

基于数据的流程工业生产过程指标预测方法综述

陈 龙¹ 刘全利¹ 王霖青¹ 赵 琨¹ 王 伟¹

摘 要 生产过程关键指标的预测对于流程工业生产调度, 安全生产和节能环保有着重要作用. 目前, 已有多种基于工业生产数据提出的生产过程指标预测方法, 主要涉及特征 (变量) 选择, 预测模型构建及其模型参数优化这三方面. 本文分别针对以上三方面论述了基于数据的流程工业生产过程指标预测国内外研究现状, 分析了各种方法的优缺点. 最后, 指出了流程工业生产过程指标预测方法在工业大数据及知识自动化等方面的未来研究方向和前景.

关键词 生产过程, 特征选择, 预测模型, 参数优化, 工业大数据

引用格式 陈龙, 刘全利, 王霖青, 赵琨, 王伟. 基于数据的流程工业生产过程指标预测方法综述. 自动化学报, 2017, 43(6): 944–954

DOI 10.16383/j.aas.2017.c170136

Data-driven Prediction on Performance Indicators in Process Industry: A Survey

CHEN Long¹ LIU Quan-Li¹ WANG Lin-Qing¹ ZHAO Jun¹ WANG Wei¹

Abstract It is of great significance to predict production process indicators in process industry for production scheduling, safety production and energy saving. Currently, various data-driven approaches for predicting these indicators are proposed, including the following three aspects: feature selection, prediction model construction and model parameter optimization. This paper surveys the above three aspects and summaries the merits and demerits of these approaches. Finally, future research directions of production process prediction of key indicators in process industry are suggested with respect to industrial big data and knowledge automation.

Key words Production process, feature selection, prediction model, parameter optimization, industrial big data

Citation Chen Long, Liu Quan-Li, Wang Lin-Qing, Zhao Jun, Wang Wei. Data-driven prediction on performance indicators in process industry: a survey. *Acta Automatica Sinica*, 2017, 43(6): 944–954

流程工业是通过分离、混合、成型或物理、化学变化使生产原材料增值的行业, 其生产过程一般是连续或成批进行, 主要包括化工、冶金、石油、橡胶、轻工、制药等^[1]. 现如今我国流程工业发展迅速, 主要产品产量居世界前列. 以粗钢生产为例, 2015 年全球粗钢产量达到 16.21 亿吨, 其中中国粗钢产量达到 8.038 亿吨, 占全球粗钢总产量的 49.6%^[2]. 然而目前我国流程工业普遍面临着过程结构复杂, 工序设备多, 能耗高等突出问题. 因此, 提高我国流程工业自动化水平以达到降低能耗和提高效率的目标迫在眉睫.

流程工业普遍包含诸多重要的生产过程指标或

变量, 现场操作人员往往会根据经验对某些特别关注的关键指标进行监测, 从而调控整个生产过程, 最终达到稳定生产的目标, 如高炉炼铁过程中铁水温度、硅含量^[3] 以及多种质量指标^[4] 等. 生产过程指标一般分为两类, 一类是生产过程运行参数, 如温度、压力等; 另一类是定义的生产过程指标, 如选矿过程中的精尾矿品位等, 而此类指标往往与其他过程变量之间存在着复杂的非线性关系. 考虑到工业生产过程通常具有非线性和大滞后等特征, 对这些指标的测量往往耗时长, 难以检测, 或根本无法检测, 因此针对其建立有效的数学模型进行实时预测 (估计) 就显得尤为重要^[5]. 另一方面, 从实时生产调度角度来讲, 操作人员希望预先了解某些关键指标的未来变化趋势, 这也使得指标趋势预测成为目前流程工业生产过程监控的重要任务^[6–7]. 传统的生产过程指标预测采用基于机理建模的方法, 此类方法在工艺机理分析的基础上, 依据物料平衡、热量平衡和动力学建立数学模型^[8]. 然而机理建模很大程度上依赖于对过程机理的认知, 由于工业生产常具有非平衡、非稳定和强非线性等特点, 此类机理模型成本高、难度大, 其准确性和可靠性难以保证, 往往存在模型精度低和容易失配等问题^[8].

收稿日期 2017-03-13 录用日期 2017-05-06
Manuscript received March 13, 2017; accepted May 6, 2017
国家自然科学基金 (61473056, 61533005, 61522304, U1560102), 国家科技支撑计划 (2015BAF22B01), 中央高校基本科研基金 (DUT16RC(3)031) 资助
Supported by National Natural Science Foundation of China (61473056, 61533005, 61522304, U1560102), National Key Technology Support Program (2015BAF22B01), Fundamental Research Funds for the Central Universities (DUT16RC(3)031)
本文责任编辑 侯忠生
Recommended by Associate Editor HOU Zhong-Sheng
1. 大连理工大学控制科学与工程学院 大连 116024
1. School of Control Science and Engineering, Dalian University of Technology, Dalian 116024

随着计算机和网络技术的发展, 流程工业企业基于监控与数据采集系统 (Supervisory control and data acquisition, SCADA) 获取了大量涉及生产过程特点、设备、质量和能源的历史数据. 目前基于数据的方法成为较盛行的生产过程指标预测方法, 此类方法通过建立输入-输出数据变量间的关系模型完成预测任务, 而无需对生产过程的反应或动力学等机理信息进行研究. 通常基于数据的生产过程指标预测过程包含三个方面, 即 1) 特征 (变量) 选择; 2) 预测模型建立; 3) 模型参数优化. 特征 (变量) 选择过程指从大量的候选输入特征中挑选出与预测指标最相关的特征作为预测模型的输入变量. 通常数据特征选择包括经验知识手动选择和基于数据分析的选择方法. 基于经验知识的方法虽然方便快捷, 但时常会因经验不足出现错选漏选或特征冗余的情况. 基于数据的预测建模可采用机器学习方法 (如人工神经网络^[9]、支持向量机^[10] 等) 来完成, 与机理模型不同的是此类方法只关注模型的输入和输出. 模型的输入是选择的相关特征变量, 模型输出即是待预测的关键指标. 预测模型参数选取对模型精度影响较大, 模型参数优化过程通常以减小预测误差为目标, 使模型获得较好的预测精度. 最常见的模型参数优化方法有基于梯度的方法, 如梯度下降法^[11]、共轭梯度法^[11] 等; 智能优化方法如遗传算法^[12]、模拟退火算法^[13] 等. 图 1 给出了基于数据的生产过程指标预测方法的基本流程.




图 1 基于数据生产关键指标预测的基本流程图

Fig. 1 A flow chart of data-based prediction on performance indicators in process industry

本文针对目前基于数据的生产过程指标预测在上述三个方面进行综述, 并结合当前最新的机器学习技术、自动化发展趋势以及工业过程的需求, 探讨基于工业数据的生产过程指标预测方法的可能发展方向.

1 生产过程指标的特征 (变量) 选择

被预测的指标值往往与生产过程中的多个过程变量相关, 进行生产过程指标预测首先需将与被预测指标最相关的特征变量从众多候选变量中挑选出来. 以热轧生产过程为例, 针对板带厚度的预测问题, 经过特征选择最终得到影响板带厚度的输入因素多达 20 个^[14]. 基于数据的特征选择根据是否独立于后续的建模算法, 可分为过滤式 (Filter) 和封装式 (Wrapper) 两种^[15]. 过滤式特征选择的基本思路是采用一种评价准则来增强特征与输出的相关性, 削减各个特征之间的相关性从而选择最相关特征, 再将被选择的最相关特征参与建模. 而封装式方法则将特征选择步骤与建模过程融合, 其缺点在于与过滤式方法相比较为耗时. 目前, 应用在工业生产过程中的特征选择方法有过滤式方法, 如基于相关性分析的方法^[16-19] 等; 封装式方法, 如变量修剪方法^[20]、基于遗传算法的方法^[21] 等.

