文章编号:1674-2974(2024)02-0111-10 DOI:10.16339/j.cnki.hdxbzkb.2024231

基于ISSA-HKLSSVM的浮选精矿品位预测方法

高云鹏[1†],罗芸[1],孟茹[1],张微[1],赵海利[2,3]
(1. 湖南大学 电气与信息工程学院, 湖南 长沙 410082;
2. 矿冶过程自动控制技术国家重点实验室, 北京 100160;
3. 矿冶过程自动控制技术北京市重点实验室, 北京 100160)

摘 要:针对浮选过程变量滞后、耦合特征及建模样本数量少所导致精矿品位难以准确预测的问题,提出了一种基于改进麻雀搜索算法(Improved Sparrow Search Algorithm,ISSA)优化混核最小二乘支持向量机(Hybrid Kernel Least Squares Support Vector Machine,HKLSSVM)的浮选过程精矿品位预测方法.首先采集浮选现场载流X荧光品位分析仪数据作为建模变量并进行预处理,建立基于最小二乘支持向量机(Least Squares Support Vector Machine,LSSVM)的预测模型,以此构建新型混合核函数,将输入空间映射至高维特征空间,再引入改进麻雀搜索算法对模型参数进行优化,提出基于ISSA-HKLSSVM方法实现精矿品位预测,最后开发基于LabVIEW的浮选精矿品位预测系统对本文提出方法实际验证.实验结果表明,本文提出方法对于浮选过程小样本建模具有良好拟合能力,相比现有方法提高了预测准确率,可实现精矿品位的准确在线预测,为浮选过程的智能调控提供实时可靠的精矿品位反馈信息.

关键词:浮选;精矿品位;最小二乘支持向量机;改进麻雀搜索算法;预测模型
中图分类号:TD923 **文献标志码**:A

A Method for Predicting Flotation Concentrate Grade Based on ISSA-HKLSSVM

GAO Yunpeng[1†],LUO Yun[1],MENG Ru[1],ZHANG Wei[1],ZHAO Haili[2,3]
(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;
2. State Key Laboratory of Process Automation in Mining & Metallurgy, Beijing 100160, China;
3. Beijing Key Laboratory of Process Automation in Mining & Metallurgy, Beijing 100160, China)

Abstract: A flotation process concentrate grade prediction method based on the Improved Sparrow Search Algorithm (ISSA) optimized Hybrid Kernel Least Squares Support Vector Machine (HKLSSVM), a flotation process concentrate grade prediction method is proposed to address the issues of delayed variables, coupling characteristics, and limited modeling sample size in the flotation process, which make it difficult to accurately predict the concentrate grade. Firstly, collect data from the flotation site current carrying X-ray fluorescence grade analyzer as

* **收稿日期**:2023-09-20
基金项目:国家重点研发计划资助项目(2021YFF0602402),National Key Research and Development Program of China (2021YFF0602402);矿冶过程自动控制技术国家重点实验室开放基金(BGRIMM-KZSKL-2020-09),Open Foundation of State Key Laboratory of Process Automation in Mining & Metallurgy(BGRIMM-KZSKL-2020-09)
作者简介:高云鹏(1978—),男,辽宁营口人,湖南大学教授,博士
† 通信联系人,E-mail:gaoyp@hnu.edu.cn

modeling variables and preprocess them to establish a prediction model based on the Least Squares Vector Machine. On this basis, a new mixed kernel function is constructed to map the input space to the high-dimensional feature space. Then, an Improved Sparrow Search Algorithm is introduced to optimize the model parameters, and an ISSA-HKLSSVM method is proposed to achieve concentrate grade prediction. Finally, a flotation concentrate grade prediction system based on LabVIEW is developed to verify the proposed method in practice. The experimental results show that the proposed method has a better fitting ability for small sample modeling in the flotation process. It can improve prediction accuracy compared to existing methods, and can achieve accurate online prediction of concentrate grade, providing real-time and reliable concentrate grade feedback information for intelligent control of the flotation process.

Key words: flotation; concentrate grade; least squares support vector machine; improve sparrow search algorithm; prediction model

我国地质资源丰富,但矿石资源存在贫瘠、细碎、杂质多的特点,品位值普遍偏低,为满足工业生产中对优质炉料的需求,我国积极推动以浮选为代表的选矿技术的发展.精矿品位作为浮选生产的重要经济指标,其稳定和提高可为企业带来巨大的经济效益[1].目前浮选过程精矿品位主要依靠人工化验获得,然而这种方法具有较大的滞后性,操作员无法及时获取精矿品位的变化信息,无法为浮选生产操作和过程优化提供有效的指导[2].因此研究浮选过程生产指标实时在线检测方法,对稳定浮选过程、优化浮选操作及提高我国矿石资源的综合利用水平具有重要的价值和意义.

