DOI: 10. 19650/j. cnki. cjsi. J2311778

基于协同计算的矿浆密度自适应智能检测方法*

王兰豪¹,卫涛杰²,余 刚^{3,4},代 伟²

(1. 中国矿业大学国家煤加工与洁净化工程技术研究中心 徐州 221116; 2. 中国矿业大学信息与控制工程学院
 徐州 221116; 3. 矿冶过程智能优化制造全国重点实验室 北京 100089;

4. 矿冶过程自动控制技术北京市重点实验室 北京 100089)

摘 要:本文针对磨矿分级中传统密度检测方法精度不高且耗时耗力的问题,提出一种矿浆密度智能检测方法。通过对矿浆流体进行机理分析,得到线性已知项和非线性未知项,结合高斯过程回归与正则化随机配置(RSC)算法对矿浆密度进行整体辨识。此外将机理模型估计的方差作为数据驱动模型的训练目标,提高了模型对数据信息的获取程度。同时采用协同计算的方式将自适应智能检测方法应用到工业中,确保矿浆密度检测的实时性和检测模型自适应性。基于工业数据实验分析,本文方法估计密度的平均绝对误差为 7.13、均方根误差为 9.31、决定系数为 99.51%、检测结果相对误差 δ < 1.0% 的样本数量占比83.58%,均优于其他对比算法,极大提高了矿浆密度检测模型的有效性。

关键词: 矿浆密度;数据驱动;随机配置网络;正则化;协同计算

中图分类号: TH7 文献标识码: A 国家标准学科分类代码: 510.80

Adaptive intelligent detection method of pulp density based on collaborative computing

Wang Lanhao¹, Wei Taojie², Yu Gang^{3,4}, Dai Wei²

(1. National Engineering Research Center of Coal Preparation and Purification, China University of Mining and Technology, Xuzhou 221116, China; 2. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China; 3. State Key Laboratory of Intelligent Optimized Manufacturing in Mining & Metallurgy Process, Beijing 100089, China; 4. Beijing Key Laboratory of Process Automation in Mining & Metallurgy, Beijing 100089, China)

Abstract: This article addresses the issues of low accuracy and time-consuming nature associated with traditional density detection methods in ore grinding classification by proposing an intelligent pulp density detection method. Through mechanistic analysis of the pulp fluid, linear known terms and nonlinear unknown terms are identified. A holistic recognition of pulp density is performed by combining Gaussian process regression with a regularized stochastic configuration algorithm. Additionally, the variance estimated by the mechanistic model is set as the training objective for the data-driven model, enhancing the model's capacity to acquire data information. Meanwhile, a collaborative computing method is employed to apply the adaptive intelligent detection method in the industrial domain, ensuring real-time detection and adaptability of the pulp density detection model. Based on industrial data experimental analysis, the proposed method shows an average absolute error of 7. 13, a root mean square error of 9. 31, a determination coefficient of 99. 51%, and a sample quantity proportion of relative error $\delta < 1.0\%$ at 83. 58%. These results are better than those of other comparative algorithms. The effectiveness of the pulp density detection model is enhanced.

Keywords: pulp density; data driven; stochastic configuration network; regularization; collaborative computing

收稿日期:2023-08-08 Received Date: 2023-08-08

^{*}基金项目:国家重点研发计划项目(2022YFB3304700)、国家自然科学基金(52304309,62373361,52261135540)、矿冶过程智能优化制造全国重 点实验室、矿冶过程自动控制技术北京市重点实验室开放基金项目(BGRIMM-KZSKL-2022-7)资助

0 引 言

随着工业社会的发展,金属的使用需求大大增加。 其中钢铁一直是我国国民经济的中流砥柱,是国家的命 脉,是国家生存和发展的物质保障。铁矿石作为钢铁生 产企业最重要的原材料,开采的需求必然很大^[1]。虽然 我国地大物博、矿产资源丰富,铁矿石的储存量也大,但 是富矿石较少,绝大多数为品位低、开发利用经济效益差 的贫矿石^[2]。因此,提高矿石资源的利用率极为重要。 在生产过程中,对生产调度和控制优化是降低能耗、提高 生产效率的关键。矿石生产过程中有很多重要的过程变 量^[3],如矿热炉埋弧冶炼过程中,电弧的耗散功率、料层 电阻等对炉矿有很大影响。高炉炼铁过程铁水温度、Si 含量、S 含量、P 含量等关键质量指标^[45],这些变量会对 生产过程的状态产生影响。因此,对工业过程变量的实 时检测对生产过程的控制、优化意义重大。

在选矿过程中,需要及时知道矿浆当中固体物质含量,以此来指导生产。磨矿过程中,旋流器溢流粒度是关键的工艺参数,而给矿密度直接影响旋流器溢流粒度。 矿浆粘度会随着矿浆密度的增大而增大,当旋流器的给 矿密度增大,由于粘度的增大,溢流粒度会变粗,影响分 级效率。而给矿密度小时,虽然分级效率高,但矿浆处理 量下降,成本耗费增大^[6]。因此,对矿浆密度检测和控制 在分选过程中是必不可少的。

目前矿浆密度检测主要有两种方法:人工化验法和 密度计检测法,而人工智能方法在矿浆密度检测中的应 用很少。下文将介绍这两种常用的检测方法。

人工化验法最常用的方法是密度壶法。就是用密度 壶盛满矿浆液体,然后通过弹簧秤或台秤测量重量,减去 密度壶的重量,之后除以密度壶度量体积,人工计算得知 矿浆密度。

密度壶法操作简单,对采样的矿浆样本检测精度高。 但是人工采样检测速度较慢,检测结果具有时滞性。并 且人工采样周期一般较长,无法保证密度检测的实时性, 不满足工业生产环境对参数实时监控的需求。