基于相关性分析的方法如灰色关联分析法^[22], 其基本思路是通过线性插值将时间离散观测值转化为分段连续的折线, 进而根据折线的几何特征构造测度关联程度模型来评价各状态变量之间的关联程度. 如文献 [23] 针对烧结过程中烧结质量的预测问题, 将 8 个过程变量分别与烧结质量进行灰色关联分析, 并最终挑选了 4 个与烧结质量最相关的因素来作为预测模型的输入. 文献 [24] 针对钢铁工业转炉煤气系统中煤气柜位预测问题提出了一种一致 T 型灰色关联分析算法来确定转炉煤气柜位的主要影响因素. 文献 [25] 针对炼焦生产过程综合生产指标 (焦炭质量、产量和焦炉能耗) 预测, 采用主元分析和灰色关联分析确定了神经网络预测模型的输入输出因素. 针对硫酸锌溶液净化过程中钴离子浓度预测^[26] 和高炉炉温预测^[27] 问题, 灰色关联方法表现出较好的精度优势. 此外, 基于 F 评分的方法也是一类基于相关性分析的特征选择方法^[19], 该方法通过定义一种 F 评分来表示每个输入特征与输出之间的相关程度, F 值越大说明该特征与输出的相关性越大. 如文献 [28] 针对高炉炉温变化趋势预测问题, 提出了一种依次验证和 F 评分方法相结合的特征选择方法, 从所有的高炉炼铁过程变量中找出与炉温变化趋势最相关的 8 个输入特征. 目前大部分基于相关性分析的特征选择方法仅仅分析了候选特征与被预测指标之间的关联性, 而未考虑各输入特征之间可能存在的联系, 从而导致选出的特征中存在冗余, 也会在一定程度上影响预测模型的建模效率.

变量修剪算法是一种封装式特征选择方法, 其思路是基于前馈神经网络回归模型从复杂的初始模型出发, 以最小化预测误差为目标, 通过逐个将相

应输入权值设置为零来剔除不相关变量^[20]。该算法在修剪输入变量的同时优化模型的网络结构(隐含节点数目)。如针对高炉铁水硅含量预测问题,文献[29–30]分别采用前馈神经网络模型作为基础预测模型,并采用变量修剪算法来去除不相关变量,最终找到了影响铁水硅含量的主要输入因素。此外,基于遗传算法的封装式方法是将候选特征随机构造预测模型组成种群并进行遗传操作来选择最优的输入特征。如文献[31]提出了一种基于遗传算法优化的神经网络非线性建模算法,建模过程中采用遗传算法同时最小化预测误差和模型复杂度两个目标,从而得到最优输入特征组合和网络结构,并将其应用到高炉炼铁过程中的铁水硅含量预测问题。文献[21]针对石油化学制品工业中的质量指标预测问题,将候选输入变量随机构造的一系列预测模型组成一个种群,以最小化预测误差为目标,通过类似遗传算法的策略来找到最优的候选变量组合。封装式特征选择方法由于以最小化预测误差为目标进行特征选择,其预测精度可能优于基于相关性分析的方法,但是由于其在建模过程中融入了特征选择步骤,算法的时间成本也相对较高。以上针对特定工业应用的无论是基于相关性分析的方法还是封装式特征选择方法大都是以离线的方式完成,这对于具有时变特性的工业生产过程并不总是适合。因此针对实际工业问题开展实时在线式的特征选择对基于数据的特征选择方法尚具有一定的挑战。

2 生产过程指标预测建模

针对工业生产过程建模问题,传统基于物理、化学机理建立精确数学模型的方法已越来越困难。而相当数量的工业企业每天都在产生并存储着大量隐含工艺变动和设备运行等信息的生产、设备和过程数据,如何有效利用大量的离线、在线数据和知识,在难于建立系统机理模型的情况下,实现对生产过程和设备的优化控制和评价,已成为迫切需要解决的问题。数据驱动的方法是解决机理不明确或含不确定性机理模型对象建模问题的有效方法^[32],此类方法利用离线、在线数据来描述对象的运行规律和相关模式,并结合反映系统参数、结构等数据,来实现复杂系统的建模^[33]。近年来,针对工业系统的指标预测问题,已有不少数据驱动方法(如迭代学习^[34]、无模型自适应方法^[35]和自适应动态规划^[36]等)被提出。基于数据的预测建模方法中,根据是否嵌入了机理模型,可将建模方法分为基于数据的方法和数据-机理相结合的方法。

2.1 基于数据的预测建模

机器学习技术的发展为基于数据的生产过程指

标预测奠定了建模基础。如针对炼铁过程铁水硅含量预测、产品质量指标预测、选矿生产指标预测等问题^[37–39]。较为常用的方法如人工神经网络^[40]、支持向量机^[41]、高斯过程回归方法^[42]以及偏最小二乘回归方法^[43]等。文献[44]针对铁水硅含量预测,通过联合人工神经网络和定性分析的方法建立预测模型。文献[45–46]采用人工神经网络分别对钢板轧制过程中的轧制力和串联轧制机组的震颤进行了预测。文献[47]针对高炉炼铁过程中的硅含量变化趋势预测,提出了二编码支持向量机模型。基于偏最小二乘回归方法和核偏最小二乘法的预测模型也应用于化工生产过程的产品质量^[48]和铜转炉吹炼过程的关键操作参数预测^[49]。基于混沌的多步迭代预测和基于 AdaBoost 的预测模型也分别应用于铁水硅含量预测^[50]和选矿生产指标预测^[51]中。此外,基于数据的预测模型不仅被应用在生产监控与调度需求中,也被应用在预测优化控制中^[52–53],而采用基于数据的机器学习方法(如人工神经网络、支持向量机等)来进行预测建模是当前较为流行的方法^[54–58]。其基本思路是将当前时刻的系统输入值和真实输出值作为基于数据预测模型的输入来预测系统的输出,并将此预测输出值反馈到系统输入端以进行滚动优化。此类方法充分利用了机器学习技术较强的非线性拟合能力,而无需关注系统内在机理,具有较强的可应用性;但却需要大量的历史数据来作为预测模型的建模基础。

根据生产过程中不同的预测需求或不同的生产状况,基于数据的预测建模通常有以下几种分类方法。根据预测时长需求,可分为长期预测模型和短期预测模型;根据预测输出指标的数量,可分为多输出预测和单输出预测;根据模型中是否考虑时滞因素,可以分为时滞因素模型和非时滞模型;根据是否有在线更新模型参数,可分为离线模型和在线模型;根据是否使用单一的机器学习预测模型,可以分为多模型集成和单一模型等。下面将重点综述几类预测建模问题,包括长期预测模型、多输出模型、时滞因素模型、在线预测模型、集成预测模型和时间序列预测模型。

1) 长期预测模型

流程工业生产中为了达到生产资源的合理配置,通常需要一个相对长期生产规划(如天、月等),因此对生产过程指标的长期预测就显得尤为重要。短期预测一般采用单步迭代的方法,然而此方法应用在长期预测问题时预测误差会随着迭代步数的增加而积累,导致最终的误差很大^[59–61]。如文献[61]针对转炉煤气流量的长期预测,提出了一种基于钢铁生产状态估计的转炉煤气流量长期预测方法,通过特征提取和特征融合得到全局性特征,利用全局性特

征来实现转炉煤气流量的长期预测. 文献 [62] 提出粒度时间序列的概念, 并采用模糊聚类方法构造时间粒度以进行长期趋势预测. 针对钢铁能源系统的副产煤气流量长期预测问题, 文献 [63] 提出了一种基于粒度计算的长期预测方法, 通过对工业原始数据根据过程操作工艺进行时间上的粒度划分, 采用动态时间弯曲技术和模糊聚类产生类别实现长期预测. 而文献 [64] 针对钢铁工业中氧氮能源系统的调度问题, 采取了预测-调度两阶段的调度方法, 其中长期预测部分同样采用了基于时间粒度划分的方法.

基于时间粒度划分的方法虽然可以有效地避免单步迭代预测带来的误差积累问题, 但是以上文献中的时间粒度划分都是采用人工划分的方式, 极度依赖于人工经验, 粒度划分的效果很难科学评判, 而且难以推广到其他工业应用, 有一定的局限性. 因此更智能的自动划分方法以及更合理的粒度划分评判方法是目前研究的重点^[63].

2) 多输出预测模型

工业生产过程往往需要同时关注多个关键预测指标, 分别对各个指标建立预测模型的方法会丢失被预测指标之间的内在关联耦合信息, 从而导致预测精度不高. 如钢铁工业转炉炼钢生产中, 文献 [24, 65] 针对两个转炉煤气柜柜位预测, 考虑两个煤气柜之间的相互关联影响, 建立了多输出最小二乘支持向量机预测模型. 文献 [66] 针对转炉煤气柜柜位的长期预测问题, 提出采用基于粒度计算的协作式模糊聚类方法建立了两柜位长期预测模型. 文献 [67] 针对高炉炼铁过程中的四个关键质量指标 (铁水温度、硅含量、硫含量和磷含量) 的预测问题, 建立了基于建模精度综合评价与遗传参数优化的铁水质量多输出支持向量回归动态预测模型. 文献 [68] 采用多输出最小二乘支持向量机同时预测氧化铝蒸发过程的全碱浓度、氧铝浓度和苛碱浓度. 在以上的工业预测应用中多输出预测模型都提高了模型预测精度.

