型性能差、适用范围窄	
		时间序列分析	1996 ^[23] , 2018 ^[70]		
	单一学习器	ANN	2021 ^[24] , 2019 ^[25] , 2019 ^[26] , 2019 ^[71] , 2022 ^[72] , 2022 ^[73] , 2020 ^[74] , 2021 ^[75]	优点: 模型简单、计算成本低、使用灵活	
		SVM	2018 ^[27] , 2017 ^[28] , 2019 ^[71] , 2022 ^[76]	不足: 处理不平衡数据时模型性能较差	
		DT	2015 ^[29] , 2019 ^[71]		
		集成学习	Bagging Boosting Stacking Blending	2022 ^[30] , 2018 ^[31] , 2022 ^[32] , 2019 ^[33] , 2011 ^[34] , 2012 ^[77] , 2019 ^[35] , 2019 ^[78] 2020 ^[36] , 2020 ^[37] , 2022 ^[38] , 2022 ^[39] 2022 ^[40] , 2022 ^[41] , 2023 ^[79]	优点: 可处理不平衡数据、提高模型预测性能 不足: 学习过程复杂、时间花费较高、处理高维数据存在局限性 ^[80]
	多学习器组合	ANN+SVM	2021 ^[42] , 2020 ^[81] , 2018 ^[82]	优点: 组合灵活、可处理多源融合数据 不足: 学习器类型的选取主要依靠经验、学习器优化复杂	
		ANN+SVM+ANFIS	2021 ^[43] , 2022 ^[76]		
		ANN+RF	2021 ^[44]		
		SVM+RF	2023 ^[79]		
		ANN+XGBoost	2023 ^[83] , 2023 ^[73]		
混合建模	机理分析增强数据驱动	串联	2023 ^[47] , 2018 ^[48] , 2021 ^[84] , 2022 ^[85]	优点: 弥补某些工业过程缺少数据或数据较少的问题 不足: 机理模型与数据驱动没有融合、模型精度主要取决于数据驱动模型	
	直接混合模型	数据驱动协助机理分析	嵌入	2020 ^[6] , 2018 ^[49] , 2017 ^[50] , 2021 ^[86] , 2014 ^[87] , 2021 ^[88] , 2022 ^[89] , 2022 ^[90] , 2010 ^[91] , 2021 ^[92]	优点: 避免了复杂工艺环节机理难以分析和部分参数难以确定的问题 不足: 降低了模型可解释性
	基于修正思想的混合模型	并联和混联	2018 ^[51] , 2022 ^[52] , 2019 ^[93] , 2012 ^[94]	优点: 模型精度较高,鲁棒性好 不足: 对机理分析和过程数据的需要均较高	
	反演模型	机理分析融入数据驱动结果	2016 ^[53] , 2014 ^[95]	优点: 估算模型重要参数 不足: 需要大量正演数据	
	降阶模型	数据驱动代理或辅助分析	2018 ^[54] , 2018 ^[55] , 2008 ^[56] , 2019 ^[57]	优点: 计算速度快 不足: 模型有一定精度损失	
	不确定性量化	数据驱动协助模型辨识和估计	2022 ^[58] , 2016 ^[96] , 2017 ^[97] , 2020 ^[98] , 2023 ^[99]	优点: 降低因系统不确定性导致的误差 不足: 模型验证困难	

2 各类方法在复杂工业过程的建模应用

2.1 指标模型

指标模型指对工业过程具有较大影响或能够反应工业过程特性的某些重要指标的模型.指标模型

在复杂工业过程中具有广泛的应用,如软测量模型、预测模型等.

铁水温度是BFI过程中的重要指标之一,对铁水温度的实时预测至关重要.然而,传统测量方法是采

用一次性热电偶进行间歇性的测量,难以满足对高炉稳定运行并产出质量稳定铁水的需求.数据驱动模型在非线性辨识、模式识别等任务上具有较高的精度和较快的速度.工业过程的可测量数据特征丰富,历史数据累计可观,因此,基于数据驱动建模方案是BFI过程铁水温度在线预测的有效方案.

Zhang等^[71]对比了7种浅层模型算法和3种深层模型算法对铁水温度的预测性能,如表2所示.其中:浅层模型训练时间较短且能够保持一定精度;而深层模型如DNN,虽然具有更高的精度,但是训练成本明显增高.可根据BFI工艺中对品质和成本的实际需求,选择合适的建模方案.

表2 各算法结果对比^[71]

算法	RMSE	R	训练时间	预测时间
PLS	13.142	0.797	4.515	0.004
LW-PLS	9.015	0.897	-	7.382e+04
SVR	5.437	0.965	34.458	1.812
GPR	2.880	0.989	374.783	0.423
RF	8.336	0.914	226.027	0.513
BRT	3.364	0.986	53.134	3.773
SNN	1.536	0.997	1.513e+03	0.079
DNN	1.142	0.999	2.193e+03	0.152
LSTM	4.021	0.982	570.921	7.337
CNN	8.402	0.912	174.728	0.327

出水水质是衡量WWT工艺是否达标的重要指标之一,进水流量等参数的随机变化较大且生物传感器的缺乏使得一些重要变量还没有经济成熟的在线测量方案.虽然已有普遍认可的机理模型,但是,模型结果难以与实际工厂运行工况吻合,而数据驱动建模因其更低的建模成本和快速的实时响应是WWT过程出水水质监测的主要方法.

