

多维未知输入时滞下工业软测量随机增量建模方法

刘 鑫, 刘小庆, 代 伟

(中国矿业大学信息与控制工程学院, 江苏徐州 221116)

摘 要: 未知时滞是工业软测量建模过程中常见的难题, 若忽略时滞变量的解析(尤其是多维未知时滞变量)可直接降低模型的可靠性及准确性, 进而导致建模任务失败. 基于此, 本文在随机配置网络(Stochastic Configuration Network, SCN)的基础上, 综合考虑多维未知输入时滞和网络模型参数的迭代优化求解问题, 提出了一种多维未知输入时滞下工业软测量随机增量建模方法. 首先, 利用随机配置网络作为基础模型映射输入输出数据间的非线性关系, 揭示传统最小二乘估计对时滞变量的敏感性, 进而利用期望最大化(Expectation-Maximization, EM)方法搭建未知时滞和网络模型参数的概率求解框架, 将多维未知时滞参数概率辨识问题公式化; 其次, 构建未知时滞变量的解空间, 通过计算时滞变量的后验概率密度函数, 量化时滞变量在解空间的概率分布; 最后, 通过迭代优化求解策略给出未知时滞和网络模型参数的联合求解公式, 避免独立估计导致的误差累积, 得到期望的软测量模型. 在模型验证过程中, 本文通过数值仿真和一个典型的磨矿过程的工业应用, 证明了提出的软测量模型的有效性和可靠性.

关键词: 软测量建模方法; 随机配置网络; 期望最大化算法; 多维未知时滞

基金项目: 国家自然科学基金(No.62573417); 江苏省自然科学基金(No.BK20252089); 中国博士后科学基金(No.2023M743776, No.2024T171003)

中图分类号: TP27

文献标识码: A

文章编号: 0372-2112(2025)12-4630-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250927

A Stochastic Incremental Network for Industrial Soft Sensing with Unknown Multidimensional Input Time-Delays

LIU Xin, LIU Xiao-qing, DAI Wei

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

Abstract: Unknown time-delays pose a common challenge in industrial soft sensor modeling. Neglecting the identification of unknown time-delay variables, particularly for multidimensional unknown time-delay variables, can undermine model reliability and accuracy, leading to modeling failure. Accordingly, this paper proposes a stochastic incremental modeling method for industrial soft sensing with multidimensional unknown input time-delays, which is developed based on stochastic configuration network (SCN) to jointly solve the iterative optimization problem of multidimensional unknown input time-delays and network model parameters. Initially, the stochastic configuration network is utilized as a basic model to map the nonlinear relationships between input and output data, thereby revealing the sensitivity of conventional least-squares estimation to time-delay variables. Subsequently, the expectation-maximization (EM) algorithm is employed to establish a probabilistic framework, which formulates the probabilistic identification problem of the multidimensional unknown time-delay parameters. Furthermore, a solution space for the unknown time-delay variables is constructed, and the probability distribution of the unknown time-delay variables within solution space is quantified by calculating the posterior probability density function. Finally, an iterative optimization strategy is adopted to derive a joint estimation formula for the parameters of both the unknown time-delay and the network model, thereby avoiding the error accumulation caused by separate estimations and obtaining the desired soft sensor model. For model validation, the effectiveness and reliability of the proposed soft sensor model are validated through a numerical simulation and an industrial application involving a typical grinding process.

Key words: soft sensing modeling method; stochastic configuration network; expectation-maximization (EM) algorithm; multidimensional unknown time-delays

Foundation Item(s): National Natural Science Foundation of China (No.62573417); Natural Science Foundation of Jiangsu (No.BK20252089); China Postdoctoral Science Foundation (No.2023M743776, No.2024T171003)

1 引言

在实际工业生产过程中,对关键过程变量的精确监测是提升产品质量以及保障生产安全的重要前提^[1,2]。然而,由于测量仪表的缺乏、数据分析周期长等因素,部分关键过程变量难以实现直接、实时的测量。为了解决此问题,软测量技术应运而生。该技术通过构建数学模型,利用易于测量的辅助变量来估计难以直接测量的目标变量,从而实现对关键变量的间接实时监测^[2]。软测量建模方法主要分为机理建模和数据驱动建模。随着工业信息化的推进和海量过程数据的积累,数据驱动的软测量建模方法因其无需复杂的机理分析而受到了广泛关注^[3-6]。在各类数据驱动方法中,神经网络因其强大的非线性映射能力而备受青睐^[7-9]。其中,随机配置网络(Stochastic Configuration Network, SCN)因引入监督机制而确保其具有无限逼近特性,被广泛应用在数据驱动的软测量建模任务中^[10,11]。

随机配置网络的核心优势在于,其独特的监督机制通过约束随机生成的输入权重与偏置,不仅从理论上保证了随机配置网络对非线性映射具有无限逼近特性,也令随机配置网络在网络拓扑结构的自主动态构建和泛化性能上表现优越,显著减少了模型构建中的人为干预,为软测量建模任务的快速实现提供了可能^[11-13]。然而,尽管现有研究已围绕提升随机配置网络的收敛速度与鲁棒性方面取得了许多进展,但标准的随机配置网络及其变体在处理工业过程中的未知时滞问题时仍显不足,难以准确辨识未知时滞参数^[14-18]。在工业软测量建模过程中,若忽略时滞变量的解析(尤其是多维未知时滞变量)可能直接降低模型的可靠性及准确性,进而导致建模任务失败^[19,20]。以磨矿过程中的物料传输为例,不同工序间的原料传输速度差异可能引起输入信号的时间偏移,从而导致系统输入与输出数据间存在未知时滞^[20]。当系统输入维度较多时,不同输入维度下的时滞会导致输入输出数据间存在复杂的错误映射关系,最终增加了软测量模型反映工业生产过程非线性特性的难度。

在现有针对含未知时滞的软测量建模方法中,文献[21]针对双率采样系统输出数据中含有时滞的问题,使用期望最大化(Expectation-Maximization, EM)方法估计时滞和模型参数,实现了在时滞取值概率未知条件下对未知时滞的准确辨识。文献[22]针对双率采样系统中时滞与阶次未知的问题,提出了基于压缩感知的稀疏辨识方法。该方法首先通过参数化将辨识模型转化为稀疏结构,再结合正交匹配追踪算法和辅助