3) 时滞因素模型

流程工业生产过程通常具有时滞性, 输入变量的变化往往需要经过一段时间才能反映到被预测指标上, 如选矿过程、钢铁生产过程等. 一方面预测建模需将输入变量的时滞性考虑在预测建模中; 另一方面被预测指标本身通常具有连续性, 其当前时刻取值与历史时刻值有着相互关联, 考虑输入输出闭环联系, 通常需将被预测指标历史时刻的变量值作为模型的输入特征来进行建模. 如文献 [69] 针对高炉煤气系统柜位波动的建模问题, 将前一时刻的高炉煤气柜柜位值添加到预测模型的输入向量中进行了 T-S 模糊预测建模. 对于炼钢转炉煤气柜柜位预测, 也需要将历史时刻的柜位值反馈到输入变量

中以形成输入输出闭环联系^[24, 65]. 文献 [70—71] 分别针对高炉炼铁过程多元铁水质量预测问题和铁水温度预测问题, 考虑到炼铁过程中的时滞性质, 将相关输入输出变量的时序和时滞关系融合到建模过程. 文献 [31] 考虑了 5 小时的输入延迟影响, 针对高炉铁水硅含量预测问题, 将输入变量的时滞影响考虑到模型中, 提高了预测精度. 然而此种考虑输入延迟的方法的关键在于选定输入变量的延迟时间, 这对于模型的性能有着重要影响. 但目前文献中通常基于人工经验来手动选取延迟时间, 预测模型建模的效果往往是难以保证的.

4) 在线预测模型

在线模型是将采集的新样本不断参与到现有模型的再训练中, 此类预测模型的内部参数会根据新样本实时更新, 模型会实时反映新的工况, 从而提高预测精度. 如文献 [72] 针对选矿过程精矿品位的预测问题, 提出了一种自适应在线支持向量机预测模型. 模型依据新工况样本对现有样本集统计特性的影响, 引入了模型参数自适应调整机制, 并采用在线迭代学习机制更新模型. 文献 [73] 针对湿法炼锌净化过程中杂质离子浓度预测问题, 提出了基于在线支持向量回归的离子浓度预测模型. 另外, 文献 [74] 针对全厂级的产品质量指标预测问题, 提出了一种根据训练样本的统计特性能在线更新参数的支持向量机预测模型. 文献 [75] 针对转炉煤气系统中煤气柜柜位和煤气流量的预测问题, 提出了一种基于最小二乘支持向量机预测模型. 其中模型的参数优化采用了一种并行化的粒子群和并行验证方法, 实现了模型参数快速的在线更新.

5) 集成预测模型

单一的机器学习预测模型通常有性能不稳定, 对模型参数敏感, 易过拟合等缺点. 而采集的工业数据通常可看作是几种不同的生产状态相叠加而产生的序列, 因此单一预测模型并不能完全反映多状态数据的变化特性. 如文献 [76] 针对赤铁矿选生产率预测问题, 提出使用多个最小二乘支持向量机模型对聚类后的数据 (每一类可以看作一个工况) 进行建模再进行加权组合. 文献 [77] 针对湿法炼锌净化过程中钴离子浓度预测问题, 基于集成建模思想将两个单一支持向量机子模型进行加权集成. 文献 [78—79] 分别针对非线性工业时间序列预测和高炉铁水硅含量的预测问题, 都考虑到单个神经网络模型易过拟合的特点, 提出使用 Bootstrap 方法将多个网络模型集成来构造预测区间 (方差和均值), 以增强模型的稳定性. 针对针铁矿法沉铁过程反应器出口亚铁离子和铁离子浓度的预测问题, 文献 [80] 提出将基于改进差分进化算法参数优化的最小二乘支持向量机预测模型和过程神经网络模型集成来进

行预测. 集成模型提高了单一预测模型的稳定性和预测精度, 但是模型的参数众多, 通常较为复杂, 同时也增加了模型训练时间. 因此, 此类模型大多不适用于在线模型.

6) 时间序列预测模型

时间序列预测方法不需要其他过程变量作为模型的输入, 而是采用自回归的方式通过寻找变量自身历史数据中的变化规律来预测未来的变化趋势. 通常先将时间序列数据集通过相空间重构构造输入输出样本集, 再采用机器学习方法构造预测模型. 它的预测输出值通常采用迭代预测的方式得到. 如文献 [81] 针对高炉煤气发生量的预测问题, 提出一种基于改进回声状态网络的时间序列预测方法. 文献 [82] 设计了基于核函数的动态贝叶斯网络来构造时间序列预测模型. 文献 [83] 针对钢铁生产中蒸汽系统的蒸汽流量预测问题, 提出采用基于贝叶斯回声状态网络模型对蒸汽流量时间序列进行建模. 以上工业时间序列预测模型能够很好地描述工业数据本身的非线性关系, 但如何确定合适的时间序列采样频率也是一个值得研究的问题.

2.2 基于数据与机理的集成预测建模

基于数据的机器学习预测模型在描述输入输出非线性关系方面优势明显, 但此类方法在先验知识处理、模型计算复杂度等方面仍然存在局限性. 为弥补基于数据建模方法的缺点, 基于机理模型和数据模型相结合的方法是一种有益的尝试. 一类方案是将机理模型和基于数据的误差补偿方法相结合来构造预测模型^[84-85]. 该类方法适用于反应机理相对明确的工业过程, 以基于动力学、热力学以及物料平衡、能量平衡的机理模型作为集成建模主体, 利用生产数据建立误差补偿模型, 补偿主体模型输出与实际输出的差值. 如文献 [84] 针对铁钒矿法沉铁过程出口亚铁离子浓度预测, 采用并联方式集成了沉铁过程的机理模型和基于最小二乘支持向量机的输出误差补偿模型. 文献 [85] 针对文献 [84] 中的方法构建了亚铁离子浓度预测模型的在线参数更新策略. 文献 [86] 分析炉内电热转换关系, 利用能量守恒原理建立了产品单吨能耗机理模型, 提出了由基于机理分析的单吨能耗主模型和基于神经网络的误差补偿模型组成的产品单吨能耗混合预报模型. 文献 [87-88] 基于机理模型和神经网络误差补偿模型相结合的建模形式, 分别预测了湿法炼锌过程中的钴离子浓度和氧化铝冶炼过程中的生料浆质量, 所提方法都提高了单独使用机理预测模型的预测精度. 另外一类是将机器学习模型融合到基于有限元分析的钢板轧制机理模型中以降低有限元分析的时间消耗, 其中机器学习模型的训练数据来源于有限元模

拟过程. 如文献 [89] 采用有限元分析和神经网络相结合的建模方法对轧钢过程中的闭合孔隙进行预测. 文献 [90] 结合轧制过程机理分析和基于数据的神经网络模型来预测轧钢过程中的轧制力, 以提高预测精度. 此外, 还有一种方案是将轧制过程的精确数学模型和数据模型相结合. 如文献 [91-92] 针对轧制力预测, 分别将贝叶斯推理和神经网络模型与轧制过程的精确数学模型相结合预测了轧制力.

此类方法仅适用于机理过程相对明确的生产过程, 而现代生产过程越来越复杂, 大部分生产过程并没有一个清晰的机理模型. 因此, 此类建模方法的应用受到了一定的限制. 将复杂生产过程中的局部精确机理模型与数据模型相结合是未来一个研究方向.

3 预测模型的参数优化

基于数据的预测模型通常包含重要的参数, 其选取对于预测模型的性能有着重要影响 (如最小二乘支持向量机的核函数参数和惩罚因子、神经网络中隐含层神经元个数以及学习率等). 针对此类参数的优化方法有基于梯度的方法和智能优化方法等.

3.1 基于梯度的优化方法

基于梯度的优化方法利用目标函数的梯度信息进行优化, 是机器学习中使用较为广泛的方法. 该方法可以建立明确的优化搜索方向, 但对初始值较敏感, 易陷入局部最优. 常用的基于梯度的方法有梯度下降法、共轭梯度法等^[11]. 在工业应用中通常会基于梯度的优化方法和其他方法相结合, 更好地优化模型参数, 如与基于噪声估计的方法^[93-94], 与基于误差密度函数估计的方法^[95], 与网格搜索算法^[96]相结合等.