Sadri等^[79]研究了不同单一学习器模型以及两种集成模型在WWT过程中出水总氮含量预测效果差异,模型框架如图8所示.实验结果表明,使用单一

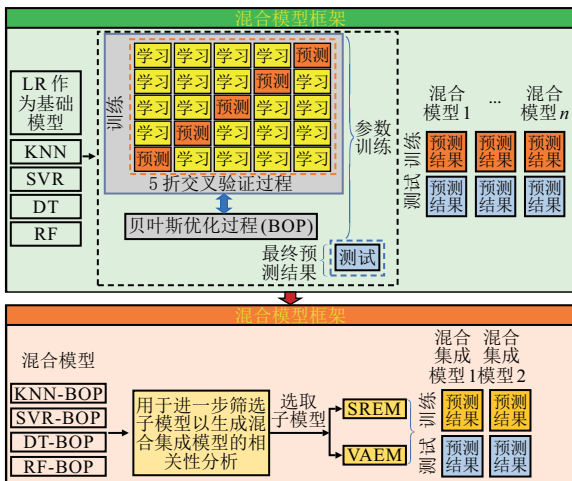


图8 一种混合学习模型框架^[79]

基学习器构建集成模型可显著提高模型的预测准确性,而使用异质基学习器的预测性能与其混合方式密切相关,并非所有异构学习器的混合集成学习模型均优于同构学习器的集成学习模型.适用研究问题的学习器组合可有效提高建模精度.

指标模型作为复杂工业过程最常用的模型之一,其建模方法的研究对于软测量、过程优化、预测控制和故障检测等具有重要意义.由于指标模型一般重点关注复杂工业过程的局部环节,而机理建模需要考虑全部工艺流程的影响,计算成本较高.基于数据驱动的指标模型因其简单易实现的特点,是目前复杂工业过程指标模型的主要建模方案之一.此外,部分工业过程对指标模型的实时性要求较高,训练完成的数据驱动模型通常对结果预测的效率较高,这是考虑指标模型应用时不可忽视的模型特性.

2.2 被控对象模型

建立被控对象模型是模拟复杂工业过程进而施加优化控制策略的基础,其对于提高复杂工业过程的生产效率和降低能耗等方面具有重要意义.

电站锅炉的稳定控制是实现电网稳定的重要环节,但是,其在并网发电时常面临负荷大幅、频繁变化等问题.此外,煤质、制粉设备状况变化对燃烧特性的影响较大,这导致难以收集长时间的稳定运行数据来建立模型并更新.吴恒运等^[72]设计了一种非对称神经网络建立锅炉燃烧被控模型,将锅炉模型的输入按照实际机理与网络结构相组合,降低了模型对样本数量的依赖,从而实现模型随煤质变化的在线更新.

BFI过程的被控对象模型是实现铁水温度和出铁率稳定的基础,然而,由于其时间常数较大,难以确定先前控制对未来结果的影响,且普遍伴随控制动作冗余的问题.Masuda等^[61]建立了一个二维瞬态模型来描述BFI过程,将基于机理分析的瞬态模型转换为非线性状态空间模型,建立控制输入、系统状态以及被控量的关系.模型由气体流动模型、固体流动模型、质量平衡模型以及能量平衡模型组成,其输入为鼓风量、富氧流量、煤粉流量、鼓风水分、鼓风温度以及焦炭比率,输出为铁水温度和出铁率.

通过对热力学和动力学的研究模拟,可一定程度理解BFI过程高炉内部现象,从而建立被控对象模型.然而,由于工艺过程的复杂性,模型应用于实践时不可避免地面临实时性能弱、过度假设和简化等问题.针对此问题,Zeng等^[91]研究了BFI过程的数据驱动预测控制,该研究在机理分析的基础上,采用子空间辨识方法,从测量数据中获得状态空间模型,

使得模型具有较好实时性的同时与实际工业过程吻合. 所建立的BFI过程的状态空间模型描述为

$$\begin{cases} x_{k+1} = Ax_k + Bu_k + Ke_k, \\ y_k = Cx_k + Du_k + e_k. \end{cases} \quad (2)$$

其中: u 为控制输入, x 为状态变量, y 为模型输出. 通过子空间辨识的方法, 可获得模型输出的预测值, 即

$$\tilde{Y}_f = [L_w \quad L_u] \begin{bmatrix} W_p \\ U_f \end{bmatrix}. \quad (3)$$

式中: $W_p = [Y_p, U_p]^T$, 下标 p 和 f 表示“过去”和“未来”时间.

采用QR分解获得预测输出的关系为

$$\begin{bmatrix} W_p \\ U_f \\ Y_f \end{bmatrix} = \begin{bmatrix} R_{11} & 0 & 0 \\ R_{21} & R_{22} & 0 \\ R_{31} & R_{32} & R_{33} \end{bmatrix} \begin{bmatrix} Q_1^T \\ Q_2^T \\ Q_3^T \end{bmatrix}, \quad (4)$$

其中 L 矩阵为

$$L = [L_w \quad L_u] = [R_{31} \quad R_{32}] \begin{bmatrix} R_{11} & 0 \\ R_{21} & R_{22} \end{bmatrix}^\dagger, \quad (5)$$

式中 \dagger 为 Moore-Penrose 伪逆. 在不明确估计模型参数的情况下, 上述方法可将系统辨识和控制结合在单次操作中.

类似地, Zhou 等^[92] 以两种数据驱动模型^[100] 为基础, 使用紧凑型动态线性化技术将非线性多变量 BFI 系统转换为动态线性模型, 从而建立 BFI 过程的被控对象模型.

基于递归的子空间辨识模型被描述为

$$Y(k+1) = L_w(k) \begin{bmatrix} Y(k) \\ U(k-1) \end{bmatrix} + L_u(k)U(k). \quad (6)$$

其中: $L_w \in \mathbf{R}^{2 \times 4}$ 和 $L_u \in \mathbf{R}^{2 \times 2}$ 为两个时变的参数矩阵, 控制变量 U 为压降和注煤率, 被控变量 Y 为铁水温度和硅含量.

基于递归的双线性子空间辨识模型被描述为

$$\begin{aligned} Y(k+1) = & A_{n \times (n+m)} \begin{bmatrix} Y(k) \\ U(k) \end{bmatrix} + \\ & N_{n \times (nm+mm)} \begin{bmatrix} U(k) \otimes Y(k) \\ U(k) \otimes U(k) \end{bmatrix} + \\ & B_{n \times m}U(k) + W(k). \end{aligned} \quad (7)$$

其中: W_k 为时变的扰动向量, U 为冷空气流量、压降、富氧流量和注煤率.