模型迭代机制,从而在有限数据条件下实现对未知时滞、阶次与模型参数的联合估计。文献[23]针对机器人控制中存在未知时滞的问题,提出了一种基于混合延迟动态模型的调度框架。该框架通过在线估计未知时滞及其统计特性,并依据估计结果自适应地切换至最匹配的动态模型,实现了对未知时滞的快速响应和模型动态匹配。然而,上述方法存在以下三方面局限性:一是以上文献均基于单维未知时滞假设,未考虑多维未知时滞问题;二是文献[21]和文献[22]的核心假设建立在线性的模型类之上,在面对工业过程普遍存在的非线性特性时,模型表达能力受限;三是文献[23]采用独立估计策略分别计算时滞与网络模型参数,易造成估计误差累积。此外,长短期记忆网络(Long Short-Term Memory, LSTM)和回声状态网络(Echo State Network, ESN)等时间序列神经网络建模方法在一定程度上解决了上述问题^[24,25]。这类神经网络不仅因为激活函数而具有强大的非线性映射能力,而且引入了记忆单元或固定储层结构,能够捕获数据中的时间依赖关系。然而,其在实际应用中存在两个主要问题:一是长短期记忆网络依赖反向传播进行训练,计算复杂度高,且对权重初始化敏感,容易陷入局部最优;二是回声状态网络等随机化模型虽通过固定储层简化了训练,但因其无法解析出时滞变量,储层节点间的随机连接可能引入错误的时序关联,同时其储层拓扑优化也十分复杂^[26,27]。

针对上述问题,本文提出了一种多维未知输入时滞下工业软测量随机增量建模方法。首先,在未知多维输入时滞存在条件下,利用随机配置网络映射输入输出数据间的非线性关系,揭示传统最小二乘估计对时滞变量的敏感性;随后,引入期望最大化算法将输入时滞视为待估计的未知参数,通过计算时滞变量的后验概率密度函数构建未知时滞的解空间;最后,搭建未知输入时滞和网络模型参数的联合迭代优化求解策略,在统计学的框架下实现未知输入时滞和网络模型参数的逐步迭代逼近,避免独立估计导致的误差累积,得到期望的软测量模型。本文的贡献体现在以下三个方面。

(1)在未知多维输入时滞存在条件下,基于随机增量构造型神经网络提出了一种工业过程软测量建模方法,利用增量节点的监督约束机制确保模型的收敛性。

(2)利用期望最大化算法将未知时滞问题从概率估计的角度公式化,通过计算时滞变量的后验概率密度函数构建未知时滞的解空间,助力实现未知多维时滞变量的精准解析。

(3)设计未知时滞和网络模型参数的联合迭代优

化辨识策略,避免了独立估计导致的误差累积,进一步确保软测量模型的准确性和可靠性.

2 SCN 简介

在诸多神经网络中,SCN 属于增量构造型神经网络的一种,其在隐含层节点增量构建过程中引入监督机制来约束隐含层参数,以确保网络的无限逼近特性.与其他增量构造式网络相比,SCN 具有易于实现、收敛速度快、泛化性能好等优点,受到国内外学者的广泛关注.

在 SCN 网络构建过程中,首先给定目标函数 $f: \mathbf{R}^d \rightarrow \mathbf{R}$ (以单输出为例),输入数据为 $\mathbf{U} = \{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_N\}$, $\mathbf{u}_k = [u_{k,1}, u_{k,2}, \dots, u_{k,d}] \in \mathbf{R}^d, k=1, 2, \dots, N$, 输出数据为 $\mathbf{Z} = \{z_1, z_2, \dots, z_N\} \in \mathbf{R}$. 此时带有 L 个隐含层节点的 SCN 描述为^[7]

$$f_L(\mathbf{U}) = \sum_{n=1}^L \mathbf{g}(\boldsymbol{\omega}_n^T \mathbf{U} + b_n) \beta_n = \mathbf{H}(\mathbf{U}) \boldsymbol{\beta} \quad (1)$$

其中, $\boldsymbol{\omega}_n \in \mathbf{R}^d$ 和 $b_n \in \mathbf{R}$ 分别表示第 n 个隐含层节点的输入权重和偏置, $n=1, 2, \dots, L$; $\mathbf{g}(\cdot)$ 表示激活函数; $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_L]^T$ 表示输出权重. 第 L 层的残差表示为 $e_L = \mathbf{f} - f_L$. 前 L 个节点的输出矩阵 $\mathbf{H}(\mathbf{U})$ 定义如下^[7]:

$$\mathbf{H}(\mathbf{U}) = [\mathbf{g}_1(\mathbf{U}), \mathbf{g}_2(\mathbf{U}), \dots, \mathbf{g}_L(\mathbf{U})] \quad (2)$$

$$\mathbf{g}_n(\mathbf{U}) = \mathbf{g}(\boldsymbol{\omega}_n^T \mathbf{U} + b_n) \quad (3)$$

在 SCN 输出权重计算过程中,利用基础的最小二乘方法可得其输出权重,计算公式如下^[7]:

$$\boldsymbol{\beta} = (\mathbf{H}(\mathbf{U})^T \mathbf{H}(\mathbf{U}))^{-1} \mathbf{H}(\mathbf{U})^T \mathbf{z} \quad (4)$$

当未达到最大节点数或未满足终止标准时,继续生成第 $L+1$ 个隐含层节点,且 $\boldsymbol{\omega}$ 和 b 的随机选取受到监督不等式 $\xi_{L+1} \geq 0$ 的约束, ξ_{L+1} 定义为^[7]

$$\xi_{L+1} = \frac{(\mathbf{e}_L^T(\mathbf{U}) \cdot \mathbf{g}_{L+1}(\mathbf{U}))^2}{\mathbf{g}_{L+1}^T(\mathbf{U}) \cdot \mathbf{g}_{L+1}(\mathbf{U})} - (1-r-\mu_{L+1}) \mathbf{e}_L^T(\mathbf{U}) \mathbf{e}_L(\mathbf{U}) \quad (5)$$

其中, $0 < r < 1, \mu_{L+1} < 1-r$, 且 $\lim_{L \rightarrow \infty} \mu_{L+1} = 0$. 当节点数达到预设最大值或满足终止条件时,则停止更新新的隐含层节点.

3 多维未知输入时滞下随机增量建模方法

多维时滞问题广泛存在于各种工业过程中,如锅炉给水、钢铁制造和石化工艺等,并对生产效率和产品质量稳定性产生显著影响. 现有基于神经网络的建模方法在处理时滞问题时存在如下局限:(1)通常采用独立估计策略分别计算时滞与网络模型参数,易造成估计误差累积,进而降低模型的准确性和可靠性;(2)大多数建模方法基于单维时滞假设,针对多维未知时滞问题考虑较少. 为解决以上问题,本文重点解决未知多维输入时滞下的软测量建模问题,利用 EM 算法将上述建模问题公式化,设计基于概率的时滞参数和网络模

型参数同步迭代优化策略.