预测误差一般被认为由工业数据噪声和预测模型的欠精确共同导致, 若将预测误差的方差逼近噪声方差, 那么相当于将模型的误差逼近于零, 这样求得模型参数将会有最优的预测性能. 如文献 [93] 考虑工业噪声对参数的影响, 提出采用一种基于噪声估计和共轭梯度方法来优化最小二乘支持向量机预测模型中的核函数参数和惩罚因子. 文献 [94] 同样采用该方法优化基于核回归的区间预测模型中的惩罚因子、核函数权重以及核函数的宽度等参数. 通过控制误差概率密度函数形状进行参数优化是另一类有效的思路. 如文献 [95] 针对选矿过程中的混合精矿品位预测问题, 将误差的概率密度函数表示成最小二乘支持向量机模型参数 (核函数的宽度和惩罚因子) 的函数, 通过调节此类参数来得到预期的误差概率密度函数, 从而达到优化模型参数的目的. 此外, 在基于交叉验证的网格搜索参数优化方法中会存在反复求逆, 同时缺乏指导的网格遍历搜索会消

耗大量时间, 无法满足现场实时性要求且优化结果也不理想. 而基于梯度的优化方法会指导优化方向, 但同时有易陷入局部最优的缺点. 因此文献 [96] 将以上两种方法相结合, 针对焦炉煤气柜位预测, 提出了一种基于网格搜索和梯度法相结合的参数优化方法. 该方法采用基于快速留一法导出网格梯度搜索方向来避免普通网格搜索方向的盲目性, 从而快速获得了较优的模型参数. 再如文献 [97] 将遗传算法和梯度下降法相结合进行参数优化应用于煤气柜位预测问题.

以上基于梯度的参数优化方法与其他方法相结合能够获得更好的参数优化结果, 然而此类方法存在运算时间长的缺点, 大多不适用于工业生产的在线参数优化, 只能进行离线应用.

3.2 基于智能优化的方法

智能优化算法是一类启发式优化算法^[98-100], 此类方法都是从任一解出发, 按照某种机制, 以一定的概率在整个求解空间中探索最优解. 智能优化算法广泛应用于基于数据的预测模型参数优化问题^[97, 101-104], 且多数应用以最小化预测误差为优化目标. 如文献 [101-102] 分别针对高炉铁水硅含量预测问题, 提出一种基于混沌粒子群优化的支持向量回归机参数优化算法. 文献 [103] 针对铜闪速熔炼过程中冰铜温度、冰铜品位及渣中铁硅质量比三个关键工艺指标的预测, 采用了实数编码的加速遗传算法来优化投影寻踪回归预测模型的参数. 针对石油工业中的二氧化碳腐蚀率的预测问题, 有学者采用了模拟退火算法来优化最小二乘支持向量机预测模型的参数^[104]. 文献 [65, 75] 分别采用粒子群算法和并行粒子群算法优化了最小二乘支持向量机的参数. 文献 [82] 采用模拟退火算法优化了基于核函数动态贝叶斯网的核函数参数. 此外, 遗传算法还被用来优化支持向量机的参数^[26, 67]. 上述智能算法虽然在参数优化过程中容易获得全局最优解, 但是它们应用在工业生产过程参数优化问题中依然存在较高的不确定性, 没有最优搜索方向以及计算复杂度较高等缺点.

4 结论与展望

现有基于数据的生产过程指标预测方法尽管研究成果已较为丰硕, 但是依然存在以下问题. 1) 现有模型虽然对于工况稳定的生产指标预测有着较好的预测效果, 然而多数生产过程是时变过程, 且经常受人为干扰. 而现有预测模型本身大多不能自动地识别工业过程中的时变特性, 进而导致基于数据的预测模型精度不高. 因此, 通过工业大数据分析有效识别这种时变特性是一个关键研究问题. 2) 对

于一个特定的预测模型, 其预测结果的误差通常是由工业噪声以及模型本身的不准确两部分因素导致. 鉴于工业噪声难以避免, 因此消除模型本身所带来的误差也是一个值得研究的问题.

近年来也有一些新的机器学习方法在工业过程指标预测方面的研究进展值得关注. 深度学习技术是机器学习领域新的研究方向, 在语音识别、计算机视觉等领域取得了突破性的进展应用, 尽管深度学习在时间序列预测问题方面已有探索^[105-108], 但在特定工业预测应用方面的研究还很少. 通过采用深度学习自动提取得到层次化的工业数据特征表示, 再基于挖掘到的深层次生产特征构造工业长期预测模型是未来预测方法可能的一个研究方向. 但目前还存在以下 2 个难点: 1) 深度学习模型参数选取; 2) 深度学习特征评价.

无模型预测逐渐成为学者研究的焦点^[109-110], 其特点是无需依赖具体的预测模型, 而是通过统计观测数据的方法来估计未来数据的变化趋势. 此方法可有效消除由预测模型带来的模型误差, 因此, 将无模型预测方法应用到工业生产过程实际预测问题(如长期预测等)是未来另一个值得研究的方向.

知识自动化是近年来自动化领域发展的新方向^[111], 基于知识的预测方法在某些领域也已形成具体的应用^[112-114]. 生产过程知识表示与获取, 以及基于生产知识的预测模型构建等是基于知识自动化的生产过程指标预测方法的关键研究内容.

自适应动态规划方法利用一个函数近似结构(例如神经网络、模糊模型、多项式等)来估计代价函数, 用于按时间正向求解动态规划问题^[115], 基于此方法的工业过程预测也形成一些具体应用^[116-117]. 将来基于自适应动态规划预测方法的一个研究方向是深入探究将抽象为智能体的生产过程与外部环境信息相交互的机制融入预测建模过程以提高预测精度.

References

- 1 Gui Wei-Hua, Wang Cheng-Hong, Xie Yong-Fang, Song Su, Meng Qing-Feng, Ding Jin-Liang. The necessary way to realize great-leap-forward development of process industries. *Bulletin of National Natural Science Foundation of China*, 2015, (5): 337-342
(桂卫华, 王成红, 谢永芳, 宋苏, 孟庆峰, 丁进良. 流程工业实现跨越式发展的必由之路. 中国科学基金, 2015, (5): 337-342)
- 2 中商智业. 2016 年度全球钢铁生产大数据分析 [Online], available: <http://mt.sohu.com/20161110/n472825318.shtml>, November 10, 2016.
- 3 Saxén H, Gao C H, Gao Z W. Data-driven time discrete models for dynamic prediction of the hot metal silicon content in the blast furnace — a review. *IEEE Transactions on Industrial Informatics*, 2013, 9(4): 2213-2225
- 4 Kim S I, Kim K E, Park E K, Song S W, Jung S. Estimation methods for efficiency of additive in removing impu-