密度计的种类有很多,其中常用的密度计有超声波 密度计、γ射线密度计、振动管密度计等。超声波密度计 作为一种常用的密度计,它的检测原理是高能超声波在 矿浆中传播时,一部分会被悬浮粒子散射衰减和吸收衰 减,通过衰减系数得到矿浆密度^[7]。超声波密度计的优 点是无辐射危害,体积小易于安装,缺点是产品造价昂 贵,且测量结果易受矿浆中气泡和流速的影响,在矿浆性 质发生改变时需要重新进行标定。γ射线检测也一直是 在线测量矿浆密度的主要方法,γ射线透过一定厚度的 被测介质可能会损失大部分能量甚至全部能量,后被检 测器所接收^[8]。当介质的厚度一定时,通过对射线的衰减量计算即可得出其密度值^[9]。γ射线密度计的优点是 检测结果精度高、响应速度快、性能稳定。缺点是要求矿 浆不能有沉降,管道内壁结垢及磨损将引起测量误差。 放射源存在安全隐患,审批程序繁琐、管理与检查严格。 振动管密度计内置一根测量管道,当检测的液体通过管 道时,密度的改变会引起管道的振动频率发生改变,由此 可测量出管道内的液体密度^[10]。振动管密度计的优点 是无特定流速要求、安装方便、测量数据稳定、结构耐久 使用,缺点是不同管型的建模、不同介质、测量管非线性 振动等因素,会导致仪器严重的零点漂移,从而影响测量 精度^[11]。

由此可见,无论是人工化验法还是密度计检测法都 有着不可避免且无法忽略的缺陷。为了满足选矿过程中 对矿浆密度检测精确性、实时性的要求,以及对工业生产 过程成本的控制,本文针对这些问题,以实际选矿过程为 研究背景,提出了一种基于协同计算的矿浆密度自适应 智能检测方法。通过对选矿过程中可知部分进行机理建 模与对复杂、不稳定的未知部分进行数据建模相结合,达 到在复杂工业过程中对矿浆密度精准和稳定测量的要 求,并采用协同计算的方式实现矿浆密度自适应智能 检测。

1 过程描述与特性分析

1.1 选矿闭路磨矿过程描述

选矿作业主要流程有原矿输送、破碎筛分、磨矿分 级、选别、脱水等。在选矿生产中,有用矿物会在矿石中 呈细粒嵌布,为了获取矿石中有用的矿物,将矿石细磨是 选矿生产过程中必不可少的步骤。随着研磨细度的减 小,矿物的回收率会一定程度增大,因此适当地减小矿石 的磨碎细度有利于提高矿物的回收率和产量^[12]。因此, 磨矿分级是选矿生产过程最重要的一个环节^[13],主要是 由球磨机、旋流器和矿浆泵等部分组成典型的磨矿闭 路^[14-15],矿浆通过泵输送到旋流器中,经过离心力的作用 分级,粗粒级矿浆从旋流器顶部溢流,进入后续选别工序。

1.2 特性分析

在磨矿分级过程中,旋流器的给矿密度会直接影响 到磨矿粒度^[16]。如果矿浆泵送入的矿浆密度过大,会导 致矿浆颗粒的粘性增强,影响旋流器的分级效果,可能导 致粒度大的矿浆颗粒无法进入球磨机进行研磨,而是从 旋流器溢流进入选别工序,最终导致磨矿产品粒度变粗, 有用矿物的回收率降低。反之,密度过小的矿浆会使得 研磨出的产品粒度变细,使得有用矿物泥化。由此可见, 矿浆密度的实时检测是选矿过程中必要的工作,对实现 矿浆密度的控制具有重要指导作用。本节将对管道中矿 浆流动过程进行机理分析。

根据边界条件的不同,将阻力损失分为两类:对于 平滑的边界,由边界对流体的阻力以及流体粘滞性产 生的阻力损失称为沿程阻力损失;由局部边界急剧改 变导致流体结构改变、流速分布改变并产生旋涡区而 引起的阻力损失称为局部阻力损失。由于矿浆密度检 测是在矿浆流至竖直管道时进行的,可以忽略局部阻 力损失。

在没有阻力损失的理想条件下,压差为:

 $\Delta P = \rho g h \tag{1}$

式中: ρ 为矿浆密度, g 为重力加速度, h 为液面高度差。矿浆在流动过程中发生沿程阻力损失, 计算公式如下:

$$h_f = \lambda \, \frac{L_p}{d} \frac{v^2}{2g} \tag{2}$$

式中: λ 为沿程阻力系数, L_p 为管长,d 为管道直径,v 为断面平均流速,g 为重力加速度。在实际工业过程中,总 压差 $\Delta P = \rho g h - h_f$,可以得到:

$$p = \frac{\Delta P + h_f}{gh} \tag{3}$$

在工业生产过程中,测量密度常用的参数是通过 摆放在不同高度的压力传感器测量得到的压差信号, 但是直接使用压差信号作为检测模型的输入会对检 测结果产生影响。根据伯努利定律,流体的总压不 变。当流速变大时,流体的静压会变小,而矿浆压力 仪表只能测量静压。

借助 Solidworks 软件建立直径为 100 mm,高为 400 mm 的柱体三维模型作为流体域。选用 ANSYS 软件 中的 Fluent-Mesh 模块对流体域进行网格划分,采用四面 体非结构化网格,总网格单元数为 122 917 个,节点数为 128 010 个,如图 1 所示。

采用 Fluent 数值模拟进行求解,湍流模型选用 RNGk - ε模型,矿浆密度为1500 kg/m³,流体入口设 置为速度入口,出口设置为压力出口,设定时间步长为 0.001 s,总时间为2 s 的瞬态计算,待运行计算收敛提 取流体域内 A、B 两点动压强并求得动压差,如图2所 示,依次计算不同流体入口速度条件下 A、B 两点的动 压差 ΔP。

如图 3 所示, A、B 两点的动压差会随着流体入口 流速的增加而增大。而传统的压力传感器是通过液体 压强引发力敏元件受压变形, 引起电桥阻值变化从而 产生的电位差并输出, 把压力转化为电信号输出, 能够 测得液体的静压差但不能测得动压差, 因此直接使用 压差信号作为密度测量模型的输入会对检测结果产生 一定的影响。