3.1 建模问题公式化

假设输入数据 \mathbf{U}^* 有 d 个维度,在每个维度上均存在相互独立的时滞变量为 $\boldsymbol{\tau} = \{\boldsymbol{\tau}_1, \boldsymbol{\tau}_2, \dots, \boldsymbol{\tau}_d\} \in \mathbf{R}^d$, 输入变量可重新表示为 $\mathbf{u}_k^* = [u_{k,1}(\boldsymbol{\tau}_1), u_{k,2}(\boldsymbol{\tau}_2), \dots, u_{k,d}(\boldsymbol{\tau}_d)]^T \in \mathbf{R}^d$. 搭建基础的 SCN 模型来映射输入和输出之间的关系如下:

$$z_k = f_L(\mathbf{u}_k^*) + \lambda_k = \sum_{n=1}^L \mathbf{g}(\boldsymbol{\omega}_n^T \mathbf{u}_k^* + b_n) \beta_n + \lambda_k = \mathbf{H}(\mathbf{u}_k^*) \boldsymbol{\beta} + \lambda_k \quad (6)$$

其中, λ_k 表示输出测量噪声且服从均值为 0 且方差为 ϑ 的高斯分布,即 $\lambda_k \sim N(\lambda_k | 0, \vartheta)$. 此时,由式(6)可知, z_k 服从以下高斯分布:

$$z_k \sim N(z_k | \mathbf{H}(\mathbf{u}_k^*) \boldsymbol{\beta}, \vartheta) = \frac{1}{\sqrt{2\pi\vartheta}} \exp\left\{-\frac{(z_k - \mathbf{H}(\mathbf{u}_k^*) \boldsymbol{\beta})^2}{2\vartheta}\right\} \quad (7)$$

在本文中,由先验知识可大致确定时滞的取值范围 $[0, J]$, 假设未知时滞在可能的取值范围中服从均匀分布,即在 $[0, J]$ 范围内取任意一个整数的概率都是相同的,数学表示为

$$p(\boldsymbol{\tau}_i = j_i) = \frac{1}{J+1}, \quad i=1, 2, \dots, d \quad (8)$$

且

$$\sum_{j_i=0}^J p(\boldsymbol{\tau}_i = j_i) = 1 \quad (9)$$

综上所述,本文拟解决的软测量建模问题可概括如下:基于工业输入输出数据构建时滞 SCN 模型,同时给出未知时滞 $\{\boldsymbol{\tau}_i\}_{i=1,2,\dots,d}$ 和网络输出权重参数 $\boldsymbol{\beta}$ 的迭代优化估计公式.

3.2 基于 EM 算法的未知时滞和输出权重联合迭代优化求解

EM 算法是一种有效解决未知隐含变量问题的迭代优化策略,通过交替执行期望步骤(E-step)和最大化步骤(M-step)以实现未知参数求解. 本文将未知的多维常时滞作为隐含变量处理,利用 EM 算法搭建未知时滞和网络输出权重参数的联合概率求解框架. 在 E-step 中,通过计算未知时滞的后验概率密度函数进而构建目标代价函数;在 M-step 中,通过最大化目标代价函数估计未知时滞变量和模型参数.

3.2.1 E-step: 计算目标代价函数

首先构造系统的对数似然函数并化简,如式(10)所示:

$$\begin{aligned} \log \mathbb{L}_1 &= \log p(D_o, D_m | D_p) = \log p(z_{1:N}, \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d} | D_p) \\ &= \log p(z_{1:N} | \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p) + \log p(\boldsymbol{\tau}_{1:d} | \mathbf{u}_{1:N}^*, D_p) + C_1 \end{aligned} \quad (10)$$

其中, D_o 表示可用数据集, 包含含有时滞的输入变量 $\mathbf{u}_{1:N}^*$ 、输出变量 $\mathbf{z}_{1:N}$ 、输入权重 $\boldsymbol{\omega}_{1:L}$ 和偏置 $\mathbf{b}_{1:L}$, 即 $D_o = \{\mathbf{u}_{1:N}^*, \mathbf{z}_{1:N}, \boldsymbol{\omega}_{1:L}, \mathbf{b}_{1:L}\}$; D_m 表示包含未知时滞 $\boldsymbol{\tau}_{1:d}$ 的隐含数据集, 即 $D_m = \{\boldsymbol{\tau}_{1:d}\}$; D_p 表示包括输出权重 $\boldsymbol{\beta}_{1:L}$ 和噪声方差 ϑ 的待辨识的参数集, 即 $D_p = \{\boldsymbol{\beta}_{1:L}, \vartheta\}$; $C_1 = \log p(\mathbf{u}_{1:N}^* | D_p)$ 表示与参数无关的常数. 依据式(6)不难发现, 第 k 时刻的输出数据 \mathbf{z}_k 仅与输入数据 \mathbf{u}_k^* 、 $\boldsymbol{\tau}_{1:d}$ 和参数 D_p 有关, 则式(10)右侧的概率密度表达式 $\log p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p)$ 依据概率统计原理可以化简为

$$\log p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p) = \sum_{k=1}^N \log p(\mathbf{z}_k | \mathbf{u}_k^*, \boldsymbol{\tau}_{1:d}, D_p) \quad (11)$$

结合式(7), 式(11)可以继续化简为

$$\begin{aligned} \log p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p) = & -\frac{N}{2} \log 2\pi - \frac{N}{2} \log \vartheta \\ & - \sum_{k=1}^N \frac{[\mathbf{z}_k - \mathbf{H}(\mathbf{u}_k^*)\boldsymbol{\beta}]^2}{2\vartheta} \end{aligned} \quad (12)$$

因为时滞 $\boldsymbol{\tau}_{1:d}$ 与模型参数和输入变量无关, 式(10)中 $\log p(\boldsymbol{\tau}_{1:d} | \mathbf{u}_{1:N}^*, D_p)$ 可以进一步化简为

$$\log p(\boldsymbol{\tau}_{1:d} | \mathbf{u}_{1:N}^*, D_p) = \sum_{i=1}^d \log p(\boldsymbol{\tau}_i = j_i) \quad (13)$$

将式(12)和(13)代入式(10)中, 则式(10)进一步化简为如下形式:

$$\begin{aligned} \log \mathbb{L}_1 = & -\sum_{k=1}^N \frac{[\mathbf{z}_k - \mathbf{H}(\mathbf{u}_k^*)\boldsymbol{\beta}]^2}{2\vartheta} + \sum_{i=1}^d \log p(\boldsymbol{\tau}_i = j_i) \\ & - \frac{N}{2} \log \vartheta + C_2 \end{aligned} \quad (14)$$

其中, $C_2 = C_1 - \left(\frac{N}{2}\right) \log 2\pi$ 表示与参数无关的常数项.