针对浮选过程精矿品位检测方法,国内外学者进行了大量的研究,主要分为基于机理的建模方法和基于数据的建模方法[3].浮选机理复杂,其过程涉及到化学、物理学且伴随较多随机因素,为准确描述真实浮选过程,传统基于机理的建模方法会对其进行一定的假设和简化[4].目前浮选产品指标的检测主要采用基于数据的建模方法[5],该方法只需在获得输入和输出数据后,利用误差最小化原理和统计分析方法拟合已有数据,而无需了解复杂的浮选内部机制,因而逐渐成为主流的浮选精矿品位检测方法.Kaartincal等[6]采集给矿流量、气量pH值等为输入变量,利用偏最小二乘法(Partial Least Squares, PLS)建立铜浮选过程精矿品位预测模型,得到较为满意的预测效果.Shean等[7]对比研究线性回归、PLS、神经网络等方法,以给矿品位、给矿浓度等作为建模参数建立精矿品位预测模型,对比结果显示基于PLS方法建模效果更好,可为现场操作人员提供有效指导.Cook等[8]利用泡沫大小、个数、RGB值及其他工况参数作为输入变量,在多层感知机基础上开展浮选精矿等级预测.Shahbazi等[9]以给矿品位值、精矿阀门开度、尾矿阀门开度为输入变量,引入动态前馈神经网络,使得浮选过程的关键性能指标预测的精度有一定提升.Allahkarami等[10]以药剂量、泡沫层厚度、进气量等作为输入,采用多层前馈神经网络构建铜精矿及钼精矿品位预测模型,其实测及仿真结果表明多层前馈神经网络相较线性回归预测建模更准确.

已有研究虽对精矿品位预测的各方面进行深入探讨,但仍然存在一些不足.首先,大部分浮选精矿品位预测研究集中在利用生产过程给矿浓度、温度等工艺参数建立预测模型,该种建模方法无法充分考虑实际浮选过程的滞后和耦合特征,易引入显著误差[11].并且,神经网络的外推能力和解释能力较弱,当训练过程中出现训练集与测试集差异较大情况时,这种局限性将导致所建立的神经网络模型无法准确预测精矿品位[12].

为解决上述问题,考虑浮选过程工艺参数的耦合性、滞后性及精矿品位小样本建模预测的需求,本文采集浮选现场载流X荧光品位分析仪数据,并在最小二乘支持向量机(Least Squares Support Vector Machine,LSSVM)方法基础上构建精矿品位预测模型.为了解决单一核函数在保证良好泛化性和较高预测准确度方面存在的困难,通过对现有经典核函数特征的分析,构建一种新型混合核函数,用于解决浮选精矿品位预测过程中输入特征空间的映射问

题.同时为增强模型的自适应性,设计改进麻雀搜索算法(Improved Sparrow Search Algorithm,ISSA)对混核最小二乘支持向量机(Hybrid Kernel Least Squares Support Vector Machine,HKLSSVM)预测模型的参数进行优化,建立基于ISSA-HKLSSVM的浮选过程精矿品位预测模型,并基于某选矿厂浮选车间的实际生产工况验证本文提出方法的准确性和有效性.

1　浮选工艺过程及问题描述

单槽浮选是一种常用的矿石分离方法,其工作原理如图1所示.在该过程中,上游生产环节的矿浆通过浮选槽的给矿口进入,同时加入浮选药剂.为增强浮选效果,向浮选槽中通入空气使其形成微小气泡,这些气泡会吸附矿物颗粒,并上浮至矿浆表面形成泡沫层.随后,泡沫层被刮出并回收,而未被浮选的颗粒则仍然留在料浆中,经过适当处理后被废弃.精矿品位作为评价浮选过程的关键性能指标,其结果能够有效指导生产,提高浮选产品质量.精矿品位过低,表征生产过程中存在磨矿细度过大、矿浆浓度不足、药剂种类及数量不适宜、充气及搅拌时间过短等问题,浮选效率较低.为确保浮选过程的顺行和产品质量,操作者需要对精矿品位进行实时在线的监控.

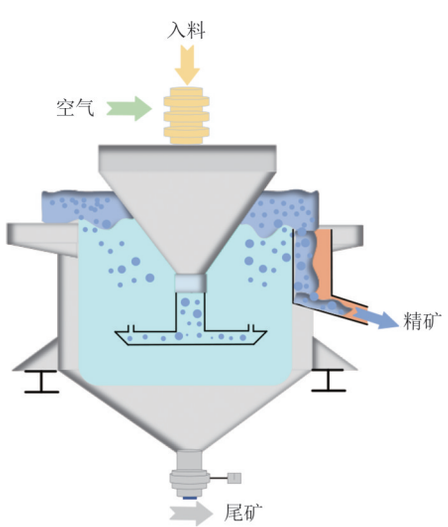


图1　单槽浮选过程原理图

Fig.1　Schematic diagram of single cell flotation process

载流X荧光品位分析仪为一种实时在线检测矿物质品位的分析仪器,应用于选矿厂浮选流程,可实现对矿浆样品品位的监测[13],其工作原理是对矿浆样品中化学元素的特征X射线进行激发和测量,所激发射线的能量和元素种类有关,强度与元素含量有关.其工作原理如图2所示.