此外压力仪表测量压力的时候会产生系统误差以及随机误差,因此考虑将测得的高压侧绝压 P_{H} 和低压侧绝压 P_{L} 进行修正,则在 t 时刻测量得到的压差 $\Delta P(t) = P_{H}(t) - P_{L}(t)$ 改写为:

$$\Delta P(t) = aP_{H}(t) - bP_{L}(t) + c + h_{1}(P_{H}(t), P_{L}(t))$$
(4)

式中: *a*,*b* 为高压和低压的修正系数,*c* 为偏移项,*h*₁(·) 表示测量压力时的未知非线性误差。平均流速 *v* 与矿浆 泵的电流 *I* 和频率 *f* 的未知非线性表达式如下所示:

$$\begin{split} v(t) &= h_2(f(t), I(t)) \quad (5) \\ & \text{将式}(2), (4) \, \pi(5) \, & \text{整合代入式}(4) \, \text{中得到}: \\ \rho(t) &= \rho_0(t) + \Delta \rho(t) \quad (6) \\ & \text{其中}: \\ \rho_0(t) &= k_1 P_H(t) + k_2 P_L(t) + k_3 \\ & \Delta \rho(t) &= h(P_H(t), P_L(t), f(t), I(t)) \\ & k_1 &= \frac{a}{gh}, k_2 &= -\frac{b}{gh}, k_3 &= \frac{c}{gh}(gh > 0) \\ & h(\cdot) &= \frac{h_1(P_H(t), P_L(t))}{gh} + \frac{\lambda L_p h_2^2(f(t), I(t))}{2g^2 dh} \end{split}$$

式中: h(·) 表示包含仪表测量误差、矿浆流动过程中的 未知扰动等未知非线性项。

2 机理与数据驱动的矿浆密度智能检测方法

2.1 矿浆密度整体辨识策略

为了提高在复杂工况下对矿浆密度的检测精度,本 文将回归模型分为线性回归模型和非线性回归模型两部 分。线性模型是基于机理分析得出的可知部分构建的. 而非线性模型则是由数据驱动的模型,是对矿浆密度估 计结果的补偿。由数据采集平台获取高压侧绝压信号、 低压侧绝压信号、频率信号以及电流信号,经过数据预处 理后,将高压侧绝压信号 P_{μ} 、低压侧绝压信号 P_{μ} 作为线 性回归模型的输入,人工化验值 ρ 作为模型输出,用机理 模型得到线性部分估计结果为îo。再将高压侧绝压信号 P_{H} 、低压侧绝压信号 P_{L} 、频率信号 f 以及电流信号 I 作为 非线性回归模型的输入,导师信号 $\Delta \rho (\Delta \rho = \rho - \hat{\rho}_0)$ 作为 标签。另外,提出将线性模型部分估计的方差 σ^2 作为标签, 使得数据驱动模型获取更多数据信息,提高估计的精度。训 练参数估计的结果为 $\Delta \hat{\rho}$ 以及 $\hat{\sigma}2$ 。将线性回归估计的结果与 非线性回归估计的结果结合,最终得到智能检测模型的估计 值 $\hat{\rho}$ 以及置信区间[$\hat{\rho} - 3\hat{\sigma}, \hat{\rho} + 3\hat{\sigma}$]。

2.2 基于高斯过程回归的机理模型

本文的机理模型即线性部分,是通过对矿浆在管道 中的物理过程分析得到的已知部分,采用高斯分布回 归^[17]对矿浆密度的线性部分进行辨识。 采集 $t = k - 1, k - 2, \dots, k - N$ 时刻的数据作为训练集, N 为样本数量。训练数据集表示为 $\{X_1(k-1), Y_1(k-1)\}$, $X_1(k-1) = [x_1^T(k-1), x_1^T(k-2), \dots, x_1^T(k-N)]^T \in \mathbb{R}$ ^{N×2}为输入数据, $x_1(k-i) = [P_H(k-i), P_L(k-i)] \in \mathbb{R}^2$, $i = 1, 2, \dots, N; Y_1(k-1) = [\rho_0(k-1), \rho_0(k-2), \dots, \rho_0(k-N)]^T \in \mathbb{R}^{N\times 1}$ 为线性项的期望输出。

设 $\tilde{\mathbf{x}}_{1}(k) = [P_{H}(k), P_{L}(k), 1], \tilde{\mathbf{X}}_{1}(k-1) = [\tilde{\mathbf{x}}_{1}^{\mathsf{T}}(k-1), \tilde{\mathbf{x}}_{1}^{\mathsf{T}}(k-2), \cdots, \tilde{\mathbf{x}}_{1}^{\mathsf{T}}(k-N)]^{\mathsf{T}}, \hat{\mathbf{Y}}_{1}(k-1) = [\hat{\rho}_{0}(k-1), \hat{\rho}_{0}(k-2), \cdots, \hat{\rho}_{0}(k-N)], \hat{\boldsymbol{\theta}}(k-1) = [k_{1}, k_{2}, k_{3}]^{\mathsf{T}}, 则有:$ $\hat{\mathbf{Y}}_{1}(k-1) = \tilde{\mathbf{X}}_{1}(k-1) \hat{\boldsymbol{\theta}}(k-1)$ (7)

$$\boldsymbol{Y}_{1}(k-1) = \widetilde{\boldsymbol{X}}_{1}(k-1)\,\boldsymbol{\hat{\theta}}(k-1) + \boldsymbol{\varepsilon}$$

$$\tag{8}$$

其中, ε 表示服从高斯分布的噪声,并且 $\varepsilon \sim \mathcal{N}(0, \sigma_s^2)$ 。可以得出目标观测样本的似然函数为:

$$P(Y_{1}(k-1) | \tilde{X}_{1}(k-1), \hat{\theta}(k-1)) =$$

$$\prod_{i=1}^{N} P(\rho_{0}(k-i) | \tilde{x}_{1}(k-i), \hat{\theta}(k-1)) =$$

$$\frac{1}{(2\pi\sigma_{n}^{2})^{\frac{N}{2}}} e^{-\frac{1}{2\sigma_{n}^{2}} |Y_{1}(k-1) - \tilde{X}_{1}(k-1)\hat{\theta}(k-1)|^{2}} =$$

$$\mathcal{N}(\tilde{\boldsymbol{X}}_{1}(k-1)\hat{\boldsymbol{\theta}}(k-1),\sigma_{n}^{2}\boldsymbol{E})$$
(9)