随后构造系统的目标代价函数为

$$\begin{aligned} Q(D_p | D_p^v) = & \mathbb{E}_{p(D_m | D_o, D_p^v)} \{ \log p(D_m, D_o | D_p) \} \\ = & \int p(D_m | D_o, D_p^v) \log p(D_m, D_o | D_p) dD_m \end{aligned} \quad (15)$$

其中, $\mathbb{E}_A\{B\}$ 表示 B 相对于 A 的条件期望; D_p^v 表示第 v 次 E-step 和 M-step 交替中获得的输出权重 $\boldsymbol{\beta}_{1:L}$ 和噪声方差 ϑ . 结合式(14), 目标代价函数化简为

$$\begin{aligned} Q(D_p | D_p^v) = & -\frac{N}{2} \log \vartheta \\ & - \frac{1}{2\vartheta} \sum_{k=1}^N \int p(\boldsymbol{\tau}_{1:d} | D_o, D_p^v) [\mathbf{z}_k - \mathbf{H}(\mathbf{u}_k^*)\boldsymbol{\beta}]^2 d\boldsymbol{\tau}_{1:d} \\ & + \int p(\boldsymbol{\tau}_{1:d} | D_o, D_p^v) \sum_{i=1}^d \log p(\boldsymbol{\tau}_i = j_i) d\boldsymbol{\tau}_{1:d} + C_2 \end{aligned} \quad (16)$$

由于时滞 $\boldsymbol{\tau}_{1:d}$ 相互独立, 则式(16)中的 $p(\boldsymbol{\tau}_{1:d} | D_o, D_p^v)$ 可以化简为

$$p(\boldsymbol{\tau}_{1:d} | D_o, D_p^v) = \prod_{i=1}^d p(\boldsymbol{\tau}_i = j_i | D_o, D_p^v) \quad (17)$$

由于时滞 $\boldsymbol{\tau}_{1:d}$ 为离散变量, 结合式(17), 式(15)可以化简为

$$\begin{aligned} Q(D_p | D_p^v) = & -\frac{N}{2} \log \vartheta - \frac{1}{2\vartheta} \sum_{k=1}^N \sum_{0 \leq j_{1:d} \leq J} \left([\mathbf{z}_k - \mathbf{H}^* \boldsymbol{\beta}]^2 \varphi_{po} \right) \\ & + \left(\sum_{0 \leq j_{1:d} \leq J} \varphi_{po} \right) \log \varphi_{pr} + C_2 \end{aligned} \quad (18)$$

其中, φ_{pr} 表示为当前假设的时滞取值是真实值的概率; φ_{po} 表示当前假设的时滞取值是真实值的条件概率. 其具体表达式分别为

$$\varphi_{pr} = \prod_{i=1}^d p(\boldsymbol{\tau}_i = j_i) \quad (19)$$

$$\varphi_{po} = \prod_{i=1}^d p(\boldsymbol{\tau}_i = j_i | D_o, D_p^v) \quad (20)$$

$$\mathbf{H}^* = \mathbf{H}(\mathbf{u}_k^*(\boldsymbol{\tau}_i = j_i)) \quad (21)$$

此时, 想要继续简化代价函数则需要进一步求出

$p(\boldsymbol{\tau}_{1:d} | D_o, D_p^v)$, 考虑如下两行公式:

$$\begin{cases} p(\mathbf{z}_{1:N}, \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d} | D_p^v) = p(\mathbf{u}_{1:N}^* | D_p^v) p(\boldsymbol{\tau}_{1:d} | \mathbf{u}_{1:N}^*, D_p^v) \\ \quad \cdot p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p^v) \\ p(\mathbf{z}_{1:N}, \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d} | D_p^v) = p(\mathbf{u}_{1:N}^* | D_p^v) p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, D_p^v) \\ \quad \cdot p(\boldsymbol{\tau}_{1:d} | \mathbf{z}_{1:N}, \mathbf{u}_{1:N}^*, D_p^v) \end{cases} \quad (22)$$

将式(22)中两行公式相除, 则式(17)简化为

$$\begin{aligned} p(\boldsymbol{\tau}_{1:d} | D_o, D_p^v) = & \frac{p(\mathbf{z}_{1:N}, \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p^v) p(\boldsymbol{\tau}_{1:d} | \mathbf{u}_{1:N}^*, D_p^v)}{p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, D_p^v)} \\ = & \frac{p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p^v) \varphi_{pr}}{\sum_{0 \leq j_{1:d} \leq J} p(\mathbf{z}_{1:N} | \mathbf{u}_{1:N}^*, \boldsymbol{\tau}_{1:d}, D_p^v) \varphi_{pr}} \\ = & \frac{\prod_{k=1}^N N(\mathbf{z}_k | \mathbf{H}^* \boldsymbol{\beta}^v, \vartheta^v)}{\sum_{0 \leq j_{1:d} \leq J} \prod_{k=1}^N N(\mathbf{z}_k | \mathbf{H}^* \boldsymbol{\beta}^v, \vartheta^v)} \end{aligned} \quad (23)$$

至此, 代价函数构造完成. 为方便后续优化求解, 将代价函数拆分为以下两部分:

$$Q(D_p | D_p^v) = -Q_1(\boldsymbol{\beta}, \vartheta) + Q_2(\varphi_{pr}) + C_2 \quad (24)$$

式中,

$$Q_1(\boldsymbol{\beta}, \vartheta) = \frac{N}{2} \log \vartheta + \frac{1}{2\vartheta} \sum_{k=1}^N \sum_{0 \leq j_{1:d} \leq J} \left([\mathbf{z}_k - \mathbf{H}^* \boldsymbol{\beta}]^2 \varphi_{po} \right) \quad (25)$$

$$Q_2(\varphi_{pr}) = \left(\sum_{0 \leq j_{1:d} \leq J} \varphi_{po} \right) \log \varphi_{pr} \quad (26)$$

3.2.2 M-step: 最大化代价函数得到参数估计

在这一步需要进一步优化代价函数得到参数估计. 在 $Q_1(\boldsymbol{\beta}, \vartheta)$ 中同时含有输出权重参数 $\boldsymbol{\beta}$ 和噪声参数 ϑ 两项参数, 所以需要采用两步优化法: 在优化 $\boldsymbol{\beta}$ 得到对应估计公式时, 固定 $\vartheta = \vartheta^v$ 为定值; 在优化 ϑ 得到对应估计公式时, 固定 $\boldsymbol{\beta} = \boldsymbol{\beta}^v$ 为定值, 即

$$\frac{\partial Q_1(\boldsymbol{\beta}, \vartheta)}{\partial \boldsymbol{\beta}} = 0 \Rightarrow \boldsymbol{\beta}^{v+1} = \frac{\sum_{k=1}^N \sum_{0 \leq j_{1:d} \leq J} (\mathbf{H}^{*T} \mathbf{z}_k \varphi_{po})}{\sum_{k=1}^N \sum_{0 \leq j_{1:d} \leq J} (\mathbf{H}^{*T} \mathbf{H}^* \varphi_{po})} \quad (27)$$

$$\frac{\partial Q_1(\boldsymbol{\beta}, \vartheta)}{\partial \vartheta} = 0 \Rightarrow \vartheta^{v+1} = \frac{1}{N} \sum_{k=1}^N \sum_{0 \leq j_{1:d} \leq J} \left[(\mathbf{z}_k - \mathbf{H}^* \boldsymbol{\beta}^v)^2 \varphi_{po} \right] \quad (28)$$