- rity in hydrometallurgical purification process. *Hydrometallurgy*, 2007, **89**(3–4): 242–252
- 5 Shang Xiu-Qin, Lu Jian-Gang, Sun You-Xian. Genetic programming based two-term prediction model of iron ore burning through point. *Journal of Zhejiang University (Engineering Science)*, 2010, **44**(7): 1266–1269, 1281
(商秀芹, 卢建刚, 孙优贤. 基于遗传规划的铁矿烧结终点 2 级预测模型. 浙江大学学报(工学版), 2010, **44**(7): 1266–1269, 1281)
 - 6 Zhang B, Yang C H, Li Y G, Wang X L, Zhu H Q, Gui W H. Additive requirement ratio prediction using trend distribution features for hydrometallurgical purification processes. *Control Engineering Practice*, 2016, **46**: 10–25
 - 7 Zhao J, Liu Q L, Wang W, Pedrycz W, Cong L Q. Hybrid neural prediction and optimized adjustment for coke oven gas system in steel industry. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, **23**(3): 439–450
 - 8 Zhou Xiao-Jun, Yang Chun-Hua, Gui Wei-Hua. Modeling and control of nonferrous metallurgical processes on the perspective of global optimization. *Control Theory & Applications*, 2015, **32**(9): 1158–1169
(周晓君, 阳春华, 桂卫华. 全局优化视角下的有色冶金过程建模与控制. 控制理论与应用, 2015, **32**(9): 1158–1169)
 - 9 Remes A, Vaara N, Saloheimo K, Koivo H. Prediction of concentrate grade in industrial gravity separation plant-comparison of rPLS and neural network. *IFAC Proceedings Volumes*, 2008, **41**(2): 3280–3285
 - 10 Wang Jun-Kai, Qiao Fei, Zhu Jun, Ni Jia-Cheng. SVR-based predictive models of energy consumption and performance criteria for sintering. *Journal of Tongji University (Natural Science)*, 2014, **42**(8): 1256–1260
(王俊凯, 乔非, 祝军, 倪嘉呈. 基于支持向量机的烧结能耗及性能指标预测模型. 同济大学学报(自然科学版), 2014, **42**(8): 1256–1260)
 - 11 Asorey-Cacheda R, Garcia-Sanchez A J, Garcia-Sanchez F, Garcia-Haro J. A survey on non-linear optimization problems in wireless sensor networks. *Journal of Network and Computer Applications*, 2017, **82**: 1–20
 - 12 Korayem M H, Hoshier A K, Nazarahari M. A hybrid co-evolutionary genetic algorithm for multiple nanoparticle assembly task path planning. *International Journal of Advanced Manufacturing Technology*, 2016, **87**(9–12): 3527–3543
 - 13 Xavier-De-Souza S, Suykens J A K, Vandewalle J, Bolle D. Coupled simulated annealing. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2010, **40**(2): 320–335
 - 14 Ding S X, Yin S, Peng K X, Hao H Y, Shen B. A novel scheme for key performance indicator prediction and diagnosis with application to an industrial hot strip mill. *IEEE Transactions on Industrial Informatics*, 2013, **9**(4): 2239–2247
 - 15 Wang L P, Wang Y L, Chang Q. Feature selection methods for big data bioinformatics: a survey from the search perspective. *Methods*, 2016, **111**: 21–31
 - 16 Jiang Zhao-Hui, Yin Ju-Ping, Gui Wei-Hua, Yang Chun-Hua. Prediction for blast furnace silicon content in hot metal based on composite differential evolution algorithm and extreme learning machine. *Control Theory & Applications*, 2016, **33**(8): 1089–1095
(蒋朝辉, 尹菊萍, 桂卫华, 阳春华. 基于复合差分进化算法与极限学习机的高炉铁水硅含量预报. 控制理论与应用, 2016, **33**(8): 1089–1095)
 - 17 Singh V, Tathavadkar V, Rao S M, Raju K S. Predicting the performance of submerged arc furnace with varied raw material combinations using artificial neural network. *Journal of Materials Processing Technology*, 2007, **183**(1): 111–116
 - 18 Zhao J, Wang W, Liu Y, Pedrycz W. A two-stage online prediction method for a blast furnace gas system and its application. *IEEE Transactions on Control Systems Technology*, 2011, **19**(3): 507–520
 - 19 Chen Y W, Lin C J. Combining SVMs with various feature selection strategies. *Feature Extraction*. Berlin Heidelberg: Springer, 2006. 315–324
 - 20 Saxén H, Pettersson F. Method for the selection of inputs and structure of feedforward neural networks. *Computers & Chemical Engineering*, 2006, **30**(6–7): 1038–1045
 - 21 Wang D, Liu J, Srinivasan R. Data-driven soft sensor approach for quality prediction in a refining process. *IEEE Transactions on Industrial Informatics*, 2010, **6**(1): 11–17
 - 22 Deng Ju-Long. *A Tutorial on Grey System Theory*. Wuhan: Huazhong University of Science and Technology Press, 1990.
(邓聚龙. 灰色系统理论教程. 武汉: 华中理工大学出版社, 1990.)
 - 23 Wang J S, Wang W. A predictive model of sinter chemical composition and its application. In: Proceedings of the 6th World Congress on Intelligent Control and Automation. Dalian, China: IEEE, 2006. 4856–4860
 - 24 Zhang Xiao-Ping, Zhao Jun, Wang Wei, Feng Wei-Min, Chen Wei-Chang. Multi-output least squares support-vector-machine for level prediction in Linz Donaniz gas holder. *Control Theory & Applications*, 2010, **27**(11): 1463–1470
(张晓平, 赵君, 王伟, 冯为民, 陈伟昌. 转炉煤气柜位的多输出最小二乘支持向量机预测. 控制理论与应用, 2010, **27**(11): 1463–1470)
 - 25 Wang Wei, Wu Min, Lei Qi, Cao Wei-Hua. An improved neural network method for the prediction of comprehensive production indices in coking process. *Control Theory & Applications*, 2009, **26**(12): 1419–1424
(王伟, 吴敏, 雷琪, 曹卫华. 炼焦生产过程综合生产指标的改进神经网络预测方法. 控制理论与应用, 2009, **26**(12): 1419–1424)
 - 26 Yan Mi-Ying, Gui Wei-Hua, Yang Chun-Hua. Prediction on research on cobalt ion concentration based on gray correlation and improved support vector machine. *Chinese Journal of Scientific Instrument*, 2011, **32**(5): 961–967
(晏密英, 桂卫华, 阳春华. 基于灰色关联和改进 SVM 的钴离子浓度预测研究. 仪器仪表学报, 2011, **32**(5): 961–967)
 - 27 Li Ai-Lian, Zhao Yong-Ming, Cui Gui-Mei. Prediction model of blast furnace temperature based on ELM with grey correlation analysis. *Journal of Iron and Steel Research*, 2015, **27**(11): 33–37
(李爱莲, 赵永明, 崔桂梅. 基于灰色关联分析的 ELM 高炉温度预测模型. 钢铁研究学报, 2015, **27**(11): 33–37)
 - 28 Gao C H, Jian L, Luo S H. Modeling of the thermal state change of blast furnace hearth with support vector machines. *IEEE Transactions on Industrial Electronics*, 2012, **59**(2): 1134–1145
 - 29 Saxén H, Pettersson F. Nonlinear prediction of the hot metal silicon content in the blast furnace. *ISIJ International*, 2007, **47**(12): 1732–1737
 - 30 Nurkkala A, Pettersson F, Saxén H. Nonlinear modeling method applied to prediction of hot metal silicon in the iron-making blast furnace. *Industrial & Engineering Chemistry Research*, 2011, **50**(15): 9236–9248