传统的被控对象模型通常为状态空间方程的形式. 机理模型因其具有明确的数学表达可直接建立对应的非线性状态空间方程. 此外, 由于机理模型的白箱属性, 控制律的求解过程同样具有可解释性. 数

据驱动方法在建立复杂工业过程的被控对象模型中同样有广泛应用, 其能够直接从数据中获取状态空间模型或基于数据对模型参数进行辨识, 且由于一般建立的模型为线性系统模型, 控制率的求解过程更加简便. 然而, 基于机理分析所建立的被控对象模型虽然有益于求解控制率, 但是, 仍然存在对复杂工业过程的机理建模昂贵且难以实现的问题; 而基于数据驱动的被控对象模型精度和适用范围难以获得保障, 这给控制器的设计带来了挑战. 相较之下, 结构合理的混合建模策略在控制器稳定性和控制精度等方面均具有一定优势, 在建立复杂工业过程被控对象模型方面具有一定的应用前景.

2.3 全流程模型

与指标模型和被控对象模型仅关注工业过程中的局部流程不同, 全流程模型是对复杂工业过程的全部流程工艺的建模研究. 全流程模型的重点在于对工业流程的分析, 一般采用多个子模型的组合来构建完整的全流程模型.

基于机理分析建立 MSWI 全流程模型时, 由于固体废弃物是一种非均质燃料, 其特性以不可预测的方式不间断变化, 且 MSWI 过程涉及多个工艺环节, 这导致建模面临挑战. Magnanelli 等^[62] 基于机理分析并结合过程数据建立了 MSWI 过程的全流程动态模型, 其考虑了固废特性和操作设定点的波动, 该模型包括炉排、炉膛、蒸发器、过热器、省煤器、锅炉汽包、冷风机以及引风机等模型, 从物质和能量转换的角度对每个子模型进行了数学描述, 并考虑了各子模型间的时间传递关系.

WWT 过程包含多级生化反应, 采用数据驱动方法建立全流程模型同样需要多个子模型对整体进行构建. Zaghoul 等^[76] 基于 ANN、SVM 和 ANFIS 等算法, 共同建立了一个全面的 WWT 过程的集成数据驱动模型. WWT 过程被设计为一个多级结构, 共包含 6 个部分, 其结构如图 9 所示. ANN、SVR 和 ANFIS 算法被用于单独开发和训练, 并将其作为独立模型. 集成 ANN (ensemble ANN, E-ANN)、集成 SVR (ensemble SVR, E-SVR)、集成 ANFIS (ensemble ANFIS, E-ANFIS)、算术平均 (arithmetic average, E-AVG) 和加权平均 (weighted average, E-WAVG) 等利用独立模型的输出作为输入来构建集成学习模型, 并选择表现最好的模型作为最终输出, 建模结果如表 3 所示. 然而, 尽管多子模型的集成建模成本较低且学习速度较快, 但是, 其无法在子模型层面体现 WWT 过程的生化反应的流程关系.

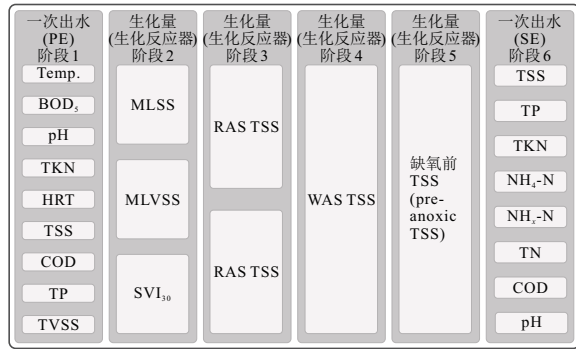


图9 一种全流程WWT过程模型结构^[73]

表3 模型各阶段选择算法和结果^[73]

输出	算法	R ² / %		RMSE		MAPE / %	
		训练	预测	训练	预测	训练	预测
缺氧前 TSS	E-WAVG	87.47	76.25	0.036	0.049	3.63	3.34
MLSS	E-WAVG	65.52	51.35	0.054	0.065	5.36	4.23
MLVSS	E-ANN	70.15	62.84	0.055	0.065	3.38	4.11
SVI30	E-WAVG	82.25	59.04	0.066	0.102	6.64	9.64
RAS TSS	E-WAVG	77.24	64.29	0.060	0.073	5.99	4.68
RAS TVSS	E-WAVG	82.13	68.21	0.057	0.072	5.72	4.68
WAS TSS	E-WAVG	90.28	72.16	0.042	0.073	4.19	5.82
SE TSS	E-ANN	89.20	62.96	0.039	0.093	4.23	15.00
SE TP	E-ANN	92.68	64.90	0.027	0.062	3.85	13.02
SE TKN	E-ANN	90.92	81.80	0.028	0.044	5.69	9.79
SE NH ₄ -N	E-WAVG	85.78	78.48	0.043	0.054	4.29	26.88
SE NO _x -N	SVR	97.10	82.25	0.023	0.058	0.89	3.84
SE TN	E-ANN	81.28	79.73	0.039	0.043	3.28	3.65
SE COD	SVR	99.92	81.23	0.003	0.049	0.26	3.51
SE pH	E-WAVG	55.51	47.37	0.011	0.012	1.05	0.49

非结构化动力学模型常用于建立燃料乙醇分批发酵过程的全流程模型,但是,由于初始葡萄糖浓度的巨大差异,非结构化动力学模型对酵母生长的预测性能较差,且由于环境条件的变化,非结构化动力学模型的参数是时变的.为了解决这些问题,Li等^[73]采用混合建模方法对燃料乙醇发酵过程进行了动态建模,该模型使用XGBoost预测生物量浓度和菌丝体生长速率作为补充机理的知识,并使用ANN确定机理模型的时变动力学参数.模型可以准确预测生物量、乙醇和葡萄糖浓度的时间序列.