式中: E 为单位矩阵。假设参数 $\hat{\theta}(k-1)$ 的先验概率分 布为 $\hat{\theta}(k-1) \sim \mathcal{N}(0, \Sigma)$,根据贝叶斯公式可得:

其中, $A = \Sigma^{-1} + \sigma_n^{-2} X_1^{\mathsf{T}}(k-1) X_1(k-1)$ 。当t = k时刻数据 $\tilde{\mathbf{x}}_1(k)$ 输入时,机理模型输出值的概率分布为:

$$P(\hat{\rho}_{0}(k) | \tilde{\mathbf{x}}_{1}(k), \tilde{\mathbf{X}}_{1}(k-1), \mathbf{Y}_{1}(k-1) = \int P(\hat{\rho}_{0}(k) | \tilde{\mathbf{x}}_{1}(k), \hat{\boldsymbol{\theta}}(k-1)) P(\hat{\boldsymbol{\theta}}(k-1) | \tilde{\mathbf{X}}_{1}(k-1), \\ \mathbf{Y}_{1}(k-1)) d\hat{\boldsymbol{\theta}} = \mathcal{N}(\sigma_{n}^{-2}\tilde{\mathbf{x}}_{1}(k)\mathbf{A}^{-1}\tilde{\mathbf{X}}\mathbf{T}_{1}(k-1)\mathbf{Y}_{1}(k-1), \\ \tilde{\mathbf{x}}_{1}(k)\mathbf{A}^{-1}\tilde{\mathbf{x}}\mathbf{T}_{1}(k))$$
(11)

式中: $\hat{\rho}_0(k) = \sigma_n^{-2} \tilde{\mathbf{x}}_1(k) \mathbf{A}^{-1} \tilde{\mathbf{X}} \mathbf{T}_1(k-1) \mathbf{Y}_1(k-1)$ 为线性 模型估计结果, 另外还可以得到估计的方差 $\sigma^2(k) = \tilde{\mathbf{x}}_1(k) \mathbf{A}^{-1} \tilde{\mathbf{x}} \mathbf{T}_1(k)$ 。

2.3 基于正则化随机配置网络的数据驱动模型

本文的未知非线性项用数据驱动模型进行拟合,用 正则化随机配置(regularized stochastic configuration, RSC)作为数据驱动的算法。随机配置网络(stochastic configuration networks, SCN)是一种增量式快速建模方 法,在监督机制的约束下,SCN 逐个增加隐藏层节点,并 确定输入权重和偏置,之后使用最小二乘方法计算输出 权重,达到预先设置的精度值或者最大隐藏层节点后停

241

止增加节点,网络构建完成^[18]。RSC 算法是将 SCN 与正则化技术结合得到的改进 SCN 算法^[19],应用 RSC 算法 对矿浆密度非线性项估计过程如下:

给定训练集 { $X_2(k-1), Y_2(k-1)$ }, $X_2(k-1) = [x_2^{T}(k-1), x_2^{T}(k-2), \dots, x_2^{T}(k-N)]^{T} \in \mathbb{R}^{N\times 4}$ 表示输入 数据, $x_2(k-i) = [P_H(k-i), P_L(k-i), f(k-i), I(k-i)] \in \mathbb{R}^4, i = 1, 2, \dots, N; Y_2(k-1) = [y_2^{T}(k-1), y_2^{T}(k-2), \dots, y_2^{T}(k-N)]^{T} \in \mathbb{R}^{N\times 2}$ 表示非线性项的期望输出, $y_2(k-i) = [\Delta \rho(k-i), \sigma^2(k-i)] \in \mathbb{R}^2, i = 1, 2, \dots, N,$ 神经网络结构如图 4 所示。



图 4 正则化随机配置网络结构 Fig. 4 Regularized stochastic configuration network

步骤 1) 给定目标函数 $F: \mathbb{R}^4 \to \mathbb{R}^2$ 假设当前隐含层的节点为 L - 1 个,则神经网络输出结果可由式(12)表示:

$$\boldsymbol{F}_{L-1}^{\mathrm{T}}(\boldsymbol{X}_{2}) = \sum_{j=1}^{L-1} \boldsymbol{\beta}_{j} \boldsymbol{g}_{j} (\boldsymbol{\omega}_{j}^{\mathrm{T}} \boldsymbol{X}_{2}^{\mathrm{T}} + \boldsymbol{b}_{j})$$
(12)

式中: $\boldsymbol{\beta}_{j}$ 表示隐藏层节点j的输出权重; $\boldsymbol{g}_{j}(\cdot)$ 表示第j个激活函数; $\boldsymbol{\omega}_{j}$ 和 b_{j} 分别表示隐含层第j个隐藏节点的输入权重和偏置。

步骤 2) 计算网络输出残差:

$$\boldsymbol{e}_{L-1} = \boldsymbol{Y}_2 - \boldsymbol{F}_{L-1}(\boldsymbol{X}_2) \in \mathbb{R}^{N \times 2}$$
(13)