此外, 计算 $Q_2(\varphi_{pr})$ 函数对 φ_{pr} 求偏导, 需要先构造拉格朗日函数. 首先假设 L_τ 为拉格朗日因子, 结合式(9)构造拉格朗日函数如下:

$$E(\varphi_{pr}, L_\tau) = \left(\sum_{0 \leq j_{1:d} \leq J} \varphi_{po} \right) \log \varphi_{pr} + L_\tau \left(\prod_{i=1}^d \sum_{j_i=0}^J P(\tau_i = j_i) - 1 \right) \quad (29)$$

求解式(29)可得:

$$\begin{cases} \frac{\partial E(\varphi_{pr}, L_\tau)}{\partial \varphi_{pr}} = 0 \\ \frac{\partial E(\varphi_{pr}, L_\tau)}{\partial L_\tau} = 0 \end{cases} \Rightarrow \varphi_{pr}^{v+1} = \frac{\varphi_{po}}{\sum_{0 \leq j_{1:d} \leq J} \varphi_{po}} \quad (30)$$

由式(30)可知, 未知时滞 $\tau_{1:d}$ 的估计公式如下:

$$\tau_{1:d}^{v+1} = \arg \max_{j_{1:d} \in \{0, \dots, J\}} \varphi_{pr}^{v+1} \quad (31)$$

综上, 未知多维输入时滞和网络模型参数估计公式全部推导完成. 本文提出的软测量建模方法(Multi-dimensional Input Time Delay SCN, MITD-SCN)可总结如算法1所示.

算法1 MITD-SCN算法

输入: 可观测数据集: $U^* \in \mathbf{R}^d, \mathbf{Z} \in \mathbf{R}$. 给定最大隐含层节点数 L_{\max} , 容忍误差 ϵ , 最大随机配置数 T_{\max} , 隐含层参数选择区间 $\gamma = \{\psi_{\min}, \Delta\psi, \psi_{\max}\}$. EM算法最大迭代次数 v_{\max} , 噪声方差初值 ϑ

输出: $\tau_{1:d}, \boldsymbol{\beta}, \omega, \mathbf{b}$

1. 运行基础SCN算法, 收集 ω, \mathbf{b} 和 $\boldsymbol{\beta}, \boldsymbol{\beta}$ 作为EM算法的初值
2. 根据式(23)计算时滞 $\tau_{1:d}$ 的后验概率密度函数
3. 根据式(27)计算输出权重 $\boldsymbol{\beta}$ 的迭代估计值
4. 根据式(28)计算噪声方差 ϑ 的迭代估计值
5. 根据式(30)和式(31)估计未知时滞 $\tau_{1:d}$
6. 转回到步骤(2), 直至达到最大迭代次数

4 算法验证

为验证本文所提算法的有效性和可靠性, 本节通过一个非线性数值仿真和一个工业实例对所提算法1进行充分测试. 选取基础SCN^[7]、ESN^[24]和LSTM等方法为对比算法以测试模型的性能. 此外, 为进一步量化算法的性能, 选取均方根误差(Root Mean Squared Error, RMSE)对模型的精度进行评估, 其定义为

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N (\mathbf{z}_k - \hat{\mathbf{z}}_k)^2} \quad (32)$$

其中, $\hat{\mathbf{z}}_k$ 是模型的预测输出. 测试结果取独立重复50次后的平均RMSE.

4.1 非线性数值仿真验证

考虑以下含四维输入的非线性模型:

$$\mathbf{z}_k = 0.6e^{u_{k,1}(\tau_1)} + 0.8e^{u_{k,2}(\tau_2)} + 0.4e^{u_{k,3}(\tau_3)} + 0.5e^{u_{k,4}(\tau_4)} + 0.2e^{u_{k,1}(\tau_1)u_{k,2}(\tau_2)} + 0.3e^{u_{k,3}(\tau_3)u_{k,4}(\tau_4)} \quad (33)$$

为了获取合适的输入输出数据, 四维输入信号分别选择 $[-1, 1]$ 之间的高斯白噪声, 时滞取值范围假定为 $[0, 4]$, 由输入信号充分激励非线性函数生成对应的输出数据, 一共生成 $N = 1000$ 个数据点. 训练集、验证集与测试集的输入输出数据长度之比为 $2:1:1$.

其他实验参数具体设置如下: SCN、ESN、LSTM和MITD-SCN的最大隐含层节点数 $L_{\max} = 130$, 最大随机配置数 $T_{\max} = 200$, 容忍误差为 $\epsilon = 10^{-4}$, LSTM算法采用单层神经网络, SCN和MITD-SCN隐含层参数选择区间设置为 $[-0.1, 0.1]$. 上述实验参数根据其在验证集上的性能表现选取.

为全面比较各算法的性能, 图1展示了各算法在四维时滞下的输出预测曲线. 此外, 为进一步验证所提算法的优势, 本文分别将输入数据中含有时滞的维度从0逐渐增加到四维, 用于测试不同维度的时滞对各模型输出预测的影响, 测试结果如表1和图2所示. 基于以上测试结果, 可得以下结论.

(1) 从表1可以看出, 当输入数据中不包含时滞, SCN和MITD-SCN算法均能保持良好的输出预测性能. 但是在有限节点和迭代次数下, ESN算法和LSTM算法的预测性能低于SCN和MITD-SCN算法.

(2) 从表1可以看出, 在多维输入数据中, 输入时滞的维度增加时, 时滞对SCN算法的负面影响逐渐加剧, 基础的SCN算法无法保持良好的输出预测性能. 此外, ESN和LSTM算法虽然保持了一定的预测性能, 但是预测精度远低于本文提出的MITD-SCN算法, 这证明了本文提出的MITD-SCN算法能够有效抑制多维未知输入时滞对数据建模的负面影响.