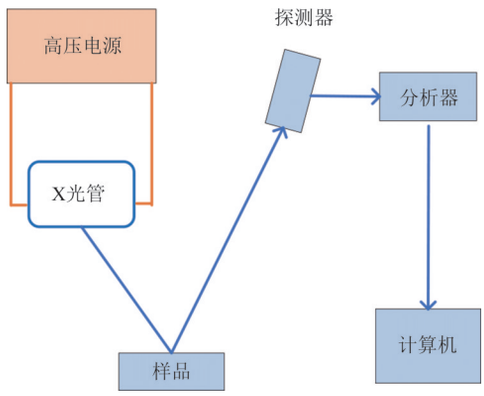


图2　载流X荧光品位分析仪工作原理

Fig.2　Working principle of BOXA current carrying X-ray fluorescence grade analyzer

矿浆经采样器采样后,经由多路器流入BOXA载流X荧光品位分析仪中,分析仪对矿浆进行荧光激发,测得矿浆样品中不同元素的特征射线强度,进行建模,输出精矿品位.

矿浆中矿物的组成复杂,其元素成分、粒度大小均会对主要元素所激发的射线强度产生一定影响,由此决定了精矿品位的模型也是多变量的,具有强非线性和不确定性.因此,精矿品位可由一个非线性模型描述,其表达式为:

$$y^t = F(x^t) \tag{1}$$

式中:t表示采样时间;x^t表示t时刻的输入向量,即载流X荧光品位分析仪各个能量通道的值;y^t表示在采样时刻t的输出,即精矿品位的值.因此,精矿品位的在线检测等同于构建基于数据驱动的预测模型F',使其尽可能逼近非线性的浮选过程以准确实现精矿品位的在线预测.据此,本文建立新型F'来构建精矿品位预测模型,采用改进算法对F'进行训练及优化,进一步提高精矿品位预测模型的性能.

2　ISSA-HKLSSVM品位预测模型构建

LSSVM作为一种用于处理数据分类与回归的新技术,小样本学习使其具有很强的泛化能力[14],因而更适合浮选过程精矿品位的在线建模研究.在LSSVM的训练过程中,核函数用于将输入空间映射为高维特征空间,其特征会影响到LSSVM的训练过程及预测结果准确度[15].本文线性组合高斯核函数与多项式核函数,利用HKLSSVM方法实现精矿品位预测.为得到更好的模型参数,提出ISSA方法,对预

测模型进行参数优化.

2.1 混核最小二乘支持向量机

LSSVM 为基于支持向量机(Support Vector Machine, SVM)的改进,将SVM优化问题里的不等式约束替换为等式约束,并将二次规划问题转变为较简单的线性方程组进行求解,因此运行速度较快,计算复杂性较低[16].基于LSSVM的优势,在分析经典核函数特性后,本文建立一种混核LSSVM以兼顾模型的学习能力与泛化能力.

首先在高维特征空间构造最优决策函数,将非线性估计函数转化为线性估计函数:

$$f(x_i) = w^{\mathrm{T}} \times x_i + b,\ i = 1, 2, \cdots, N \tag{2}$$

式中:$x_i=(x_{i,1}, x_{i,2}, \cdots, x_{i,D})$表示输入数据,$D$为输入数据的维度;$N$为样本数;$f(x_i)$为函数输出值;$b$为偏差;$w^{\mathrm{T}}$为回归系数.

把回归问题转换成带有约束的优化问题,即

$$\begin{aligned} &\min_{w,b,\xi} J(\boldsymbol{w},\xi) = \frac{1}{2}\|\boldsymbol{w}\|^2 + \frac{\gamma}{2}\sum_{i=1}^{N}\xi_i^2 \\ &\text{s.t.} \quad y_i = w^{\mathrm{T}} \times \boldsymbol{\varphi}(x_i) + b + \xi_i, \gamma \geqslant 0 \end{aligned} \tag{3}$$

式中:γ为惩罚因子;ξ_i为松弛变量;$\boldsymbol{\varphi}(x_i)$为从低维到高维特征空间的映射.

引入拉格朗日乘子,构造函数:

$$J(w,b,\xi_i,\alpha_i) = J(\boldsymbol{w},\xi_i) - \sum_{i=1}^{N}\alpha_i\left\{w^{\mathrm{T}}\varphi(x_i) + b + \xi_i - y_i\right\} \tag{4}$$

式中:α_i为拉格朗日乘子.

利用L分别对式(4)的拉格朗日乘子α_i、偏差b、松弛变量ξ_i以及回归系数w进行求导,可得:

$$\begin{cases} \dfrac{\partial L}{\partial \boldsymbol{w}} = 0 \rightarrow w = \displaystyle\sum_{i=1}^{N}\alpha_i\varphi(x_i) \\ \dfrac{\partial L}{\partial b} = 0 \rightarrow \displaystyle\sum_{i=1}^{N}\alpha_i = 0 \\ \dfrac{\partial L}{\partial \xi_i} = 0 \rightarrow \alpha_i = \gamma\xi_i \\ \dfrac{\partial L}{\partial \alpha_i} = 0 \rightarrow w^{\mathrm{T}}\varphi(x_i) + b + \xi_i + y_i = 0 \end{cases} \tag{5}$$

消去w和ξ_i后,求解的优化问题转化为如下线性方程组.

$$\begin{bmatrix} 0 & \boldsymbol{I}^{\mathrm{T}} \\ \boldsymbol{I} & \boldsymbol{\Omega} + \gamma^{-1}\boldsymbol{I} \end{bmatrix}\begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \boldsymbol{y} \end{bmatrix} \tag{6}$$

式中:$\boldsymbol{\Omega}=K(\boldsymbol{x}_i, \boldsymbol{x}_j)=\varphi(\boldsymbol{x}_i)^{\mathrm{T}}\varphi(\boldsymbol{x}_j)$;$\boldsymbol{I}=[1, 1, \cdots, 1]^{\mathrm{T}}$;$\boldsymbol{y}=[y_1, y_2, \cdots, y_N]^{\mathrm{T}}$;$\boldsymbol{\alpha}=[\alpha_1, \alpha_2, \cdots, \alpha_N]^{\mathrm{T}}$.