全流程模型的建模难点主要在于模型尺寸以及各工艺环节间的影响,需要对整体工业过程进行全面考虑和分析.此外,复杂工业过程的全流程模型通常需要采用多个子模型分别建立不同的工艺环节模型,且需要考虑各工艺环节间的相互作用.机理模型通常考虑了系统时间的变化,可有效解决各工艺环节间的时滞影响,但是,全流程模型囊括的难以确定的参数更多,增加了机理分析的难度.数据驱动模型一般仅为各模块间的组合,难以消除时滞影响.此外,由于部分工业过程的中间过程量检测缺失,导致数据驱动模型的适用性下降.合适的混合建模方案可避免机

理建模和数据驱动建模过程的缺点,但是,混合方式及其与工艺环节的联系仍然需要具体分析.

综上所述,复杂工业过程的建模方法多种多样,并不具有确定的解决方案,多种建模策略各有侧重点,且正处于齐头并进的发展阶段.在具体应用中,应根据研究对象、研究问题、成本限定和性能需求等设计合适的建模策略.

数字孪生是工业发展的新趋势,近年来获得了广泛关注.复杂工业过程丰富的指标模型、被控对象模型以及全流程模型为构建数字孪生后台模型打下了坚实的基础.通过数字孪生体与工业实体的实时交互和迭代优化,实现生产过程精准预测控制、自组织优化调度和设备全生命周期管理等,可大幅提升工业过程的生产质量和效益,促进复杂工业过程的高质量发展^[101].数字孪生系统首要是设计和构建工业大数据远程传输和存储系统,原始数据被临时存储于工厂的数据中心,经预处理后,将“洁净数据”从本地服务器传输至云数据库,从而实现在本地服务器和云数据库的数据集上进行相应的建模优化和控制,并将算法仿真结果发回工厂,以协助工厂实时调整运行状态.Zhou等^[74-75]建立了BFI过程的基础数字孪生模型,实现了云端与工厂的实时交互,研究包括对云端工厂的数据存储、实时建模以及多目标优化,所设计的云端BFI工厂如图10所示.




图10 云端高炉炼铁工厂示意图^[75]

3 结论和展望

复杂工业过程的建模研究是提升其智能化水平和运行效率的关键.复杂工业过程由于工艺复杂,不确定因素繁多,导致其建模过程存在诸多挑战.本文对当前复杂工业过程的建模方法进行了综述,主要从机理建模、数据驱动建模以及混合建模3个方面讨论了工业建模技术发展的过程和研究现状,并以指标模型、被控对象模型、全流程模型等为实例,分析了复杂工业过程建模的应用方案和特点.本文结合复杂

工业过程的建模研究现状及其亟待解决的问题,指出以下几点潜在的研究方向。

1) 结合专家知识的混合建模研究. 针对某些机理分析困难,但是已存在领域专家知识的成熟工业过程,合理地提取专家知识,并将其用于模型的工况划分、特征选取、控制规则提取等具有重要的意义. 如WWT过程存在不同季节以及晴天雨天情况下的工况划分、MSWI过程存在燃烧线前后移动的工况划分等. 虽然工况不同但是具有类似的模型基础,因此,可利用模型状态知识、策略知识、特征知识等的迁移以及模型传递技术,增强模型外推性的同时能够有效降低建模的难度.

2) 融合多源多模态信息的建模研究. 一些复杂工业过程的图像、声音等信息与运行参数密切相关,如MSWI过程中的火焰燃烧图像,BFI过程中的铁水颜色图像、球磨机的研磨声音等. 可利用深度学习、图模型等技术实现数据的模态转化,将数值数据、声音数据、图像数据等转换为统一的模态,实现多源多模态数据的深度融合,进而提升数据挖掘的效果.

3) 面向多模型误差传递问题的建模研究. 复杂工业过程因其多流程的特性,通常在建模时需要多个子模型的级联,如MSWI过程的固相燃烧、烟气处理、蒸汽发电以及WWT过程的多级生化反应等过程. 然而,这种建模方法易造成子模型间的误差传递,导致模型偏差逐渐放大. 通过更改模型的连接方式,设置断点并加入时间序列预测模型是一种有效的解决方案. 此外,通过设置误差临界值,并插入误差纠正模型同样可避免误差传递的发生.

4) 对接实际优化控制策略的建模研究. 复杂工业模型需要与实际的执行机构紧密结合以完成优化控制策略. 建模过程应考虑多个工艺环节间变量的传递关系、多输入多输出过程中变量的耦合性以及多个指标的协同优化问题. 针对具体问题构建目的性明确的精准模型,有助于在实际应用中减少执行器磨损并降低能耗. 建立工况以及部件状态的智能感知模型,在实现对工业过程运行指标(表征产品质量、产量、能耗、成本、排放的工艺参数)准确预测的同时,将设备运行时间和损耗等系统信息纳入建模考虑,为优化决策和控制策略设计提供更精确的模型和全面的指标.

参考文献(References)