(3) 从图1和图2的比较试验结果可得, 由于基础SCN网络、LSTM网络以及ESN网络无法解析出时滞变

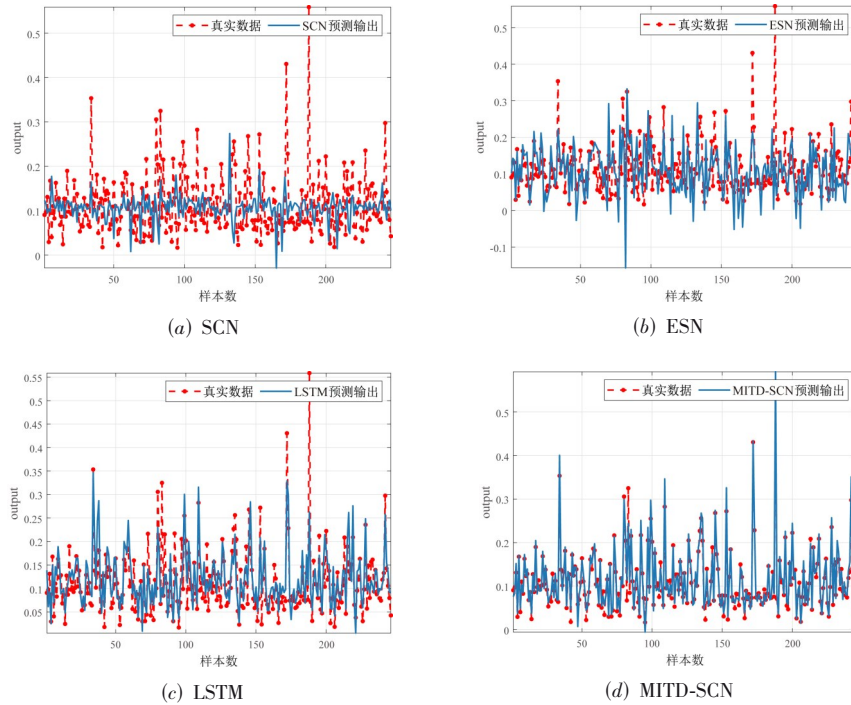


图 1 各算法的输出预测图

表 1 不同维度的时滞干扰下各算法的预测 RMSE (均值, 标准差)

算法	不含时滞	一维时滞	二维时滞	三维时滞	四维时滞
SCN	0.013 3, 0.002 8	0.050 9, 0.024 0	0.065 8, 0.027 6	0.077 8, 0.021 6	0.092 1, 0.026 2
ESN	0.039 1, 0.010 3	0.047 8, 0.008 4	0.051 3, 0.009 5	0.055 8, 0.008 0	0.067 4, 0.010 7
LSTM	0.044 3, 0.007 5	0.047 2, 0.008 4	0.050 4, 0.010 0	0.051 6, 0.009 3	0.055 4, 0.010 8
MITD-SCN	0.020 1, 0.004 6	0.020 9, 0.007 8	0.020 7, 0.005 9	0.020 7, 0.007 4	0.020 8, 0.006 6

注:加粗数值表示效果最好.

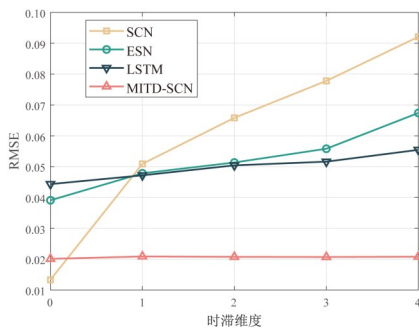


图 2 多维输入时滞下各算法预测 RMSE

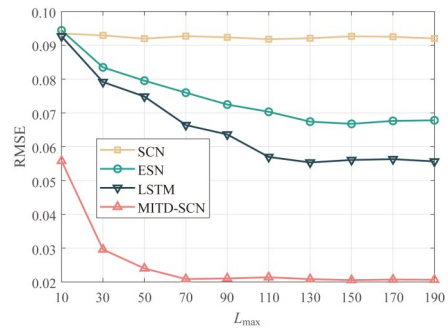


图 3 不同节点数下各算法预测 RMSE

量,导致输出预测精度不高.而本文提出的 MITD-SCN 算法在精准估计未知时滞参数的同时,也能够给出精准的输出变量预测结果,这证明了本文所提出算法的有效性和可靠性.

为进一步量化模型复杂度对各算法性能的影响,本研究在四维时滞场景下,系统测试了最大节点数为 [10, 190] 时各算法的性能表现,如图 3 和表 2 所示.

(1)从图 3 和表 2 可以看出,当模型复杂度逐渐增

加时,SCN 算法的预测精度无明显变化,说明模型复杂度的增加无法减弱多维未知输入时滞对 SCN 建模的负面影响.此外,ESN 算法和 LSTM 算法的输出预测 RMSE 值虽然随模型复杂度的增加而下降,但其预测精度仍然低于本文提出的 MITD-SCN 算法,这说明了本文提出的 MITD-SCN 算法可以有效抑制多维未知输入时滞对数据建模的负面影响,无需过高的模型复杂度就能保持良好的输出预测性能,证明了本文所提算法的有效性.

表2 不同最大节点数下各算法的平均RMSE

算法	最大节点数 L_{\max}									
	10	30	50	70	90	110	130	150	170	190
SCN	0.093 5	0.092 9	0.092 0	0.092 7	0.092 4	0.091 8	0.092 1	0.092 7	0.092 5	0.092 0
ESN	0.094 4	0.083 5	0.079 5	0.076 0	0.072 5	0.070 3	0.067 4	0.066 8	0.067 6	0.067 8
LSTM	0.092 7	0.079 2	0.074 9	0.066 4	0.063 6	0.057 0	0.055 4	0.056 1	0.056 3	0.055 7
MITD-SCN	0.055 8	0.029 6	0.024 0	0.020 9	0.021 0	0.021 4	0.020 8	0.020 5	0.020 7	0.020 7

注:加粗数值表示效果最好.

(2)从表2的测试结果可以看出,MITD-SCN算法在低节点数时性能已接近饱和,并且当节点数逐渐升高时,MITD-SCN算法的预测性能仅在小幅度范围内波动,证明了MITD-SCN算法的稳定性.

4.2 赤铁矿磨矿粒度预测

在赤铁矿选矿工艺中,磨矿粒度(Particle Size, PS)是表征矿物解离度与能源效率的核心质量指标.磨矿粒度的精准控制对后续分选作业具有决定性影响.若磨矿粒度过小,将导致有用矿物泥化难以回收,且显著增加能耗;若磨矿粒度过大,则会降低分选回收率^[28].因此,实现磨矿粒度的精准估计具有重要意义.