由此得到最终LSSVM预测模型为:

$$f(x_i) = \sum_{i=1}^{N}\alpha_i K(x, x_i) + b \tag{7}$$

核函数$K(x_i, x_j)$分为全局核函数和局部核函数,其主要实现样本从低维到高维特征空间的映射.全局核函数对于远距离样本泛化性能较好,但对于近距离样本学习性能较差.局部核函数学习性能强,但泛化性能弱.通过构造混合核函数,可有效结合两者的优点.

高斯径向基函数局部性强,可将数据映射至一个更高维的空间内,使其变得线性可分,基于这一优势,选取其为精矿品位预测模型的局部核函数.

$$K_1(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \tag{8}$$

式中:σ为高斯径向基核函数的宽度参数.

多项式核函数具有出色的全局性能,在整个数据空间中都能捕捉到全局关系,结合这一特点,选取其为精矿品位预测模型的全局核函数:

$$K_2(x_i, x_j) = (x_i^{\mathrm{T}} \cdot x_j + 1)^m, m \in N^* \tag{9}$$

式中:m为多项式核函数参数.

通过线性组合构造混合核函数,仍然满足容许核条件:

$$K(x_i, x_j) = aK_1(x_i, x_j) + (1 - a)K_2(x_i, x_j) \tag{10}$$

通过对混合核函数权重系数α进行调整,可实现精矿品位预测模型局部特性与全局特性的平衡.

2.2 改进麻雀搜索算法

为得到准确的HKLSSVM精矿品位预测模型参数,本文提出改进麻雀搜索算法对其参数进行优化.

麻雀搜索算法(Sparrow Search Algorithm, SSA)灵感来源于麻雀的觅食和反捕食行为,该算法模拟麻雀种群中的探索者、伴随者、侦查者三种角色,以及相互间的交互和更新机制[17-18],与其他算法相比具有更高的收敛性能和更强的局部搜索能力.

在SSA中,种群中n只麻雀在d维解空间的初始位置为:

$$\boldsymbol{X} = \begin{bmatrix} x_{1,1}\, x_{1,2} \cdots x_{1,d} \\ x_{2,1}\, x_{2,2} \cdots x_{2,d} \\ \vdots\ \ \vdots\ \ \vdots\ \ \vdots \\ x_{n,1}\, x_{n,2} \cdots x_{n,d} \end{bmatrix} \tag{11}$$

式中:d表示变量维度;n表示麻雀数量.

则初始种群中麻雀的适应度值为:

$$\boldsymbol{F}_X = \begin{bmatrix} f\left(x_{1,1}\, x_{1,2} \cdots x_{1,d}\right) \\ f\left(x_{2,1}\, x_{2,2} \cdots x_{2,d}\right) \\ \vdots\ \ \vdots\ \ \vdots\ \ \vdots \\ f\left(x_{n,1}\, x_{n,2} \cdots x_{n,d}\right) \end{bmatrix} \tag{12}$$

式中:$\boldsymbol{F}_X$每行的值代表每个麻雀个体的适应度.

SSA位置更新流程可分为三个步骤,即探索者更新、伴随者更新和危险预警.在进化过程中,用下式更新探索者的位置信息.

$$X_{ij}^{t+1}=\begin{cases}X_{ij}^{t}\cdot\exp\left(-\dfrac{i}{\alpha\cdot \mathrm{iter}_{\max}}\right), & R_2<\mathrm{ST}\\ X_{ij}^{t}+Q\cdot\boldsymbol{P}, & R_2\geqslant\mathrm{ST}\end{cases}\tag{13}$$

式中:t代表当前进化代数;$\mathrm{iter}_{\max}$为预先设定的最大进化代数;X_{ij}为种群中序号为i的麻雀在第j维中的位置;R_2为停滞阈值;ST为安全阈值;α为[0,1]中的随机数;$\boldsymbol{P}=[1,1,\cdots]_{1\times d}$;$\boldsymbol{Q}$为正态分布的随机数.

伴随者的位置信息更新计算式为

$$X_{ij}^{t+1}=\begin{cases}\boldsymbol{Q}\cdot\exp\left(\dfrac{X_{\mathrm{worst}}^{t}-X_{ij}^{t}}{i^2}\right), & i>n/2\\ X_{\mathrm{P}}^{t+1}+\left|X_{ij}^{t}-X_{\mathrm{P}}^{t+1}\right|\cdot\boldsymbol{A}^{+}\cdot\boldsymbol{P}, & \text{otherwise}\end{cases}\tag{14}$$

式中:X_{P}、X_{worst}分别表示当前全局适应度最佳、最差的麻雀;$\boldsymbol{A}$表示每个成员被随机赋值-1或1的矩阵,且$\boldsymbol{A}^{+}=\boldsymbol{A}^{\mathrm{T}}(\boldsymbol{A}\boldsymbol{A}^{\mathrm{T}})^{-1}$;当$i>n/2$时,说明第$i$个加入者适应度值较低,状态较差,需要向其它方向移动进行觅食,以获取更多能量.