步骤 3) 最大隐藏层节点数为 L_{max} ,期望精度为 ϵ_{\circ} 若 $L \leq L_{max}$, $\| \boldsymbol{e}_{L-1}^2 > \epsilon$,则增加第 L 个隐藏层节点,令 $\boldsymbol{e}_{L-1} = [\boldsymbol{e}_{L-1,1}, \boldsymbol{e}_{L-1,2}]$,分別由式(14)和(15)得到隐藏层 节点 L的输出 \boldsymbol{h}_L 和监督机制 $\xi_{L,q}$, $q = 1, 2_{\circ}$

$$\boldsymbol{h}_{L} = [\boldsymbol{g}_{L}(\boldsymbol{\omega}_{L}^{\mathrm{T}}\boldsymbol{x}_{2}(k-1) + b_{L}), \boldsymbol{g}_{L}(\boldsymbol{\omega}_{L}^{\mathrm{T}}\boldsymbol{x}_{2}(k-2) + b_{L}), \cdots, \boldsymbol{g}_{L}(\boldsymbol{\omega}_{L}^{\mathrm{T}}\boldsymbol{x}_{2}(k-N) + b_{L})]^{\mathrm{T}}$$
(14)

$$\xi_{L,q} = \frac{(\boldsymbol{e}_{L-1,q}^{\mathrm{T}} \boldsymbol{h}_{L})^{2}}{\boldsymbol{\gamma}} - (1 - r - \boldsymbol{\mu}_{L}) \boldsymbol{e}_{L-1,q}^{\mathrm{T}} \boldsymbol{e}_{L-1,q}, q = 1, 2$$

(15)

式中: $\gamma = (\mathbf{h}_{L}^{\mathrm{T}} \cdot \mathbf{h}_{L} + 1/C)^{2} / (\mathbf{h}_{L}^{\mathrm{T}} \cdot \mathbf{h}_{L} + 2/C)$, 给定 1 - $\epsilon < r < 1$, 令 $\mu_{L} = (1 - r) / (L + 1)$, C 为正则项系数。随机配 置 T_{max} 次, 每次配置将在一定范围内随机选取第 L 个隐 藏层节点的输入权重 $\boldsymbol{\omega}_{L}$ 和偏置 b_{L} , 并计算 $\xi_{L,q}$, q = 1,

2。如果 min $\xi_{L,1}, \xi_{L,2} \ge 0$,则将 $\boldsymbol{\omega}_L, b_L, \xi_{L,q}$ 储存起来;如 果所有 $\xi_{L,q}$ 都不符合条件,则选择更大的 r 值重新配置。 随机配置结束后,选择最大的 $\sum_{q=1}^{2} \xi_{L,q}$ 对应的 $\boldsymbol{\omega}_L, b_L$ 作为 第 L 个节点的输入权重和偏置。

步骤4)通过式(16)计算输出权重β:

$$\boldsymbol{\beta} = \operatorname{argmin}_{\boldsymbol{\beta}} \|\boldsymbol{H}_{l}\boldsymbol{\beta} - \boldsymbol{Y}_{2}\|^{2} + \frac{1}{C} \|\boldsymbol{\beta}\|^{2} = \left(\boldsymbol{H}_{L}^{\mathrm{T}}\boldsymbol{H}_{L} + \frac{\boldsymbol{E}}{C}\right)^{-1} \boldsymbol{H}_{L}^{\mathrm{T}}\boldsymbol{Y}_{2}$$
(16)

式中: $H_L = [h_1, h_2, \cdots, h_L], E$ 为单位矩阵。

步骤 5)得到在 t=k 时刻,数据驱动模型估计表示为:

$$\hat{\boldsymbol{\rho}}(k) = \sum_{j=1}^{L} \boldsymbol{\beta}_{j} \boldsymbol{g}_{j} (\boldsymbol{\omega}_{j}^{\mathrm{T}} \boldsymbol{x}_{2}(k) + b_{j})$$
(17)

2.4 基于协同计算的矿浆密度自适应智能检测方法

随着万物互联的时代到来,云计算、大数据和人工智 能等方法通过互联网平台在工业领域大放异彩。端边云 协同是在端云协同的基础上引入了边缘计算的一种新的 计算框架,边缘计算将数据实时计算和分析的过程放在 了离终端设备更近的地方,缓解了云侧计算的压力,弥补 了端云协同实时处理数据能力不足的缺点^[20-22]。下文将 详细介绍结合端边云协同计算技术与智能检测方法研发 的矿浆密度检测系统。

如图 5 所示, 矿浆密度智能检测方法采用了端-边-云协同架构, 实现了实时监控与智能分析, 有效提高了矿 浆密度检测的精度和效率。端侧设备负责数据采集和初 步处理, 确保系统的实时性和稳定性。在边侧, 边缘控制 系统负责数据处理与在线智能检测模型的执行。操作人 员可通过监控界面实时查看矿浆泵电流、矿浆泵频率、矿 浆压力、矿浆密度等关键参数, 并在交互界面提交人工化 验值用于模型更新。边缘控制系统具备较强的实时性和 低延迟, 满足了工业现场的需求。在云侧, 信息化云平台 中的虚拟机运行矿浆密度检测软件, 与数据库连接实现 数据的读取和存储。云平台从边侧获取处理后的数据, 离线更新和评估模型。当模型精度得到提高时, 将更新 后的模型部署至边侧用于在线检测。云侧为整个系统提 供了强大的计算能力和资源, 实现了数据的集中管理和 模型的优化迭代。

为了保证算法应用在工业现场时能够适应新采集的数据,提出一种自校正机制来监控模型的结构和参数,作为云侧模型更新的策略。当采集到新的人工化验值数据时,如果人工化验值在估计值的置信区间内,将会根据2.1~2.3节所提的算法重新训练模型。当新训练的模型在最近的100组有标签数据集上的均方误差(mean square error, MSE)小于旧模型的均方误差,将新训练模型的结构和参数在在线检测模型上更新;反之,则不更新在线检测模型。



图 5 基于协同计算的矿浆密度智能检测方法结构

Fig. 5 Architecture of the intelligent density detection method for collaborative computing in pulp

3 实验分析

3.1 数据预处理

实验使用的是真实工业现场采集的数据集,数据集 共有 800 组数据,按照训练集:测试集 = 3:1 划分。为 了排除量纲的干扰,让数据驱动模型专注于数据本身,需 要将训练的数据进行最大最小标准化处理。令 $X = [P_{\mu}, P_{\mu}, f, I], X 为 N × 4 阶矩阵,通过式(18)处理数据:$

$$\boldsymbol{X}' = \frac{\boldsymbol{X} - \min(\boldsymbol{X})}{\max(\boldsymbol{X}) - \min(\boldsymbol{X})}$$
(18)