- [1] 中国社会科学院世界经济与政治研究所, 虹桥国际经济论坛研究中心. 世界开放报告2022[M]. 北京: 中国社会科学出版社, 2022: 87-111.
(Institute of World Economics and Politics Chinese Academy of Social Sciences, Research Center for Hongqiao International Economic Forum. World open report 2022[M]. Beijing: China Social Sciences Press, 2022: 87-111.)
- [2] 柴天佑. 工业人工智能发展方向[J]. 自动化学报, 2020, 46(10): 2005-2012.
(Chai T Y. Development directions of industrial artificial intelligence[J]. Acta Automatica Sinica, 2020, 46(10): 2005-2012.)
- [3] 中华人民共和国工业和信息化部. 关于印发《工业互联网创新发展行动计划(2021-2023年)》的通知 [EB/OL]. (2020-12-22)[2023-03-26]. https://www.miit.gov.cn/ztlz/rdzt/gyhlw/wjfb/art/2021/art_6706d89a6cbc49cea75e8d47d4787064.html.
(Ministry of Industry and Information Technology of the People's Republic of China. Notice on printing and distributing the "Industrial Internet Innovation and Development Action Plan (2021-2023)" [EB/OL]. (2020-12-22)[2023-03-26]. https://www.miit.gov.cn/ztlz/rdzt/gyhlw/wjfb/art/2021/art_6706d89a6cbc49cea75e8d47d4787064.html.)
- [4] Saidur R, Hossain M S, Islam M R, et al. A review on kiln system modeling[J]. Renewable and Sustainable Energy Reviews, 2011, 15(5): 2487-2500.
- [5] Özkan L, Bombois X, Ludlage J H A, et al. Advanced autonomous model-based operation of industrial process systems (autoprofit): Technological developments and future perspectives[J]. Annual Reviews in Control, 2016, 42: 126-142.
- [6] Sun B, Yang C H, Wang Y L, et al. A comprehensive hybrid first principles/machine learning modeling framework for complex industrial processes[J]. Journal of Process Control, 2020, 86: 30-43.
- [7] Nazarenko A A, Sarraipa J, Camarinha-Matos L M, et al. Analysis of relevant standards for industrial systems to support zero defects manufacturing process[J]. Journal of Industrial Information Integration, 2021, 23: 100214.
- [8] Lin L, Han L H, Xie K, et al. First-principles study of (Ni, Pd, Au)-embedded VS₂ monolayers for adsorption of CO, H₂S, NO, NO₂ and SO₂[J]. FlatChem, 2022, 36: 100421.
- [9] Vouyiouka S N, Karakatsani E K, Pappaspyrides C D. Solid state polymerization[J]. Progress in Polymer Science, 2005, 30(1): 10-37.
- [10] Wang X Q, Deng D C. A comprehensive model for solid-state polycondensation of poly(ethylene terephthalate): Combining kinetics with crystallization and diffusion of acetaldehyde[J]. Journal of Applied Polymer Science, 2002, 83(14): 3133-3144.
- [11] Ghosh D, Moreira J, Mhaskar P. Application of data-driven modeling approaches to industrial hydroprocessing units[J]. Chemical Engineering Research and Design, 2022, 177: 123-135.
- [12] Sun C Y, Ma H J. An enhanced kernel learning data-driven method for multiple fault detection and

- identification in industrial systems[J]. *Information Sciences*, 2022, 615: 431-448.
- [13] Ren J C, Liu D, Wan Y. VMD-SEAE-TL-Based data-driven soft sensor modeling for a complex industrial batch processes[J]. *Measurement*, 2022, 198: 111439.
- [14] Bradley W, Kim J, Kilwein Z, et al. Perspectives on the integration between first-principles and data-driven modeling[J]. *Computers & Chemical Engineering*, 2022, 166: 107898.
- [15] 李凡军, 王孝红, 路士增. 水泥熟料烧成系统建模方法研究进展[J]. *控制与决策*, 2019, 34(10): 2041-2047. (Li F J, Wang X H, Lu S Z. Review for modeling of cement clinker burning system[J]. *Control and Decision*, 2019, 34(10): 2041-2047.)
- [16] Yang Y B, Goh Y R, Zakaria R, et al. Mathematical modelling of MSW incineration on a travelling bed[J]. *Waste Management*, 2002, 22(4): 369-380.
- [17] Zhou H, Jensen A D, Glarborg P, et al. Numerical modeling of straw combustion in a fixed bed[J]. *Fuel*, 2005, 84(4): 389-403.
- [18] Wu W H, Zhu R, Wei G S, et al. Modeling on the blast furnace with CO₂-enriched hot blast[J]. *Journal of Cleaner Production*, 2021, 319: 128690.
- [19] Alex J, Benedetti L, Copp J, et al. Benchmark simulation model no.1 (BSM1)[J]. Report by the IWA Taskgroup on Benchmarking of Control Strategies for WWTPs, 2008, 1: 1-61.
- [20] Wissing F, Wirtz S, Scherer V. Simulating municipal solid waste incineration with a DEM/CFD method—Influences of waste properties, grate and furnace design[J]. *Fuel*, 2017, 206: 638-656.
- [21] Cho B A, Grobler E, Pott R W M C, et al. A CFD coupled photo-bioreactive transport modelling of tubular photobioreactor mixed by peristaltic pump[J]. *Chemical Engineering Science*, 2023, 270: 118525.
- [22] Merten H, Wirtz S, Bartusch H, et al. Analysis of the impact of carbon dissolution and energy transport on the flow in the hearth of an ironmaking blast furnace by transient CFD simulations[J]. *Thermal Science and Engineering Progress*, 2023, 39: 101747.
- [23] Östermark R, Saxén H. VARMAX-modelling of blast furnace process variables[J]. *European Journal of Operational Research*, 1996, 90(1): 85-101.
- [24] Sun J, Meng X, Qiao J F. Prediction of oxygen content using weighted PCA and improved LSTM network in MSWI process[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-12.
- [25] Yang C L, Qiao J F, Ahmad Z, et al. Online sequential echo state network with sparse RLS algorithm for time series prediction[J]. *Neural Networks*, 2019, 118: 32-42.
- [26] Zhou P, Li W P, Wang H, et al. Robust online sequential RVFLNs for data modeling of dynamic time-varying systems with application of an ironmaking blast furnace[J]. *IEEE Transactions on Cybernetics*, 2020, 50(11): 4783-4795.
- [27] Vincent B, Duhamel C, Ren L, et al. A PCA and SVR based method for continuous industrial process modelling[J]. *IFAC-PapersOnLine*, 2018, 51(11): 1604-1609.
- [28] Zhou P, Guo D W, Wang H, et al. Data-driven robust M-LS-SVR-based NARX modeling for estimation and control of molten iron quality indices in blast furnace ironmaking[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(9): 4007-4021.
- [29] 于涛, 李江鹏, 李明昕, 等. 基于分类回归树的高炉铁水硅含量预测模型[J]. *内蒙古大学学报: 自然科学版*, 2015, 46(5): 548-552. (Yu T, Li J P, Li M X, et al. A prediction model of hot metal silicon content based on algorithm of classification and regression tree[J]. *Journal of Inner Mongolia University: Natural Science Edition*, 2015, 46(5): 548-552.)
- [30] Mousavi S Z, Momeni S A, Dehdashti B, et al. Advanced treatment of industrial estate effluent using ozone-membrane processes based on optimized random forest model[J]. *Journal of Water Process Engineering*, 2022, 48: 102897.
- [31] Liu Y, Ge Z Q. Weighted random forests for fault classification in industrial processes with hierarchical clustering model selection[J]. *Journal of Process Control*, 2018, 64: 62-70.
- [32] Yan A J, Guo J C, Wang D H. Heterogeneous feature ensemble modeling with stochastic configuration networks for predicting furnace temperature of a municipal solid waste incineration process[J]. *Neural Computing and Applications*, 2022, 34(18): 15807-15819.
- [33] Zhang X M, Kano M, Matsuzaki S. Ensemble pattern trees for predicting hot metal temperature in blast furnace[J]. *Computers & Chemical Engineering*, 2019, 121: 442-449.
- [34] Zhao L J, Yuan D C, Chai T Y, et al. KPCA and ELM ensemble modeling of wastewater effluent quality indices[J]. *Procedia Engineering*, 2011, 15: 5558-5562.
- [35] Su X L, Zhang S, Yin Y X, et al. Prediction model of hot metal temperature for blast furnace based on improved multi-layer extreme learning machine[J]. *International Journal of Machine Learning and Cybernetics*, 2019, 10(10): 2739-2752.
- [36] Luo S H, Dai Z A, Chen T X, et al. A weighted SVM ensemble predictor based on AdaBoost for blast furnace ironmaking process[J]. *Applied Intelligence*, 2020, 50(7): 1997-2008.
- [37] Yu Z Y, Yousaf K, Ahmad M, et al. Efficient pyrolysis of ginkgo biloba leaf residue and pharmaceutical sludge (mixture) with high production of clean energy: Process optimization by particle swarm optimization and gradient boosting decision tree algorithm[J]. *Bioresource Technology*, 2020, 304: 123020.
- [38] Kheimi M, Almadani M A, Zounemat-Kermani M.