侦查者的位置信息更新计算式如式(15)所示.

$$X_{ij}^{t+1}=\begin{cases}X_{\mathrm{best}}^{t}+\beta\cdot\left|X_{ij}^{t}-X_{\mathrm{best}}^{t}\right|, & f_i>f_{\mathrm{g}}\\ X_{ij}^{t}+K\cdot\left[\dfrac{\left|X_{ij}^{t}-X_{\mathrm{worst}}^{t}\right|}{(f_i-f_{\mathrm{w}})+\varepsilon}\right], & f_i=f_{\mathrm{g}}\end{cases}\tag{15}$$

式中:K为步长因子,是范围在[-1,1]的随机数;X_{best}为全局最佳位置;β表示步长控制参数,为服从N(0,1)的随机数;f_i为第i只麻雀的适应度;f_{w}为当前最差适应度;f_{g}为当前最佳适应度;当$f_i>f_{\mathrm{g}}$时,表示麻雀在群体外围,向群体内部靠拢;当$f_i=f_{\mathrm{g}}$时,意味着位于中央的麻雀感知到危险,需向种群中其他麻雀方向移动.

SSA在算法搜索后期面临无法跃出局部极值的问题[18].因此,本文提出ISSA进行精矿品位的预测建模,在探索者更新机制中引入正弦余弦思想并融合非线性学习因子,提高收敛速度;在伴随者更新机制中引进Levy飞行策略,扰动当前最佳位置,增强SSA的局部逃逸能力.改进后探索者位置更新式如下.

$$w=w_{\min}+(w_{\max}-w_{\min})\cdot\sin(t\pi/\mathrm{iter}_{\max})\tag{16}$$

$$X_{ij}^{t+1}=\begin{cases}(1-w)X_{ij}^{t}+w\cdot\sin r_1\cdot\left|r_2\cdot X_{\mathrm{best}}-X_{ij}^{t}\right|, & R_2<\mathrm{ST}\\ (1-w)X_{ij}^{t}+w\cdot\cos r_1\cdot\left|r_2\cdot X_{\mathrm{best}}-X_{ij}^{t}\right|, & R_2\geqslant\mathrm{ST}\end{cases}\tag{17}$$

式中:r_1为[0,2π]内的随机数;r_2为[0,2]内的随机数.

当探索者进化到一定代数且适应度值不变时,为防止算法在局部最优处停滞,引入Levy飞行策略对伴随者位置进行扰动,提高算法全局搜索能力.改进后伴随者的位置更新计算式如下:

$$\boldsymbol{X}_{ij}^{t+1}=\begin{cases}Q\cdot\exp\left(\dfrac{\boldsymbol{X}_{\mathrm{worst}}^{t}-\boldsymbol{X}_{ij}^{t}}{i^2}\right), & i>n/2\\ \boldsymbol{X}_{\mathrm{P}}^{t+1}+\boldsymbol{X}_{\mathrm{P}}^{t+1}\otimes\mathrm{Levy}(d), & \text{otherwise}\end{cases}\tag{18}$$

则Levy飞行策略如下:

$$\mathrm{Levy}(x)=0.01\times\frac{r_3\times\sigma}{\left|r_4\right|^{1/\xi}}\tag{19}$$

$$\sigma=\left\{\frac{(1+\xi)!\times\sin(\pi\xi/2)}{[(1+\xi)/2]!\times\xi\times2^{\frac{\xi-1}{2}}}\right\}\tag{20}$$

式中:r_3、r_4均为[0,1]内的随机数;ξ的值可取1.5.

2.3 ISSA-HKLSSVM模型构建

结合本文提出的混合核函数与ISSA特性,建立基于ISSA-HKLSSVM精矿品位预测方法的计算流程如图3所示,其主要步骤如下:

1)精矿品位预测数据集构建.对载流X荧光品位分析仪采集的各通道数据进行数据清洗,去除异常值、离群值,将清洗后数据标准化,分为训练集和测试集,完成精矿品位预测数据集构建;

2)设置ISSA参数和适应度函数.初始化麻雀算法种群参数、最大进化代数,建立适应度函数;

3)计算麻雀个体适应度,确定最优个体的位置.从适应度较好的麻雀中选取部分为探索者,引入动态学习因子加快求解速率,根据式(17)更新探索者位置.剩余麻雀作为伴随者,引入Levy飞行策略进行扰动,根据式(18)对伴随者位置进行更新.部分麻雀随机选作侦查者,根据式(16)对其位置进行更新;

4)ISSA算法优化HKLSSVM模型参数.根据适应度函数进行评估,直到达到预设的终止条件,记录此时的全局最优解赋予HKLSSVM模型参数;