3.2 实验结果分析

为了验证本文算法的可行性,将机理模型、数据驱动 模型以及机理与数据驱动的检测方法做对比。机理模型 为线性模型 Linear;数据驱动模型有 SCN、RSC 模型;机 理与数据驱动的检测方法有线性模型结合 SCN 模型(L-SCN 模型)、用估计方差作为训练目标的 L-SCN(L-V-SCN 模型)、线性模型结合 L-RSC 模型(L-RSC 模型)以 及本文方法估计方差作为训练目标的 L-RSC 网络模型 (L-V-RSC 模型)。本文方法 L-V-RSC 通过交叉验证和 网格搜索的超参数调优技术选择期望精度 ϵ 、最大随机 配置次数 T_{max} 、正则项系数 C等参数,其他模型的超参数 也是通过这种方式选取,防止由于参数选择的偏向性对 实验结论造成影响。

本文统计了7种模型估计误差最小的频率(在所有 测试样本中,每种模型估计误差最小的样本数占比),并 采用平均绝对误差(mean absolute error, MAE)、均方根 误差(root mean square error, RMSE)和决定系数(Rsquare, R2)以及可接受误差界限内的检测值的百分比 $\delta < 1.0\%$ 作为模型评价指标。

图 6 为不同模型 R2、估计误差最小频率以及 δ < 1.0% 比较,图 7 为不同模型 RMSE 和 MAE 比较。可以 观察到,L-V-SCN 模型相较于 L-SCN 模型,在这 5 个指标上 均表现更出色。同样,L-V-RSC 模型在这 5 个指标上 的表现也优于 L-RSC 模型。L-V-RSC、L-RSC、RSC 分别 好于 L-V-SCN、L-SCN、SCN。此外,机理与数据驱动模型 在这 5 个指标上整体上优于单一的机理模型或数据驱动 模型。由此分析得出,用线性部分估计方差作为训练目

标可以提高非线性补充模型对数据的拟合能力;选择 RSC 作为数据驱动模型可以得到更好的估计结果;机理 与数据驱动模型在真实工业数据应用的效果要好于单一 的机理模型或数据驱动模型。



图 6 不同模型 R2、估计误差最小频率以及 δ < 1.0% 比较 Fig. 6 Comparison of different models in terms of R2, minimum estimation error frequency, and δ < 1.0%



图 7 不同模型 RMSE 和 MAE 比较



表1给出7种算法所建立的模型对矿浆密度检测的评价量化指标,可以看出所提出的L-V-RSC的平均绝对误差为7.13、均方根误差为9.31,为7种算法中最小。决定系数为99.51%,更逼近理想值1。并且检测结果相对误差小于 $\delta < 1.0\%$ 的样本数量占比83.58%,所有的评价指标结果均优于其他6种算法。说明本文所提出的L-V-RSC矿浆密度智能检测模型精度最高、鲁棒性最强。

上述 7 种模型估计误差概率密度函数(probability density function, PDF)如图 8 所示,L-V-RSC 估计误差自 相关函数(auto correlation function, ACF)如图 9 所示。 可以看出机理模型和机理与数据驱动模型的误差均值基 本都接近 0,曲线仅有一个高峰,符合高斯分布,误差序 列为随机数据。然而,在局部细节方面,L-V-RSC 模型的 误差概率密度函数更接近对称轴,此外 L-V-RSC 模型的 误差自相关曲线接近于白噪声,这表明模型估计误差

表 1 模型检测结果评价 Table 1 Model evaluation results

模型	估计误差 最小频率/%	MAE	RMSE	R ² /%	δ<1. 0%
Linear	12.00	7.69	10.31	99.40	78.60
SCN	8.00	28.61	35.26	93.08	29.35
RSC	10.00	17.99	22.94	97.08	40. 29
L-SCN	12. 50	7.70	9.93	99.45	79.60
L-V-SCN	14. 50	7.41	9. 59	99.49	80. 59
L-RSC	16.00	7.37	9.55	99.49	82. 58
L-V-RSC	27.00	7.13	9.31	99.51	83. 58

是随机误差、与模型本身关系较小,其具有较好的估计性能和较强的泛化能力。这种特性使得 L-V-RSC 模型更加适用于复杂工业生产环境,而其他 6 个模型可能会在某些工况下表现出较差的性能。



error for the L-V-RSC model

4 工业应用分析

在工业应用中,采用西门子 S7-1500 PLC 通过 RS485 总线和 Modbus-RTU 协议与边侧设备通信,实时采 集和发送现场数据。边侧设备使用 TIA V16 和 Modscan32 软件模拟 Modbus 通信,同时可以远程监控和 控制现场设备。边侧数据会经过私有云协议传送到云端 进行分析和存储。为了在线检测矿浆密度并提供可视化 界面,开发了一个基于 Vue、Spring Boot 和 Flask 框架的 矿浆密度检测软件,支持数据展示、存储和查询功能。本 软件已经投入河北唐山某选矿厂现场应用 9 个月余,用 户友好的界面设计简化了操作流程,减少了工作人员误 操作的次数。如图 10 所示,该表格从软件界面上截取, 为系统投运后随机抽样化验得到最新的 10 组对比值,可 见这 10 组数据中通过协同计算得到的密度估计结果与 人工化验结果的相对误差均小于 1%。表 2 为投运 9 个 月的矿浆密度估计误差分析,当设置可接受相对误差小 于 2%时为合格,投运至今大部分月份的合格率为 100%, 所有月份合格率均在 95%以上,说明经过这段时间的运 行和实践,本文提出的基于协同计算的矿浆密度自适应 智能检测方法在工业中取得良好的效果,对生产效率提 升有着重要的意义。