- 31 Saxén H, Pettersson F, Gunturu K. Evolving nonlinear time-series models of the hot metal silicon content in the blast furnace. *Materials and Manufacturing Processes*, 2007, **22**(5): 577–584
- 32 Hou Zhong-Sheng, Xu Jian-Xin. On data-driven control theory: the state of the art and perspective. *Acta Automatica Sinica*, 2009, **35**(6): 650–667
(侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望. 自动化学报, 2009, **35**(6): 650–667)
- 33 Shi Yun-Tao, Yang Zhen-An, Li Zhi-Jun, Sun De-Hui, Liu Da-Qian. Method of hybrid system modeling and optimizing control based on data-driven. *Journal of System Simulation*, 2013, **25**(11): 2709–2716
(史运涛, 杨震安, 李志军, 孙德辉, 刘大千. 基于数据驱动的混杂系统建模与优化控制研究. 系统仿真学报, 2013, **25**(11): 2709–2716)
- 34 Bu Xu-Hui, Yu Fa-Shan, Hou Zhong-Sheng, Wang Fu-Zhong. Iterative learning control for a class of linear discrete-time switched systems. *Acta Automatica Sinica*, 2013, **39**(9): 1564–1569
(卜旭辉, 余发山, 侯忠生, 王福忠. 一类线性离散切换系统的迭代学习控制 (英文). 自动化学报, 2013, **39**(9): 1564–1569)
- 35 Hou Zhong-Sheng, Dong Hang-Rui, Jin Shang-Tai. Model-free adaptive control with coordinates compensation for automatic car parking systems. *Acta Automatica Sinica*, 2015, **41**(4): 823–831
(侯忠生, 董航瑞, 金尚泰. 基于坐标补偿的自动泊车系统无模型自适应控制. 自动化学报, 2015, **41**(4): 823–831)
- 36 Wang Kang, Li Xiao-Li, Jia Chao, Song Gui-Zhi. Optimal tracking control for slag grinding process based on adaptive dynamic programming. *Acta Automatica Sinica*, 2016, **42**(10): 1542–1551
(王康, 李晓理, 贾超, 宋桂芝. 基于自适应动态规划的矿渣微粉生产过程跟踪控制. 自动化学报, 2016, **42**(10): 1542–1551)
- 37 Wang B, Fang Y, Sheng J F, Gui W H, Sun Y. BTP prediction model based on ANN and regression analysis. In: *Proceedings of the 2nd International Workshop on Knowledge Discovery and Data Mining*. Moscow, Russia: IEEE, 2009. 108–111
- 38 Nakhaei F, Mosavi M R, Sam A, Vaghei Y. Recovery and grade accurate prediction of pilot plant flotation column concentrate: neural network and statistical techniques. *International Journal of Mineral Processing*, 2012, **110**–**111**: 140–154
- 39 Nakhaei F, Sam A, Mosavi M R, Zeidabadi S. Prediction of copper grade at flotation column concentrate using Artificial Neural Network. In: *Proceedings of the 10th IEEE International Conference on Signal Processing (ICSP)*. Beijing, China: IEEE, 2010. 1421–1424
- 40 Er M J, Liao J, Lin J Y. Fuzzy neural networks-based quality prediction system for sintering process. *IEEE Transactions on Fuzzy Systems*, 2000, **8**(3): 314–324
- 41 Jian L, Gao C H, Li L, Zeng J S. Application of least squares support vector machines to predict the silicon content in blast furnace hot metal. *ISIJ International*, 2008, **48**(11): 1659–1661
- 42 Jiang S L, Liu M, Lin J H, Zhong H X. A prediction-based online soft scheduling algorithm for the real-world steelmaking-continuous casting production. *Knowledge-Based Systems*, 2016, **111**: 159–172
- 43 Bhattacharya T. Prediction of silicon content in blast furnace hot metal using partial least squares (PLS). *ISIJ International*, 2005, **45**(12): 1943–1945
- 44 Chen J. A predictive system for blast furnaces by integrating a neural network with qualitative analysis. *Engineering Applications of Artificial Intelligence*, 2001, **14**(1): 77–85
- 45 Rath S, Singh A P, Bhaskar U, Krishna B, Santra B K, Rai D, Neogi N. Artificial neural network modeling for prediction of roll force during plate rolling process. *Materials and Manufacturing Processes*, 2010, **25**(1–3): 149–153
- 46 Haghani A, Khoogar A R, Kumarci F. Predicting strip tearing in cold rolling tandem mill using neural network. *International Journal of Advanced Design and Manufacturing Technology*, 2015, **8**(1): 67–75
- 47 Jian L, Gao C H. Binary coding SVMs for the multiclass problem of blast furnace system. *IEEE Transactions on Industrial Electronics*, 2013, **60**(9): 3846–3856
- 48 Vanlaer J, Gins G, Van Impe J F M. Quality assessment of a variance estimator for partial least squares prediction of batch-end quality. *Computers & Chemical Engineering*, 2013, **52**(52): 230–239
- 49 Song Hai-Ying, Gui Wei-Hua, Yang Chun-Hua, Peng Xiao-Qi. Application of dynamical prediction model based on kernel partial least squares for copper converting. *The Chinese Journal of Nonferrous Metals*, 2007, **17**(7): 1201–1206
(宋海鹰, 桂卫华, 阳春华, 彭小奇. 基于核偏最小二乘法的动态预测模型在铜转炉吹炼中的应用. 中国有色金属学报, 2007, **17**(7): 1201–1206)
- 50 Gao C H, Chen J M, Zeng J S, Liu X Y, Sun Y X. A chaos-based iterated multistep predictor for blast furnace ironmaking process. *AIChE Journal*, 2009, **55**(4): 947–962
- 51 Liu C X, Ding J L, Chai T Y. Robust prediction for quality of industrial processes. In: *Proceedings of 2014 IEEE International Conference on Information and Automation (ICIA)*. Hailar, China: IEEE, 2014. 1172–1175
- 52 Sossan F, Namor E, Cherkaoui R, Paolone M. Achieving the dispatchability of distribution feeders through prosumers data driven forecasting and model predictive control of electrochemical storage. *IEEE Transactions on Sustainable Energy*, 2016, **7**(4): 1762–1777
- 53 Xiong Wei, Li Bing, Chen Jun, Zhou Hua-Yu. A self-adaptation approach based on predictive control for SaaS. *Chinese Journal of Computers*, 2016, **39**(2): 364–376
(熊伟, 李兵, 陈军, 周华昱. 一种基于预测控制的 SaaS 系统自适应方法. 计算机学报, 2016, **39**(2): 364–376)
- 54 Reese B M, Collins Jr E G. A graph search and neural network approach to adaptive nonlinear model predictive control. *Engineering Applications of Artificial Intelligence*, 2016, **55**: 250–268
- 55 Han H G, Zhang L, Hou Y, Qiao J F. Nonlinear model predictive control based on a self-organizing recurrent neural network. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, **27**(2): 402–415
- 56 Feng K, Lu J G, Chen J S. Nonlinear model predictive control based on support vector machine and genetic algorithm. *Chinese Journal of Chemical Engineering*, 2015, **23**(12): 2048–2052