5)浮选过程精矿品位预测输出.基于ISSA-

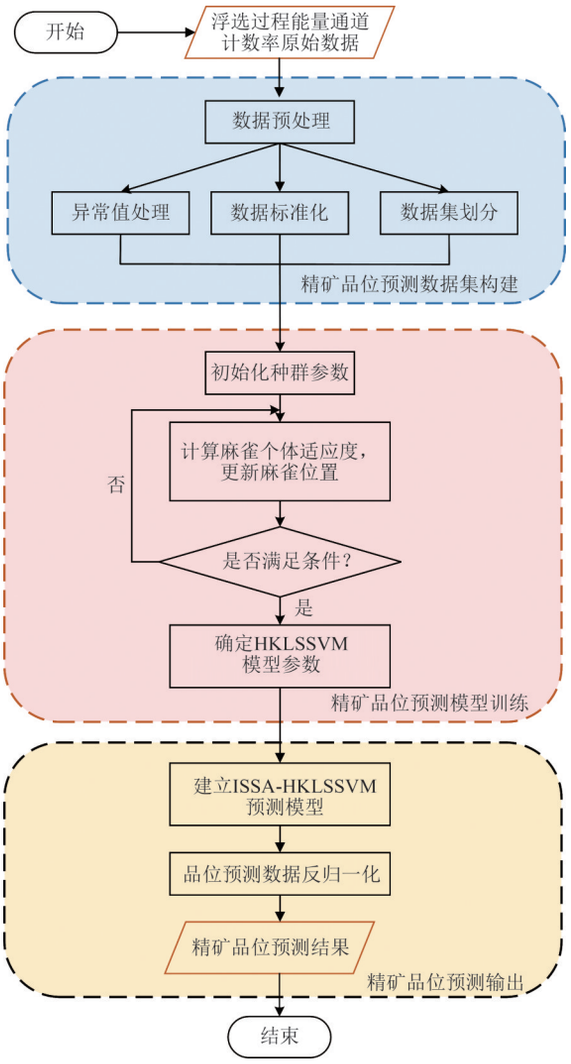


图 3 ISSA-HKLSSVM 流程图

Fig.3 ISSA-HKLSSVM Flowchart

HKLSSVM 方法建立精矿品位预测模型，实现浮选精矿品位的预测输出.

3 实验与分析

为验证本文提出的基于ISSA-HKLSSVM方法的浮选精矿品位预测模型的准确性和有效性，用该方法在国内某浮选厂锌精矿流道上实际采集数据开展工业试验，其预测结果可为浮选现场操作工人提供实时的品位变化信息.

3.1 数据分析和预处理

本文数据来源于载流X荧光品位分析仪的SQL Serve云端数据库.通过对比研究来自载流X荧光品位分析仪数据监测客户端的矿场数据，基于数据量大小和数据质量好坏进行筛选，最终以某浮选厂锌精矿浮选生产过程为研究对象，采集其浮选车间的359组数据作为样本，以ISSA-HKLSSVM预测模型为基础，确定铁、铜、锌、铅、钪5个能量通道的计数率为输入变量，锌精矿品位为输出变量，浮选精矿品位预测模型的输入、输出变量见表1，现场采集的数据见表2.

表 1 ISSA-HKLSSVM 精矿品位预测模型输入变量

Tab.1 ISSA-HKLSSVM Concentrate Grade Prediction Model Input Variables

变量	变量描述	数值范围
x_1	铁能量通道计数率	1 921.1~7 269.7
x_2	铜能量通道计数率	172.1~3 930.7
x_3	锌能量通道计数率	3 761.9~7 1735.3
x_4	铅能量通道计数率	413.2~8 938.7
x_5	钪能量通道计数率	2 004.8~9 515.4
y	锌精矿品位	40.7~56.3

表 2 ISSA-HKLSSVM 精矿品位预测模型部分数据

Tab.2 Partial data of ISSA-HKLSSVM concentrate grade prediction model

序号	各能量通道计数率					精矿品位/%
	铁	铜	锌	铅	钪	
1	2 744	811	41 127	2 996	5 014	52.56
2	3 132	903	55 348	2 702	3 763	54.49
			…			
359	3 794	2 338	68 184	5 236	3 567	52.05

由表1及表2可看出，浮选车间所采集数据可能存在超出参考值范围、噪声干扰、包含异常值等问题.为确保模型建立的准确性和稳定性，对数据进行预处理.

本文基于2σ原则对所采集浮选精矿品位的5个变量进行异常值处理，其基本过程如下.

$$\left| x_{\text{data}} - \bar{x} \right| \geqslant 2\sigma \tag{21}$$

$$\sigma = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(x_i - \bar{x})} \tag{22}$$

采用2σ原则对数据进行筛选，剔除掉与平均值相差大于2σ的异常值后，原始的357组数据最终剩余347组.为了消除指标之间的量纲影响，对数据进行归一化，其计算式如下.

$$Z^* = \frac{Z - Z_{\min}}{Z_{\max} - Z_{\min}} \tag{23}$$

式中：Z^*为数据归一化后的结果；Z为需要归一化的数据；$Z_{\max}$、$Z_{\min}$分别为所需归一化数据的最大值和最小值.