4.2.1 工艺描述

图4展示了一段典型磨矿工艺流程,其核心设备包括球磨机、螺旋分级机及配套传感执行机构.




图4 赤铁矿磨矿过程工艺流程图

(1)原矿经皮带输送至球磨机,通过给水阀门动态调节矿浆浓度至最佳工况.

(2)研磨后矿浆进入螺旋分级机,通过补水量控制实现粒度分级.粗颗粒经底流返回再研磨,合格细颗粒

由溢流进入分选工序.

由磨矿过程特性^[28]可知,磨矿粒度PS主要受球磨机给矿量 α_1 、入口给水流量 α_2 及分级机溢流浓度 α_3 三个参数耦合作用.但是在工业赤铁矿研磨过程中, α_1 、 α_2 、 α_3 与PS之间可能存在物料传输延迟、水力滞后和分级机动态响应等时滞效应.因此,建立如下含时滞的软测量模型:

$$PS(t) = f(\alpha_1(t - \tau_1), \alpha_2(t - \tau_2), \alpha_3(t - \tau_3)) + \lambda(t) \quad (34)$$

其中, τ_1 、 τ_2 和 τ_3 为各输入维度的未知时滞参数; $\lambda(t)$ 为输出测量噪声,服从零均值高斯分布.

4.2.2 实验设计

为系统评估算法有效性,本研究基于半实物仿真平台^[28]设计多组对照试验.首先,根据式(34)分别设定输入变量多维时滞参数为 $\tau_1=3$ 、 $\tau_2=11$ 、 $\tau_3=14$ 个采样周期;随后,采集2500组含时滞干扰的工业数据,并划分为2000组训练样本和500组测试样本,并建立基于MITD-SCN算法的磨矿粒度软测量模型.试验重点探究以下参数对MITD-SCN算法磨矿粒度估计精度的影响.

(1)随机权重范围:分别设置 $|\psi|$ 为0.5、1、5、10,探究隐含层参数选择区间对模型性能的影响.

(2)模型复杂度:模型的最大节点数分别设为 $L=10:20:190$,分析模型复杂度与时滞估计的关联性.

测试结果如表3所示,为了更加清晰地展现测试结果,我们绘制了不同参数下MITD-SCN算法的平均输出预测RMSE图,如图5所示.图6和图7则分别给出了MITD-SCN算法在 $L_{\max}=110$ 、 $|\psi| \leq 1$ 条件下时滞参数迭代收敛过程和输出预测结果.

基于以上测试结果可以得出以下结论.

(1)从表3和图5可以看出,当模型复杂度增加时,

表3 不同参数下MITD-SCN算法的平均RMSE

随机权重范围	最大节点数 L_{\max}									
	10	30	50	70	90	110	130	150	170	190
$ \psi \leq 0.5$	0.046 2	0.043 1	0.043 0	0.043 1	0.043 1	0.043 0	0.043 1	0.043 1	0.043 0	0.043 0
$ \psi \leq 1$	0.046 1	0.042 2	0.042 2	0.042 2	0.042 2	0.042 2	0.042 2	0.042 2	0.042 3	0.042 3
$ \psi \leq 5$	0.045 2	0.040 9	0.040 5	0.040 4	0.040 4	0.040 3	0.040 4	0.040 4	0.040 4	0.040 4
$ \psi \leq 10$	0.048 0	0.040 6	0.040 3	0.040 2	0.040 2	0.040 2	0.040 2	0.040 2	0.040 2	0.040 2

注:加粗数值表示效果最好.




图5 不同参数配置下MITD-SCN算法平均RMSE对比




图6 时滞参数迭代优化过程




图7 MITD-SCN软测量模型的磨矿粒度估计结果

不同随机权重范围下的MITD-SCN算法保持了良好的输出预测性能,并且在不同参数下MITD-SCN算法的输出预测RMSE值波动较小,这说明基于MITD-SCN算法构建的软测量模型在磨矿粒度估计中对参数的敏感性较小。

(2)从图6和图7的试验结果可得,MITD-SCN算法估计的时滞参数能够快速收敛至真值,并且模型输出预测值与真实值基本吻合。说明在磨矿粒度估计中,本文所提算法建立的软测量模型在准确识别出时滞参数的同时,也能保持良好的输出预测性能,证明了本文所提算法的有效性和可靠性。

(3)从表3、图5和图6可以看出,MITD-SCN算法在不同随机权重范围、最大节点数和EM算法迭代次数下快速收敛,说明MITD-SCN算法可以以较小的节点数和

迭代次数完成工业软测量建模任务,因此随机初始化的参数范围不宜过大。

5 结论

本文提出了一种多维未知输入时滞下工业软测量随机增量建模方法,利用随机配置网络映射输入输出数据之间的非线性关系,进而使用期望最大化算法设计未知输入时滞和网络模型参数的联合迭代优化求解策略,在统计学的框架下实现未知输入时滞和网络模型参数的逐步迭代逼近,避免了分开独立估计所带来的误差累积,保障了软测量模型的精度。最后,对建模方法的验证结果表明:当输入变量中含有多维未知时滞时,本文所提出的建模方法在精准构建网络模型的同时,既能够精确地实现未知时滞变量的估计,又能准确地实现输出数据预测,证明了本文提出的建模算法的有效性。

综上,针对多维常时滞问题,本文提出的MITD-SCN算法与现有算法相比,适用范围更广、泛化性能更强。在本文研究基础上,未来的研究工作可集中在以下方面。

(1)实际工业过程除受多维常时滞干扰外,常具有时变特性和非均匀先验分布的问题,并且时滞的取值范围往往是未知的,因此在时滞的解空间自适应调整下,研究基于输入数据受多维时变时滞干扰的工业软测量建模算法尤其重要。

(2)实际工业过程可能受到噪声干扰,导致采集数据偏离真实值,因此需要进一步提升算法的鲁棒性。

(3)在实际工业过程中可能存在概念漂移的现象,一旦发生概念漂移,已有的模型参数将无法反映系统内部真实的机理,因此需要设计在线增量学习机制。

参考文献

- [1] LI J, WANG J L, SUI E G, et al. Soft sensor development based on hybrid modeling with ensemble learning for multimode batch processes[J]. IEEE Sensors Journal, 2025, 25(9): 15588-15597.
- [2] DING Z Y, LOO J Y, NURZAMAN S G, et al. A zero-shot soft sensor modeling approach using adversarial learning for robustness against sensor fault[J]. IEEE Transactions on Industrial Informatics, 2023, 19(4): 5891-5901.
- [3] GUO R Y, LIU H, XIE G, et al. A self-interpretable soft sensor based on deep learning and multiple attention mechanism: From data selection to sensor modeling[J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 6859-6871.
- [4] GAO S W, LI T Z, DONG X H, et al. Semi-supervised soft