- 57 Ekkachai K, Nilkhamhang I. Swing phase control of semi-active prosthetic knee using neural network predictive control with particle swarm optimization. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2016, **24**(11): 1169–1178
- 58 Wang D C, Lin H. A new class of dual support vector machine NPID controller used for predictive control. *IEEE Transactions on Electrical and Electronic Engineering*, 2015, **10**(4): 453–457
- 59 Pedrycz W, Chen S M. *Information Granularity, Big Data, and Computational Intelligence*. Switzerland: Springer International Publishing, 2015.
- 60 Zhou Z, Xu Z W, Wu W B. Long-term prediction intervals of time series. *IEEE Transactions on Information Theory*, 2010, **56**(3): 1436–1446
- 61 Tang X Y, Zhao J, Sheng C Y, Wang W. Long term prediction for generation amount of Converter gas based on steel-making production status estimation. In: *Proceedings of the 2014 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. Beijing, China: IEEE, 2014. 1088–1095
- 62 Dong R J, Pedrycz W. A granular time series approach to long-term forecasting and trend forecasting. *Physica A: Statistical Mechanics and Its Applications*, 2008, **387**(13): 3253–3270
- 63 Zhao J, Han Z Y, Pedrycz W, Wang W. Granular model of long-term prediction for energy system in steel industry. *IEEE Transactions on Cybernetics*, 2016, **46**(2): 388–400
- 64 Han Z Y, Zhao J, Wang W, Liu Y. A two-stage method for predicting and scheduling energy in an oxygen/nitrogen system of the steel industry. *Control Engineering Practice*, 2016, **52**: 35–45
- 65 Han Z Y, Liu Y, Zhao J, Wang W. Real time prediction for converter gas tank levels based on multi-output least square support vector regressor. *Control Engineering Practice*, 2012, **20**(12): 1400–1409
- 66 Han Z Y, Zhao J, Liu Q L, Wang W. Granular-computing based hybrid collaborative fuzzy clustering for long-term prediction of multiple gas holders levels. *Information Sciences*, 2016, **330**: 175–185
- 67 Zhou Ping, Li Rui-Feng, Guo Dong-Wei, Wang Hong, Chai Tian-You. Multi-output support vector regression modeling for multivariate molten iron quality indices in blast furnace iron making process. *Control Theory & Applications*, 2016, **33**(6): 727–734
(周平, 李瑞峰, 郭东伟, 王宏, 柴天佑. 高炉炼铁过程多元铁水质量指标多输出支持向量回归建模. *控制理论与应用*, 2016, **33**(6): 727–734)
- 68 Yang Chun-Hua, Nie Xiao-Kui, Chai Qin-Qin, Gui Wei-Hua. Alumina evaporation concentration prediction based on adaptive weighted LS-SVR. *Control Engineering of China*, 2012, **19**(2): 187–190
(阳春华, 聂晓凯, 柴琴琴, 桂卫华. 氧化铝蒸发浓度的自适应加权 LSSVR 预测. *控制工程*, 2012, **19**(2): 187–190)
- 69 Sheng Chun-Yang, Zhao Jun, Wang Wei, Liu Ying. A fuzzy modeling method based on T-S model for blast furnace gas system. *Journal of Shanghai Jiaotong University*, 2012, **46**(12): 1907–1913
(盛春阳, 赵君, 王伟, 刘颖. 基于 T-S 模型的高炉煤气系统模糊建模. *上海交通大学学报*, 2012, **46**(12): 1907–1913)
- 70 Song He-Da, Zhou Ping, Wang Hong, Chai Tian-You. Non-linear subspace modeling of multivariate molten iron quality in blast furnace ironmaking and its application. *Acta Automatica Sinica*, 2016, **42**(11): 1664–1679
(宋贺达, 周平, 王宏, 柴天佑. 高炉炼铁过程多元铁水质量非线性子空间建模及应用. *自动化学报*, 2016, **42**(11): 1664–1679)
- 71 Martín R D, Obeso F, Mochón J, Barea R, Jiménez J. Hot metal temperature prediction in blast furnace using advanced model based on fuzzy logic tools. *Ironmaking & Steelmaking*, 2007, **34**(3): 241–247
- 72 Liu Chang-Xin, Ding Jin-Liang, Jiang Bo, Chai Tian-You. Adaptive online support vector regression prediction model for concentrate grade of the ore-dressing processes. *Control Theory & Applications*, 2014, **31**(3): 386–391
(刘长鑫, 丁进良, 姜波, 柴天佑. 选矿过程精矿品位自适应在线支持向量预测方法. *控制理论与应用*, 2014, **31**(3): 386–391)
- 73 Wang Ling-Yun, Gui Wei-Hua, Liu Mei-Hua, Yang Chun-Hua. Prediction model of ion concentration based on improved online support vector regression. *Control and Decision*, 2009, **24**(4): 537–541
(王凌云, 桂卫华, 刘梅花, 阳春华. 基于改进在线支持向量回归的离子浓度预测模型. *控制与决策*, 2009, **24**(4): 537–541)
- 74 Liu C X, Ding J L, Toprac A J, Chai T Y. Data-based adaptive online prediction model for plant-wide production indices. *Knowledge and Information Systems*, 2014, **41**(2): 401–421
- 75 Zhao J, Wang W, Pedrycz W, Tian X W. Online parameter optimization-based prediction for converter gas system by parallel strategies. *IEEE Transactions on Control Systems Technology*, 2012, **20**(3): 835–845
- 76 Ding J L, Chai T Y, Cheng W J, Zheng X P. Data-based multiple-model prediction of the production rate for hematite ore beneficiation process. *Control Engineering Practice*, 2015, **45**: 219–229
- 77 Yan Mi-Ying, Gui Wei-Hua, Yang Chun-Hua. Prediction model of cobalt ion concentration based on intelligent fusion strategy. *Control and Decision*, 2011, **26**(5): 707–711
(晏密英, 桂卫华, 阳春华. 基于智能融合策略的钴离子浓度预测模型. *控制与决策*, 2011, **26**(5): 707–711)
- 78 Sheng C Y, Zhao J, Wang W, Leung H. Prediction intervals for a noisy nonlinear time series based on a bootstrapping reservoir computing network ensemble. *IEEE Transactions on Neural Networks and Learning Systems*, 2013, **24**(7): 1036–1048
- 79 Jiang Zhao-Hui, Dong Meng-Lin, Gui Wei-Hua, Yang Chun-Hua, Xie Yong-Fang. Two-dimensional prediction for silicon content of hot metal of blast furnace based on bootstrap. *Acta Automatica Sinica*, 2016, **42**(5): 715–723
(蒋朝辉, 董梦林, 桂卫华, 阳春华, 谢永芳. 基于 Bootstrap 的高炉铁水硅含量二维预报. *自动化学报*, 2016, **42**(5): 715–723)
- 80 Xiong Fu-Qiang, Gui Wei-Hua, Yang Chun-Hua. Integrated prediction model of iron concentration in goethite method to remove iron process. *Control and Decision*, 2012, **27**(3): 329–334
(熊富强, 桂卫华, 阳春华. 针铁矿法沉铁过程铁离子浓度集成预测模型. *控制与决策*, 2012, **27**(3): 329–334)
- 81 Liu Ying, Zhao Jun, Wang Wei, Wu Yi-Ping, Chen Wei-Chang. Improved echo state network based on data-driven and its application to prediction of blast furnace gas output. *Acta Automatica Sinica*, 2009, **35**(6): 731–738
(刘颖, 赵君, 王伟, 吴毅平, 陈伟昌. 基于数据的改进回声状态网

- 络在高炉煤气发生量预测中的应用. 自动化学报, 2009, **35**(6): 731–738)
- 82 Chen L, Liu Y, Zhao J, Wang W, Liu Q L. Prediction intervals for industrial data with incomplete input using kernel-based dynamic Bayesian networks. *Artificial Intelligence Review*, 2016, **46**(3): 307–326
 - 83 Liu Y, Liu Q L, Wang W, Zhao J, Leung H. Data-driven based model for flow prediction of steam system in steel industry. *Information Sciences*, 2012, **193**: 104–114
 - 84 Xie Shi-Wen, Xie Yong-Fang, Yang Chun-Hua, Jiang Zhao-Hui, Gui Wei-Hua. A ferrous iron concentration prediction model for the process of iron precipitation by goethite. *Acta Automatica Sinica*, 2014, **40**(5): 830–837
(谢世文, 谢永芳, 阳春华, 蒋朝辉, 桂卫华. 针铁矿法沉铁过程亚铁离子浓度预测. 自动化学报, 2014, **40**(5): 830–837)
 - 85 Xie Y F, Xie S W, Chen X F, Gui W H, Yang C H, Caccetta L. An integrated predictive model with an on-line updating strategy for iron precipitation in zinc hydrometallurgy. *Hydrometallurgy*, 2015, **151**: 62–72
 - 86 Wu Zhi-Wei, Chai Tian-You, Wu Yong-Jian. A hybrid prediction model of energy consumption per ton for fused magnesia. *Acta Automatica Sinica*, 2013, **39**(12): 2002–2011
(吴志伟, 柴天佑, 吴永建. 电熔镁砂产品单吨能耗混合预报模型. 自动化学报, 2013, **39**(12): 2002–2011)
 - 87 Sun B, Gui W H, Wu T B, Wang Y L, Yang C H. An integrated prediction model of cobalt ion concentration based on oxidation-reduction potential. *Hydrometallurgy*, 2013, **140**: 102–110
 - 88 Yang C H, Gui W H, Kong L S, Wang Y L. Modeling and optimal-setting control of blending process in a metallurgical industry. *Computers & Chemical Engineering*, 2009, **33**(7): 1289–1297
 - 89 Chen J, Chandrashekhara K, Mahimkar C, Lekakh S N, Richards V L. Void closure prediction in cold rolling using finite element analysis and neural network. *Journal of Materials Processing Technology*, 2011, **211**(2): 245–255
 - 90 Lin J C. Prediction of rolling force and deformation in three-dimensional cold rolling by using the finite-element method and a neural network. *The International Journal of Advanced Manufacturing Technology*, 2002, **20**(11): 799–806
 - 91 Nelson A W, Malik A S, Wendel J C, Zipf M E. Probabilistic force prediction in cold sheet rolling by Bayesian inference. *Journal of Manufacturing Science and Engineering*, 2014, **136**(4): Article No. 041006
 - 92 Rath S, Sengupta P P, Singh A P, Marik A K, Talukdar P. Mathematical-artificial neural network hybrid model to predict roll force during hot rolling of steel. *International Journal of Computational Materials Science and Engineering*, 2013, **2**(1): Article No. 1350004
 - 93 Zhao J, Liu Q L, Pedrycz W, Li D X. Effective noise estimation-based online prediction for byproduct gas system in steel industry. *IEEE Transactions on Industrial Informatics*, 2012, **8**(4): 953–963
 - 94 Zhao Jun, Du Ya-Nan, Sheng Chun-Yang, Wang Wei. Kernel-based method for predicting online gas flow interval in metallurgical enterprises. *Control Theory & Applications*, 2013, **30**(10): 1274–1280
(赵璿, 杜雅楠, 盛春阳, 王伟. 基于核的冶金煤气流量在线区间预测. 控制理论与应用, 2013, **30**(10): 1274–1280)
 - 95 Ding J L, Chai T Y, Wang H. Offline modeling for product quality prediction of mineral processing using modeling error PDF shaping and entropy minimization. *IEEE Transactions on Neural Networks*, 2011, **22**(3): 408–419
 - 96 Zhang Xiao-Ping, Zhao Jun, Wang Wei, Cong Li-Qun, Feng Wei-Min, Chen Wei-Chang. COG holder level prediction model based on least square support vector machine and its application. *Control and Decision*, 2010, **25**(8): 1178–1183
(张晓平, 赵璿, 王伟, 丛力群, 冯为民, 陈伟昌. 基于最小二乘支持向量机的焦炉煤气柜位预测模型及应用. 控制与决策, 2010, **25**(8): 1178–1183)
 - 97 Zhang X P, Zhao J, Wang W, Cong L Q, Feng W M. An optimal method for prediction and adjustment on byproduct gas holder in steel industry. *Expert Systems with Applications*, 2011, **38**(4): 4588–4599
 - 98 Kennedy J, Eberhart R C. Particle swarm optimization. In: *Proceedings of the 1995 IEEE International Conference on Neural Networks*. Perth, Australia: IEEE, 1995, **4**: 1942–1948
 - 99 Holland J H. *Adaptation in Natural and Artificial Systems*. Ann Arbor: University of Michigan Press, 1975.
 - 100 Kirkpatrick S, Gelatt Jr C D, Vecchi M P. Optimization by simulated annealing. *Science*, 1983, **220**(4598): 671–680
 - 101 Tang Xian-Lun, Zhuang Ling, Hu Xiang-Dong. The support vector regression based on the chaos particle swarm optimization algorithm for the prediction of silicon content in hot metal. *Control Theory & Applications*, 2009, **26**(8): 838–842
(唐贤伦, 庄陵, 胡向东. 铁水硅含量的混沌粒子群支持向量机预报方法. 控制理论与应用, 2009, **26**(8): 838–842)
 - 102 Tang X L, Zhuang L, Jiang C J. Prediction of silicon content in hot metal using support vector regression based on chaos particle swarm optimization. *Expert Systems with Applications*, 2009, **36**(9): 11853–11857
 - 103 Liu Jian-Hua, Gui Wei-Hua, Xie Yong-Fang, Wang Ya-Lin, Jiang Zhao-Hui. Key process indicators predicting for copper flash smelting process based on projection pursuit regression. *The Chinese Journal of Nonferrous Metals*, 2012, **22**(11): 3255–3260
(刘建华, 桂卫华, 谢永芳, 王雅琳, 蒋朝辉. 基于投影寻踪回归的铜闪速熔炼过程关键工艺指标预测. 中国有色金属学报, 2012, **22**(11): 3255–3260)
 - 104 Hatami S, Ghaderi-Ardakani A, Niknejad-Khomami M, Karimi-Malekabadi F, Rasaei M R, Mohammadi A H. On the prediction of CO₂ corrosion in petroleum industry. *The Journal of Supercritical Fluids*, 2016, **117**: 108–112
 - 105 Långkvist M, Karlsson L, Loutfi A. A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 2014, **42**: 11–24
 - 106 Dalto M. Deep neural networks for time series prediction with applications in ultra-short-term wind forecasting. In: *Proceedings of the 2015 IEEE International Conference on Industrial Technology (ICIT)*. Seville, Spain: IEEE, 2015. 1657–1663
 - 107 Hirata T, Kuremoto T, Obayashi M, Mabu S, Kobayashi K. A novel approach to time series forecasting using deep learning and linear model. *IEEE Transactions on Electronics Information and Systems*, 2016, **136**(3): 348–356