3.2 模型性能评价指标

为了评估模型的精矿品位预测效果,选用平均相对误差(Mean Relative Error, MRE)、均方误差(Mean Squared Error,MSE)、均方根误差(Root Mean Squared Error,RMSE)、决定系数(Coefficient of Determination,R^2)作为评价指标对所提方法进行评价[19],具体计算式分别为:

$$\mathrm{MRE}=\frac{1}{m}\sum_{i=1}^{m}\left|\frac{y_i-y_i^{\wedge}}{y_i}\right| \tag{24}$$

$$\mathrm{MSE}=\frac{1}{m}\sum_{i=1}^{m}\left(y_i-\hat{y_i}\right) \tag{25}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{m}\sum_{i=1}^{m}\left(y_i-\hat{y_i}\right)^2} \tag{26}$$

$$R^2=1-\frac{\sum_{i=1}^{m}(y_i-\hat{y_i})^2}{\sum_{i=1}^{m}(y_i-\bar{y})^2} \tag{27}$$

式中:y_i为精矿品位的真实值;$\hat{y_i}$为所构建模型的预测值;m为样本个数.

3.3 实验结果和分析

根据前文所描述ISSA-HKLSSVM方法构建精矿品位预测模型,开展浮选精矿品位预测研究.所采集原始数据清洗后剩余347组,其中以80%作为训练集,20%作为测试集,分别用于所构建模型的训练及测试.

为比较本文提出的基于ISSA-HKLSSVM方法建立的精矿品位预测模型的性能,将LSSVM方法用于建模讨论,其参数与ISSA-HKLSSVM预测模块中的保持一致,目的是为了对比分析引入的ISSA及新的混合核函数对精矿品位预测性能的影响.考虑到浮选工业过程中经常采用最小二乘法(Ordinary Least Squares,OLS)、PLS、BP神经网络等方法实现矿石品位建模,因此这三种方法也被用来建模比较.实验使用64位Windows处理系统,利用Matlab软件进行数据分解和模型预测的计算.详细的实验对比结果如表3所示.

由表3可见,相比于OLS、PLS方法,由BP神经网络、LSSVM及其优化方法建立的模型性能更佳,其原因是精矿品位的模型是多变量的,具有很强的非线性和不确定性,而后者所用方法有助于挖掘数据中隐含的关系,进而提高模型的性能.相比于BP神经网络,LSSVM方法更适用于精矿品位预测的小样本学习,具有更强的泛化能力.对比未经改进的

表3 浮选精矿品位预测模型实验结果比较

Tab.3 Comparison of experimental results of flotation concentrate grade prediction models

预测模型	MSE	RMSE	MRE	R^2
OLS	2.921 2	1.709 2	0.026 6	0.735 1
PLS	3.700 3	1.924 4	0.029 8	0.664 2
BP	1.960 9	1.400 3	0.019 2	0.760 2
LSSVM	1.545 9	1.243 3	0.018 3	0.810 9
HKLSSVM	1.515 1	1.230 9	0.017 8	0.844 7
SSA-HKLSSVM	1.341 4	1.158 1	0.017 3	0.861 9
ISSA-HKLSSVM	1.194 6	1.092 9	0.016 7	0.906 9

LSSVM方法,由ISSA及新的混合核函数优化的LSSVM决定系数达到了0.906 9,均方误差、均方根误差及平均相对误差分别为1.194 6、1.092 9、1.67%,表明前期的麻雀搜索算法可找到合适的品位预测模型参数,有助于提高模型的自适应性,对比单核和混核的预测结果,混核的引入使得预测模型的性能优于单核LSSVM模型.综合以上实验统计结果,本文提出的ISSA-HKLSSVM方法可高效对精矿品位进行预测,满足实际浮选现场品位预测准确度需求.

为直观展示精矿品位预测的细节信息,对比不同模型的性能,绘制了如图4所示模型预测值和实际值的曲线图.对比发现,基于ISSA-HKLSSVM方法所预测的精矿品位和实际品位值在数值与趋势上吻合较好,进一步证明了本文所提方法的准确性.

为更加清晰地展示基于不同方法的精矿品位预测结果误差分布情况,绘制模型预测值和实际化验值相对误差分布曲线如图5所示.由图5可知,基于OLS、PLS、BP三种方法预测的锌精矿品位误差值波动较大,无法保证结果的准确性.相比之下,基于改进LSSVM算法得出的结果更符合浮选现场实际精矿品位的检测准确度要求,且混合核函数和ISSA的引入,使得精矿品位预测模型能够更有效地探索特征空间,模型的精度得到显著提升.由此,本文所提出的ISSA-HKLSSVM模型能够以较高的准确率预测精矿品位.

为进一步阐述模型的准确性和稳定性,将不同模型预测的品位值和实际化验值分别作为横、纵坐标,绘制散点分布图如图6所示.由图6可知,基于OLS、PLS、BP方法预测的精矿品位值其散点图有大量的点分布在$y_1=x+1.5$的上方,预测性能较差.基于LSSVM、HKLSSVM的散点图有部分位于在$y_1=x+1.5$