- sensor modeling based on ensemble learning with pseudolabel optimization[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 2524818.
- [5] ZHU Y Z, XU N, WU F, et al. Fault estimation for a class of Markov jump piecewise-affine systems: Current feedback based iterative learning approach[J]. *IEEE/CAA Journal of Automatica Sinica*, 2024, 11(2): 418-429.
- [6] ZHU Y Z, XU N, BASIN M V, et al. Stability and tracking recovery of continuous-time Markov jump piecewise affine systems using virtual-sensor-based reconfiguration[J]. *IEEE Transactions on Automatic Control*, 2024, 69(4): 2705-2712.
- [7] WANG D H, LI M. Stochastic configuration networks: Fundamentals and algorithms[J]. *IEEE Transactions on Cybernetics*, 2017, 47(10): 3466-3479.
- [8] 代伟, 李德鹏, 杨春雨, 等. 一种随机配置网络的模型与数据混合并行学习方法[J]. *自动化学报*, 2021, 47(10): 2427-2437.
- DAI W, LI D P, YANG C Y, et al. A model and data hybrid parallel learning method for stochastic configuration networks[J]. *Acta Automatica Sinica*, 2021, 47(10): 2427-2437. (in Chinese)
- [9] ZHAO L J, XU Z Y, WANG G G, et al. Distributed online sludge volume index prediction model via image analysis and federated broad stochastic configuration network[J]. *Journal of Water Process Engineering*, 2024, 63: 105534.
- [10] YAN A J, GUO J C, WANG D H. Robust stochastic configuration networks for industrial data modelling with Student's-t mixture distribution[J]. *Information Sciences*, 2022, 607: 493-505.
- [11] 代伟, 张政焯, 杨春雨, 等. 基于SCN数据模型的SISO非线性自适应控制[J]. *自动化学报*, 2024, 50(10): 2002-2012.
- DAI W, ZHANG Z X, YANG C Y, et al. Adaptive control of SISO nonlinear system using data-driven SCN model[J]. *Acta Automatica Sinica*, 2024, 50(10): 2002-2012. (in Chinese)
- [12] HUANG C Q, HUANG Q H, WANG D H. Stochastic configuration networks based adaptive storage replica management for power big data processing[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(1): 373-383.
- [13] 李帷韬, 童倩倩, 王殿辉, 等. 基于深层卷积随机配置网络的电熔镁炉工况识别方法研究[J]. *自动化学报*, 2024, 50(3): 527-543.
- LI W T, TONG Q Q, WANG D H, et al. Research on fused magnesium furnace working condition recognition method based on deep convolutional stochastic configuration networks[J]. *Acta Automatica Sinica*, 2024, 50(3): 527-543. (in Chinese)
- [14] DAI W, LI D P, ZHOU P, et al. Stochastic configuration networks with block increments for data modeling in process industries[J]. *Information Sciences*, 2019, 484: 367-386.
- [15] WANG Q J, HONG Q Q, WU S, et al. Multitarget stochastic configuration network and applications[J]. *IEEE Transactions on Artificial Intelligence*, 2023, 4(2): 338-348.
- [16] WANG D H, LI M. Robust stochastic configuration networks with kernel density estimation for uncertain data regression[J]. *Information Sciences*, 2017, 412: 210-222.
- [17] LU J, DING J L. Mixed-distribution-based robust stochastic configuration networks for prediction interval construction[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(8): 5099-5109.
- [18] LI M, WANG D H. 2-D stochastic configuration networks for image data analytics[J]. *IEEE Transactions on Cybernetics*, 2021, 51(1): 359-372.
- [19] BROWNE F, REES B, CHIU G T, et al. Iterative learning control with time-delay compensation: An application to twin-roll strip casting[J]. *IEEE Transactions on Control Systems Technology*, 2021, 29(1): 140-149.
- [20] WANG L H, CHAI T Y. Signal compensation based adaptive cascade control for regrinding processes[J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(10): 8732-8742.
- [21] 刘鑫. 时滞取值概率未知下的线性时滞系统辨识方法[J]. *自动化学报*, 2023, 49(10): 2136-2144.
- LIU X. Identification of linear time-delay systems with unknown delay distributions in its value range[J]. *Acta Automatica Sinica*, 2023, 49(10): 2136-2144. (in Chinese)
- [22] 焦帆, 曹余庆, 谢莉. 时滞和阶次未知的双率采样输出误差系统辨识[J]. *控制与决策*, 2024, 39(9): 3006-3012.
- JIAO F, CAO Y Q, XIE L. Identification of dual-rate sampled output-error systems with unknown time-delays and orders[J]. *Control and Decision*, 2024, 39(9): 3006-3012. (in Chinese)
- [23] WANG Z C, XING D P, YANG Y M, et al. Delayed dynamic model scheduled reinforcement learning with time-varying delays for robotic control[J]. *IEEE Robotics and Automation Letters*, 2025, 10(3): 2646-2653.
- [24] SUN C X, SONG M X, CAI D R, et al. A systematic review of echo state networks from design to application[J]. *IEEE Transactions on Artificial Intelligence*, 2024, 5(1):

23-37.

- [25] SOLTANI R, BENMOHAMED E, LTIFI H. Echo state network optimization: A systematic literature review[J]. Neural Processing Letters, 2023, 55(8): 10251-10285.
- [26] VIEHWEG J, WORTHMANN K, MÄDER P. Parameterizing echo state networks for multi-step time series prediction[J]. Neurocomputing, 2023, 522: 214-228.

- [27] CHEN X F, LUO X, JIN L, et al. Growing echo state network with an inverse-free weight update strategy[J]. IEEE Transactions on Cybernetics, 2023, 53(2): 753-764.
- [28] DAI W, LI D P, CHEN Q X, et al. Data driven particle size estimation of hematite grinding process using stochastic configuration network with robust technique[J]. Journal of Central South University, 2019, 26(1): 43-62.

作者简介



刘 鑫 男,1990年7月出生于江苏省盐城市. 现为中国矿业大学信息与控制工程学院副教授、博士生导师. 主要研究方向为系统辨识、数据驱动的工业建模和软测量.
E-mail: 15B904027@hit.edu.cn



代 伟 男,1984年3月出生于河南省安阳市. 现为中国矿业大学信息与控制工程学院教授、博士生导师. 主要研究方向为复杂工业过程建模、运行优化与控制.
E-mail: weidai@cumt.edu.cn



刘小庆 男,2001年3月出生于河南省商丘市. 现为中国矿业大学信息与控制工程学院硕士研究生. 主要研究方向为系统辨识、数据驱动的工业软测量建模.
E-mail: xiaoqing_cumt@163.com