- Simulating wastewater treatment plants for heavy metals using machine learning models[J]. *Arabian Journal of Geosciences*, 2022, 15(17): 1458.
- [39] Ching P M L, Zou X, Wu D, et al. Development of a wide-range soft sensor for predicting wastewater BOD₅ using an eXtreme gradient boosting (XGBoost) machine[J]. *Environmental Research*, 2022, 210: 112953.
- [40] Xia H, Tang J, Aljerf L. Dioxin emission prediction based on improved deep forest regression for municipal solid waste incineration process[J]. *Chemosphere*, 2022, 294: 133716.
- [41] Chen C, Wang N, Chen M, et al. A framework based on heterogeneous ensemble models for liquid steel temperature prediction in LF refining process[J]. *Applied Soft Computing*, 2022, 131: 109724.
- [42] Zhou P, Gao B H, Wang S, et al. Identification of abnormal conditions for fused magnesium melting process based on deep learning and multisource information fusion[J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(3): 3017-3026.
- [43] Nourani V, Asghari P, Sharghi E. Artificial intelligence based ensemble modeling of wastewater treatment plant using jittered data[J]. *Journal of Cleaner Production*, 2021, 291: 125772.
- [44] Chen K, Peng Y Q, Lu S Y, et al. Bagging based ensemble learning approaches for modeling the emission of PCDD/Fs from municipal solid waste incinerators[J]. *Chemosphere*, 2021, 274: 129802.
- [45] Hu H S, Feng D Z, Yang F. A promising nonlinear dimensionality reduction method: Kernel-based within class collaborative preserving discriminant projection[J]. *IEEE Signal Processing Letters*, 2020, 27: 2034-2038.
- [46] Liu Z, Han H G, Yang H Y, et al. Knowledge-aided and data-driven fuzzy decision making for sludge bulking[J]. *IEEE Transactions on Fuzzy Systems*, 2023, 31(4): 1189-1201.
- [47] Le D K, Guo M, Yoon J Y. A hybrid CFD—Deep learning methodology to improve the accuracy of cut-off diameter prediction in coarse-grid simulations for cyclone separators[J]. *Journal of Aerosol Science*, 2023, 170: 106143.
- [48] 华丰, 方舟, 邱彤. 乙烯裂解炉反应与传热耦合的智能混合建模与模拟[J]. *化工学报*, 2018, 69(3): 923-930. (Hua F, Fang Z, Qiu T. Recirculation and reaction hybrid intelligent modeling and simulation for industrial ethylene cracking furnace[J]. *CIESC Journal*, 2018, 69(3): 923-930.)
- [49] Yang J, Chai T Y, Luo C M, et al. Intelligent demand forecasting of smelting process using data-driven and mechanism model[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(12): 9745-9755.
- [50] Azarpour A, Borhani T N G, Alwi S R W, et al. A generic hybrid model development for process analysis of industrial fixed-bed catalytic reactors[J]. *Chemical Engineering Research and Design*, 2017, 117: 149-167.
- [51] 郭晶晶, 徐金金, 杜文莉, 等. 自适应迭代混合建模及在碳二加氢过程的应用[J]. *化工学报*, 2018, 69(11): 4814-4822. (Guo J J, Xu J J, Du W L, et al. Self-adaptive iterative hybrid modeling and its application in acetylene hydrogenation process[J]. *CIESC Journal*, 2018, 69(11): 4814-4822.)
- [52] Azadi P, Winz J, Leo E, et al. A hybrid dynamic model for the prediction of molten iron and slag quality indices of a large-scale blast furnace[J]. *Computers & Chemical Engineering*, 2022, 156: 107573.
- [53] Raccuglia P, Elbert K C, Adler P D F, et al. Machine-learning-assisted materials discovery using failed experiments[J]. *Nature*, 2016, 533(7601): 73-76.
- [54] Xiao D, Heaney C E, Mottet L, et al. A reduced order model for turbulent flows in the urban environment using machine learning[J]. *Building and Environment*, 2019, 148: 323-337.
- [55] Mohan A, Gaitonde D. A deep learning based approach to reduced order modeling for turbulent flow control using LSTM neural networks[J/OL]. 2018, arXiv: 1804.09269.
- [56] Amsallem D, Farhat C. Interpolation method for adapting reduced-order models and application to aeroelasticity[J]. *AIAA Journal*, 2008, 46(7): 1803-1813.
- [57] Schäfer P, Caspari A, Kleinhans K, et al. Reduced dynamic modeling approach for rectification columns based on compartmentalization and artificial neural networks[J]. *AIChE Journal*, 2019, 65(5): e16568.
- [58] Sharma N, Liu Y A. A hybrid science-guided machine learning approach for modeling chemical processes: A review[J]. *AIChE Journal*, 2022, 68(5): e17609.
- [59] Adnan A, Mahmud S, Uddin M R, et al. Energy, exergy, exergoeconomic, and environmental(4E) analyses of thermal power plants for municipal solid waste to energy application in Bangladesh[J]. *Waste Management*, 2021, 134: 136-148.
- [60] Zhuang J B, Tang J, Aljerf L. Comprehensive review on mechanism analysis and numerical simulation of municipal solid waste incineration process based on mechanical grate[J]. *Fuel*, 2022, 320: 123826.
- [61] Masuda R, Hashimoto Y, Mulder M, et al. Automation on thermal control of blast furnace[J]. *Digital Chemical Engineering*, 2023, 7: 100085.
- [62] Magnanelli E, Tranås O L, Carlsson P, et al. Dynamic modeling of municipal solid waste incineration[J]. *Energy*, 2020, 209: 118426.
- [63] Yang Y B, Sharifi V N, Swithenbank J. The effect of changing waste compositions on the incineration process of municipal solid wastes in packed-bed systems: A CFD approach[J]. *Progress in Computational Fluid Dynamics, An International Journal*, 2007, 7(1): 3-10.
- [64] Soria J, Gauthier D, Falcoz Q, et al. Local CFD kinetic model of cadmium vaporization during fluid bed incineration of municipal solid waste[J]. *Journal of*