□ 2023-08-01	- 2023-	-08-02	人工化验密	度: 0-1500 ∨	Q 查诸	1	生成数据
采集时间 ≑	是否异常	高压值/Pa ≎	低压值/Pa ¢	变频器电流/A \$	变频器频率/Hz ♥	模型估计密度/(kg/m³) €	人工化验密度/(kg/m³) ¢
2023-08-01 09:00:00	否	39 720.87	27 620.45	3.31	43.3	1 237.67	1 234.69
2023-08-01 11:00:00	否	31 629.44	20 849.98	3.16	39.56	1 098.57	1 099.94
2023-08-01 13:00:00	否	42 351.92	31 490.18	3.35	46.82	1 100.75	1 108.34
2023-08-01 15:00:00	否	48 067.63	37 161.58	3.52	49.57	1 101.99	1 102.86
2023-08-01 17:00:00	否	48 276.51	37 376.79	3.51	49.22	1 105.58	1 110.21
2023-08-02 09:00:00	否	28 097.47	16 488.83	3.11	35.88	1 178.18	1 182.55
2023-08-02 11:00:00	否	28 325.34	16 729.36	3.09	35.91	1 187.13	1 183.26
2023-08-02 13:00:00	否	30 673.66	19 071.34	3.15	37.76	1 176.57	1 180.90
2023-08-02 15:00:00	否	30 717.96	19 115.65	3.12	37.73	1 176.52	1 181.91
2023-08-02 17:00:00	否	35 857.67	24 204.72	3.22	41.35	1 184.26	1 189.07

图 10 抽样化验结果表格

Fig. 10 Sampling inspection result table

表 2 投运 9 个月的矿浆密度估计误差分析

Table 2	Analysis of pulp	density e	estimation n	ine months a	after de	ployment

月份	月化验次数	平均密度 (人工化验)	平均绝对误差	最大绝对误差	δ<1. 0%	<i>δ</i> <2.0% (合格率)/%
2022. 11	50	1 276.75	9. 23	41.16	76.00	96.00
2022. 12	36	1 251.07	7.35	21.73	77.78	100.00
2023.01	46	1 251.90	5.56	14. 70	95.65	100.00
2023.02	44	1 248.05	8.79	16.09	90. 91	100.00
2023.03	40	1 211.60	6.56	16.05	80.00	100.00
2023.04	34	1 239. 17	8.71	24.98	88. 23	97.05
2023.05	56	1 213.99	6.97	22. 91	85.71	100.00
2023.06	50	1 255.77	6. 29	26.14	76.00	98.00
2023.07	44	1 242. 45	7.23	21.46	77.27	100.00

5 结 论

本文对管道中矿浆流体流动过程进行了分析,借助 Solidworks 和 Fluent 软件对流体进行仿真,为本文将高 压、低压信号作为模型输入的合理性提供了实验依据,并 建立了机理与数据驱动的矿浆密度智能检测整体模型。 用高斯过程回归对机理模型参数辨识,结合正则化技术 与随机配置网络作为数据驱动模型,并且提出将机理模 型估计得到的方差作为数据驱动模型的训练目标,提高 了数据驱动模型的精度。采用协同计算的方式提出了矿 浆密度自适应智能检测方法,提出了基于模型估计置信 区间的自校正机制。通过基于工业实际数据的实验结果 表明,所提出的方法检测精度能够达到生产工艺对矿浆 密度检测精度要求,为实现选矿矿浆密度闭环优化控制 创造了条件。

参考文献

- MOREAU K, LAAMANEN C, BOSE R, et al. Environmental impact improvements due to introducing automation into underground copper mines [J]. International Journal of Mining Science and Technology, 2021, 31 (6): 1159-1167.
- [2] ZHANG H, ZHANG P, ZHOU F, et al. Application of multi-stage dynamic magnetizing roasting technology on the utilization of cryptocrystalline oolitic hematite: A review[J]. International Journal of Mining Science and Technology, 2022, 32(4): 865-876.
- [3] 李沛,阳春华,贺建军,等.基于影子趋势对比的矿 热炉炉况在线辨识及趋势预测[J].自动化学报, 2021,47(6):1343-354.

LI P, YANG CH H, HE J J, et al. Smelting condition identification and prediction for ubmerged arc furnace based on shadow-trend-comparison[J]. Acta Automatica Sinica, 2021, 47(6): 1343-1354.

[4] 周平,李瑞峰,郭东伟,等.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[J].控制理论与
 应用,2016,33(6):727-734.

ZHOU P, LI R F, GUO D W, et al. Multi-output support vector regression modeling for multivariate molten iron quality indices in blast furnace ironmaking process[J]. Control Theory & Applications, 2016, 33(6): 727-734.

 [5] 宋贺达,周平,王宏,等.高炉炼铁过程多元铁水质 量非线性子空间建模及应用[J].自动化学报,2016, 42(11):1664-1679.

SONG H D, ZHOU P, WANG H, et al. Nonlinear subspace modeling of multivariate molten iron quality in blast furnace ironmaking and its application [J]. Acta Automatica Sinica, 2016, 42(11): 1664-1679.

[6] 冯静安.电石渣除杂水力旋流器关键参数数值模拟 试验优化与影响分析[D].武汉:华中科技大学, 2017.

> FENG J AN. Numerical simulation test optimization and impact analysis of key parameters of calcium carbide slag

hydraulic cyclone for impurity removal [D]. Wuhan: Huazhong University of Science and Technology, 2017.

- [7] MORKUN V, MORKUN N. Estimation of the crushed ore particles density in the pulp flow based on the dynamic effects of high-energy ultrasound [J]. Archives of Acoustics, 2018, 43(1): 61-67.
- [8] 程栋,温和,滕召胜,等.基于双能γ射线的煤质灰分 软测量技术研究[J]. 仪器仪表学报, 2014, 35(10): 2263-2270.
 CHENG D, WEN H, TENG ZH SH, et al. Study on soft-sensing of coal ash content based on dual-energy γray[J]. Chinese Journal of Scientific Instrument, 2014, 35(10):2263-2270.
- [9] 杨洁明,魏晋宏,熊诗波.基于γ射线密度探测的跳 法机床层松散度回归方法[J].仪器仪表学报,2007, 28(7):1300-1304.
 YANG J M, WEI J H, XIONG SH B. Regressive method of jig bed mobility based on γ ray density detection[J]. Chinese Journal of Scientific Instrument, 2007, 28(7): 1300-1304.
- [10] 徐宸.管道液体密度在线监测系统研究[D].哈尔滨:哈尔滨工业大学,2021.
 XU CH. Research on online monitoring system for

XU CH. Research on online monitoring system for pipeline liquid density [D]. Harbin: Harbin Institute of Technology, 2021.