- 108 Hirata T, Kuremoto T, Obayashi M, Mabu S, Kobayashi K. Deep belief network using reinforcement learning and its applications to time series forecasting. In: Proceedings of the 23rd International Conference on Neural Information Processing. Kyoto, Japan: Springer, 2016. 30–37
- 109 Torregrossa D, Boudec J Y L, Paolone M. Model-free computation of ultra-short-term prediction intervals of solar irradiance. *Solar Energy*, 2016, **124**: 57–67
- 110 Runge J, Donner R V, Kurths J. Optimal model-free prediction from multivariate time series. *Physical Review E*, 2015, **91**(5): Article No. 052909
- 111 Gui Wei-Hua, Chen Xiao-Fang, Yang Chun-Hua, Xie Yong-Fang. Knowledge automation and its industrial application. *Scientia Sinica: Informationis*, 2016, **46**(8): 1016–1034 (桂卫华, 陈晓方, 阳春华, 谢永芳. 知识自动化及工业应用. 中国科学: 信息科学, 2016, **46**(8): 1016–1034)
- 112 Wu S F V, Hsieh N, Lin L J, Tsai J M. Prediction of self-care behaviour on the basis of knowledge about chronic kidney disease using self-efficacy as a mediator. *Journal of Clinical Nursing*, 2016, **25**(17–18): 2609–2618
- 113 Waardenberg A J, Homan B, Mohamed S, Harvey R P, Bouveret R. Prediction and validation of protein-protein interactors from genome-wide DNA-binding data using a knowledge-based machine-learning approach. *Open Biology*, 2016, **6**(9): Article No. 160183.
- 114 Zhai Jing-Mei, Ying Can, Xu Xiao. Surface roughness prediction of integration knowledge modeling into data mining. *Computer Integrated Manufacturing Systems*, 2012, **18**(5): 1046–1053 (翟敬梅, 应灿, 徐晓. 知识建模和数据挖掘融合的粗糙度预测新方法. 计算机集成制造系统, 2012, **18**(5): 1046–1053)
- 115 Wang Kang, Li Xiao-Li, Jia Chao, Song Gui-Zhi. Optimal tracking control for slag grinding process based on adaptive dynamic programming. *Acta Automatica Sinica*, 2016, **42**(10): 1542–1551 (王康, 李晓理, 贾超, 宋桂芝. 基于自适应动态规划的矿渣微粉生产过程跟踪控制. 自动化学报, 2016, **42**(10): 1542–1551)
- 116 Luo X, Lv Y X, Li R X, Chen Y. Web service QoS prediction based on adaptive dynamic programming using fuzzy neural networks for cloud services. *IEEE Access*, 2015, **3**: 2260–2269
- 117 Zhang Zhi-Gang, Ma Guang-Wen, Ye Wei-Bao, Zhang Jun-Liang. System marginal price forecasting based on adaptive dynamic programming. *Computer Engineering*, 2009, **35**(5): 9–11 (张志刚, 马光文, 叶伟宝, 张军良. 基于自适应动态规划的系统边际电价预测. 计算机工程, 2009, **35**(5): 9–11)



陈 龙 大连理工大学控制科学与工程学院博士研究生. 主要研究方向为流程工业生产计划与优化调度和机器学习.

E-mail: chl1207@aliyun.com

(**CHEN Long** Ph.D. candidate at the School of Control Science and Engineering, Dalian University of Technology. His research interest covers production planning and scheduling optimization for process industry, and machine learning.)


production planning and scheduling optimization for process industry, and machine learning.)



刘全利 大连理工大学控制科学与工程学院教授. 主要研究方向为流程工业生产计划与优化调度, 嵌入式系统研究、设计及应用. 本文通信作者.

E-mail: liuql@dlut.edu.cn


(**LIU Quan-Li** Professor at the School of Control Science and Engineering, Dalian University of Technology. His research interest covers production planning and scheduling optimization for process industry and embedded systems research, design, and application. Corresponding author of this paper.)



王霖青 大连理工大学控制科学与工程学院讲师. 主要研究方向为流程工业生产计划与优化调度, 计算机集成制造, 机器学习.

E-mail: wanglinqing@dlut.edu.cn

(**WANG Lin-Qing** Lecturer at the School of Control Science and Engineering, Dalian University of Technology. His research interest covers production planning and scheduling optimization for process industry, computer integrated manufacturing, and machine learning.)



赵 珺 大连理工大学控制科学与工程学院教授. 主要研究方向为流程工业生产计划与优化调度, 计算机集成制造, 智能优化, 机器学习和知识自动化.

E-mail: zhaoj@dlut.edu.cn

(**ZHAO Jun** Professor at the School of Control Science and Engineering, Dalian University of Technology. His research interest covers production planning and scheduling optimization for process industry, computer integrated manufacturing, intelligent optimization, machine learning, and knowledge automation.)



王 伟 大连理工大学控制科学与工程学院教授. 主要研究方向为复杂系统建模、控制与优化, 流程工业生产计划与优化调度, 知识自动化.

E-mail: wangwei@dlut.edu.cn

(**WANG Wei** Professor at the School of Control Science and Engineering, Dalian University of Technology. His research interest covers complex system modeling, control and optimization, production planning and scheduling optimization for process industry, and knowledge automation.)