- Hazardous Materials, 2013, 248/249: 276-284.
- [65] Lin H, Ma X Q. Simulation of co-incineration of sewage sludge with municipal solid waste in a grate furnace incinerator[J]. Waste Management, 2012, 32(3): 561-567.
- [66] Wang J F, Xue Y Q, Zhang X X, et al. Numerical study of radiation effect on the municipal solid waste combustion characteristics inside an incinerator[J]. Waste Management, 2015, 44: 116-124.
- [67] Lei Y X, Karimi H R. A digital twin model of three-dimensional shading for simulation of the ironmaking process[J]. Machines, 2022, 10(12): 1122.
- [68] 张学莲, 胡立生, 曹广益. 基于过程数据的动态PLS建模[J]. 系统仿真学报, 2008, 20(10): 2686-2688. (Zhang X L, Hu L S, Cao G Y. Dynamic PLS modeling based on process data[J]. Journal of System Simulation, 2008, 20(10): 2686-2688.)
- [69] 刘学彦, 王昕, 王振雷. 带遗忘因子的线性回归性能评估算法及应用[J]. 控制工程, 2014, 21(6): 867-872. (Liu X Y, Wang X, Wang Z L. Performance assessment algorithm of improved linear regression with forgetting factor (ILR) and its application[J]. Control Engineering of China, 2014, 21(6): 867-872.)
- [70] Baptista M, Sankararaman S, de Medeiros I P, et al. Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling[J]. Computers & Industrial Engineering, 2018, 115: 41-53.
- [71] Zhang X M, Kano M, Matsuzaki S. A comparative study of deep and shallow predictive techniques for hot metal temperature prediction in blast furnace ironmaking[J]. Computers & Chemical Engineering, 2019, 130: 106575.
- [72] 吴恒运, 高林, 田建勇, 等. 基于非对称神经网络结构的电站锅炉智能燃烧控制模型[J]. 热力发电, 2017, 46(12): 6-10. (Wu H Y, Gao L, Tian J Y, et al. Intelligent combustion control model for utility boilers based on asymmetric artificial neural networks[J]. Thermal Power Generation, 2017, 46(12): 6-10.)
- [73] Li X Z, Dong Y F, Chang L, et al. Dynamic hybrid modeling of fuel ethanol fermentation process by integrating biomass concentration XGBoost model and kinetic parameter artificial neural network model into mechanism model[J]. Renewable Energy, 2023, 205: 574-582.
- [74] Zhou H, Yang C J, Sun Y X. A collaborative optimization strategy for energy reduction in ironmaking digital twin[J]. IEEE Access, 2020, 8: 177570-177579.
- [75] Zhou H, Yang C J, Sun Y X. Intelligent ironmaking optimization service on a cloud computing platform by digital twin[J]. Engineering, 2021, 7(9): 1274-1281.
- [76] Zaghoul M S, Achari G. Application of machine learning techniques to model a full-scale wastewater treatment plant with biological nutrient removal[J]. Journal of Environmental Chemical Engineering, 2022, 10(3): 107430.
- [77] Zhao L J, Chai T Y, Yuan D C. Selective ensemble extreme learning machine modeling of effluent quality in wastewater treatment plants[J]. International Journal of Automation and Computing, 2012, 9(6): 627-633.
- [78] Zhou P X, Li Z, Snowling S, et al. A random forest model for inflow prediction at wastewater treatment plants[J]. Stochastic Environmental Research and Risk Assessment, 2019, 33(10): 1781-1792.
- [79] Sadri M S, Mesghali H. A new hybrid ensemble approach for the prediction of effluent total nitrogen from a full-scale wastewater treatment plant using a combined trickling filter-activated sludge system[J]. Environmental Science and Pollution Research, 2023, 30(1): 1622-1639.
- [80] 徐继伟, 杨云. 集成学习方法: 研究综述[J]. 云南大学学报: 自然科学版, 2018, 40(6): 1082-1092. (Xu J W, Yang Y. A survey of ensemble learning approaches[J]. Journal of Yunnan University: Natural Sciences Edition, 2018, 40(6): 1082-1092.)
- [81] Han Z Z, Hossain M M, Wang Y W, et al. Combustion stability monitoring through flame imaging and stacked sparse autoencoder based deep neural network[J]. Applied Energy, 2020, 259: 114159.
- [82] Golkarnarenji G, Naebe M, Badii K, et al. Support vector regression modelling and optimization of energy consumption in carbon fiber production line[J]. Computers & Chemical Engineering, 2018, 109: 276-288.
- [83] Liu S H, Sun W Q. Attention mechanism-aided data- and knowledge-driven soft sensors for predicting blast furnace gas generation[J]. Energy, 2023, 262: 125498.
- [84] Xu Y W, Wu X L, Zhong X B, et al. Mechanism model-based and data-driven approach for the diagnosis of solid oxide fuel cell stack leakage[J]. Applied Energy, 2021, 286: 116508.
- [85] Ni Y L, Xu J N, Zhu C B, et al. Accurate residual capacity estimation of retired LiFePO₄ batteries based on mechanism and data-driven model[J]. Applied Energy, 2022, 305: 117922.
- [86] Liang H P, Yang C H, Huang K, et al. A hybrid first principles and data-driven process monitoring method for zinc smelting roasting process[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-14.
- [87] Lu S W, Zhou P, Chai T Y, et al. Modeling and simulation of whole ball mill grinding plant for integrated control[J]. IEEE Transactions on Automation Science and Engineering, 2014, 11(4): 1004-1019.
- [88] Ren J C, Liu D, Wan Y. Modeling and application of Czochralski silicon single crystal growth process using hybrid model of data-driven and mechanism-based methodologies[J]. Journal of Process Control, 2021, 104: 74-85.
- [89] Ren J C, Liu D, Wan Y. Data-driven and mechanism-based hybrid model for semiconductor silicon monocrystalline quality prediction in the czochralski process[J]. IEEE Transactions on