- [11] 罗凡,甘蓉,赵普俊,等.科里奥利质量流量计传感器零点模型研究及应用[J].仪器仪表学报,2021,41(8):15-23.
 LUO F, GAN R, ZHAO P J, et al. Research and application of the zero-point model of the sensor in Coriolis mass flowmeter[J]. Chinese Journal of Scientific Instrument, 2021, 41(8):15-23.
- [12] 杨玮.复杂难处理金精矿提取及综合回收的基础研究与应用[D].长沙:中南大学,2011.
 YANG W. Basic research and application of extraction and comprehensive recovery of complex refractory gold concentrate[D]. Changsha: Central South University, 2011.
- [13] 柴天佑.复杂工业过程运行优化与反馈控制[J].自动化学报,2013,39(11):1744-1757.
 CHAITY. Operational optimization and feedback control for complex industrial processes [J]. Acta Automatica Sinica, 2013, 39(11): 1744-1757.

[14] 卿宗胜, 高云鹏, 吴聪,等. 基于自适应 VMD 和改进

功率谱估计的球磨机负荷特征提取[J]. 仪器仪表学报, 2020, 41(5): 234-241.

QING Z SH, GAO Y P, WU C, et al. Feature extraction method of ball mill load based on the adaptive variational mode decomposition and the improved power spectrum analysis [J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 234-241.

- [15] NKWANYANA S, LOVEDAY B. Addition of pebbles to a ball-mill to improve grinding efficiency [J]. Minerals Engineering, 2017, 103: 72-77.
- [16] QUTEISHAT M A K. Hydrocyclone flow characteristics and measurements [J]. Flow Measurement and Instrumentation, 2020, DOI: 10.1016/ j. flowmeasinst. 2020. 101741.
- [17] CAO Z, WU X, TANG B, et al. Gaussian process regression for prediction of hydrogen adsorption temperature-pressure dependence curves in metal-organic frameworks [J]. Chemical Engineering Journal, 2023, DOI: 10.1016/j.cej.2023.146553.
- [18] WANG D, LI M. Stochastic configuration networks: Fundamentals and algorithms [J]. IEEE Transactions on Cybernetics, 2017, 47(10): 3466-3479.
- [19] 王前进,杨春雨,马小平,等.基于随机配置网络的 并下供给风量建模[J].自动化学报,2021,47(8): 1963-1975.
 WANG Q J, YANG CH Y, MA X P, et al. Underground

airflow quantity modeling based on SCN [J]. Acta Automatica Sinica, 2021, 47(8): 1963-1975.

- [20] ZHOU X, XU X, LIANG W, et al. Deep-learningenhanced multitarget detection for end-edge-cloud surveillance in smart IoT [J]. IEEE Internet of Things Journal, 2021, 8(16):12588-12596.
- [21] 高傃婷,柴天佑.端边云协同的氧化铝生产过程苛性 碱浓度智能预报方法[J].自动化学报,2023,49(5): 964-973.

GAO S T, CHAI T Y. Intelligent forecasting method of caustic concentration in alumina production process based on end-edge-cloud coordination [J]. Acta Automatica Sinica, 2023, 49(5): 964-973.

[22] 张菁雯,柴天佑,李慷. 电熔镁砂生产用电需量多步 智能预报方法[J]. 自动化学报, 2023, 49(9): 1868-1877.

> ZHANG J W, CHAI T Y, LI K. Multi-step intelligent forecasting method for electricity demand of fused magnesia production[J]. Acta Automatica Sinica, 2023, 49(9): 1868-1877.

作者简介



王兰豪,2022 年毕业于东北大学流程工 业综合自动化国家重点实验室,获得博士学 位。现为中国矿业大学副教授,矿物加工工 程专业硕导,主要研究方向为选矿生产全流 程优化决策与智能控制方法及其应用、选矿 生产过程的工艺参数检测方法及其应用。

E-mail: wanglanhao888@ 163. com

Wang Lanhao received his Ph. D. degree from the State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University in 2022. He is currently an associate professor and a master advisor in the field of Mineral Processing Engineering at China University of Mining and Technology. His main research interests include the optimization and intelligent control of the entire mineral processing production process, as well as the detection and application of process parameters within these operations.



余刚,2012年毕业于东北大学流程工业 综合自动化国家重点实验室,获得博士学 位。现为矿冶科技集团有限公司信息技术 与自动化研究设计所副所长、副研究员,主 要研究方向为选冶工业过程建模、智能优化 控制技术研发及应用。

E-mail: yugang@ bgrimm. com

Yu Gang received his Ph. D. degree from the State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University in 2012. He is currently serving as the deputy director and associate researcher at the Information Technology and Automation Research and Design Institute of Beijing General Research Institute of Mining &Metallurgy. He primarily engages in the research and development, as well as the application of modeling, intelligent optimization and control technology within the selection metallurgical industry process.



代伟(通信作者),2015年毕业于东北 大学流程工业综合自动化国家重点实验室, 获得博士学位。现为中国矿业大学人工智 能研究院、信息与控制工程学院教授,博导, 主要研究方向为工业数据分析与建模、工业 运行优化控制。

E-mail: weidai@cumt.edu.cn

Dai Wei (Corresponding author) received his Ph. D. degree from State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University in 2015. He is currently a professor and a Ph. D. advisor in the Artificial Intelligence Research Institute and School of Information and Control Engineering, China University of Mining and Technology. His main research interests are data analysis and modeling, industrial operation optimization control.