- Semiconductor Manufacturing, 2022, 35(4): 658-669.
- [90] Mu Y F, Xu Y R, Cao Y, et al. A two-stage scheduling method for integrated community energy system based on a hybrid mechanism and data-driven model[J]. Applied Energy, 2022, 323: 119683.
- [91] Zeng J S, Gao C H, Su H Y. Data-driven predictive control for blast furnace ironmaking process[J]. Computers & Chemical Engineering, 2010, 34(11): 1854-1862.
- [92] Zhou P, Zhang S, Wen L, et al. Kalman filter-based data-driven robust model-free adaptive predictive control of a complicated industrial process[J]. IEEE Transactions on Automation Science and Engineering, 2022, 19(2): 788-803.
- [93] Wang X. A knowledge-and-data-driven soft sensor for predicting air preheater rotor deformation[C]. Chinese Control Conference. Guangzhou, 2019: 525-530.
- [94] Von Stosch M, Oliveira R, Peres J, et al. A general hybrid semi-parametric process control framework[J]. Journal of Process Control, 2012, 22(7): 1171-1181.
- [95] Tomba E, Barolo M, García-Muñoz S. In-silico product formulation design through latent variable model inversion[J]. Chemical Engineering Research and Design, 2014, 92(3): 534-544.
- [96] Duong P L T, Ali W, Kwok E, et al. Uncertainty quantification and global sensitivity analysis of complex chemical process using a generalized polynomial chaos approach[J]. Computers & Chemical Engineering, 2016, 90: 23-30.
- [97] Proppe J, Husch T, Simm G N, et al. Uncertainty quantification for quantum chemical models of complex reaction networks[J]. Faraday Discussions, 2016, 195: 497-520.
- [98] Wang S W, Pillai H S, Xin H L. Bayesian learning of chemisorption for bridging the complexity of electronic descriptors[J]. Nature Communications, 2020, 11: 6132.
- [99] Mou T Y, Pillai H S, Wang S W, et al. Bridging the complexity gap in computational heterogeneous catalysis with machine learning[J]. Nature Catalysis, 2023, 6(2): 122-136.
- [100] 戴鹏. 高炉铁水质量双线性子空间建模及非线性预测控制[D]. 沈阳: 东北大学, 2019.
(Dai P. Bilinear subspace modeling and nonlinear predictive control of molten iron quality indices in blast furnace[D]. Shenyang: Northeastern University, 2019.)
- [101] 李彦瑞, 杨春节, 张瀚文, 等. 流程工业数字孪生关键技术探讨[J]. 自动化学报, 2021, 47(3): 501-514.
(Li Y R, Yang C J, Zhang H W, et al. Discussion on key technologies of digital twin in process industry[J]. Acta Automatica Sinica, 2021, 47(3): 501-514.)

作者简介

乔俊飞(1968—), 男, 教授, 博士生导师, 从事智能控制与智能信息处理、环境感知和保护自动化技术等研究, E-mail: adqiao@bjut.edu.cn;

黄卫民(1997—), 男, 博士生, 从事复杂工业过程特征建模的研究, E-mail: wmhuang@emails.bjut.edu.cn;

丁海旭(1994—), 男, 博士生, 从事城市固废焚烧过程特征建模与智能控制等研究, E-mail: dinghaixu@emails.bjut.edu.cn;

于涛(2000—), 男, 硕士生, 从事城市固废焚烧过程数据驱动建模与智能控制等研究, E-mail: yutao@emails.bjut.edu.cn.



特邀专家 乔俊飞, 北京工业大学教授、副校长。1995~1998年于东北大学攻读并取得博士学位, 教育部“长江学者奖励计划”特聘教授(2014), 国家杰出青年基金获得者(2012), 国家级百千万人才工程入选者(2014), 国务院特殊津贴专家(2013)。现任智能感知与自主控制教育部工程中心主任、智慧环保北京实验室主任。长期从事计算智能与智能优化控制领域研究工作, 以项目负责人正在承担国家自然科学基金创新群体项目、科技创新2030—“新一代人工智能”重大项目等, 在IEEE汇刊、Automatica及自动化学报等国内外权威期刊上发表学术论文百余篇, 授权美国专利、国家发明专利40余项, 研究成果已广泛应用于环保领域生产实践, 获得国家科技进步奖二等奖、吴文俊人工智能科技进步奖一等奖、教育部科技进步奖一等奖等。

专家寄语 桃李芬芳, 万木承泽竞生长。江河奔流, 百川得水总向东。在东北大学百年华诞来临之际, 祝愿母校继往开来、开拓创新, 续写绚丽新华章!