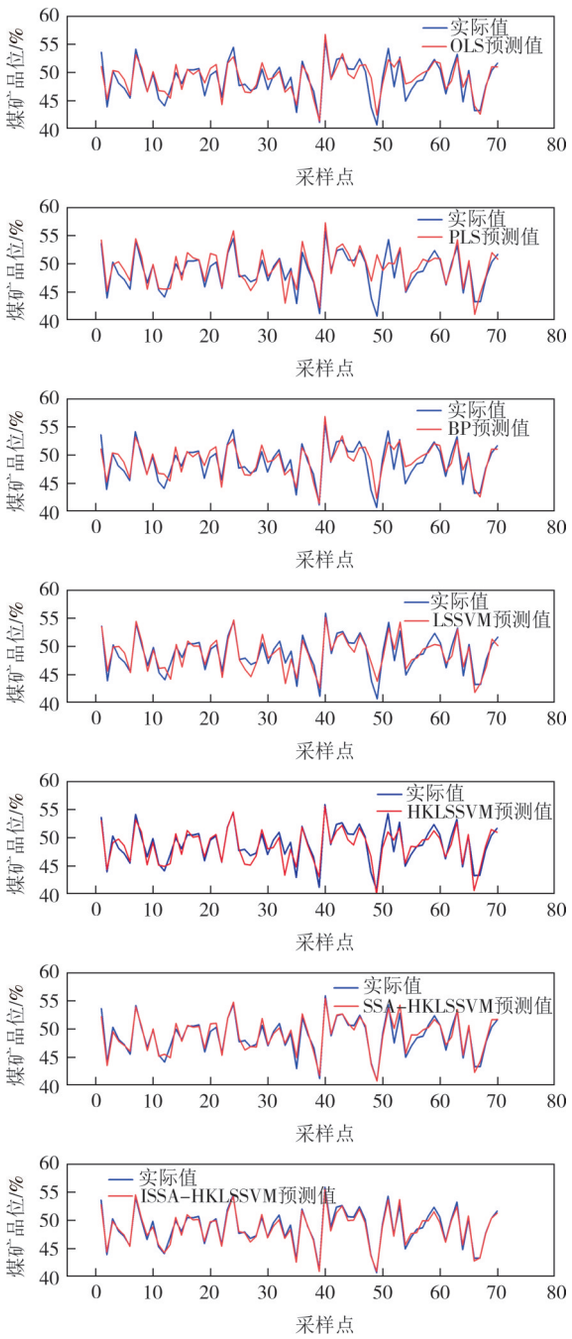


图4 不同方法精矿品位预测值和实际值曲线图

Fig.4 Curve plots of predicted and actual concentrate grades using different methods

和$y_2=x-1.5$两条临界线之外.此外,分布在两条临界线之间的散点也呈现较大的分散度.这表明,尽管这两种方法的预测结果在一定程度上满足准确度要求,其预测精度仍有提升空间.而基于本文提出的ISSA-HKLSSVM方法的散点分布在$y=x$附近,只有极少数的点分布在界线外,且分布在界限内的散点相对集中,说明本文模型获得的预测值与实际值更接近.

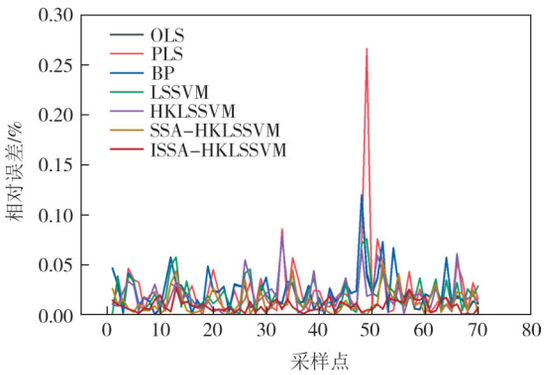


图5 不同方法的预测相对误差对比

Fig.5 Comparison of relative prediction errors between different methods

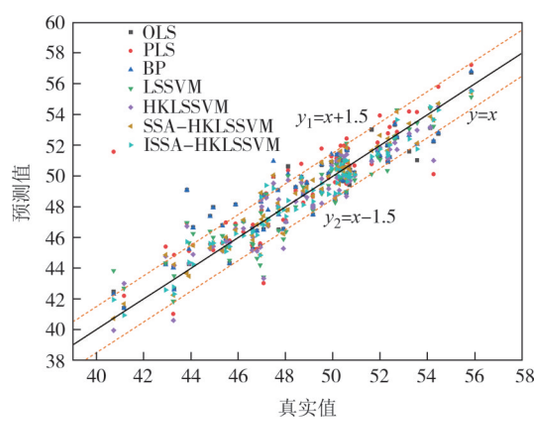


图6 不同方法预测值和实测值的散点图

Fig.6 Scatter plots of predicted and measured values using different methods

通过以上实验及其对比分析证明,本文提出的基于ISSA-HKLSSVM精矿品位建模方法准确度和泛化能力相较于其他现有方法得到了增强,可更好实现浮选过程精矿品位可靠预测和实际工程应用.

4 浮选精矿品位预测系统

基于本文提出的ISSA-HKLSSVM精矿品位预测方法,构建浮选过程精矿品位预测系统的结构框图如图7所示.系统由安装于浮选车间载流X荧光品位分析仪机身的X光管激发矿浆样品,由探测器测得能量通道计数率,上传至云端数据库,完成精矿品位预测所需自变量的存储,再通过LabVIEW的Database Connectivity工具包建立与数据库的连接,并基于本文提出方法开发浮选精矿品位预测系统.

将本文提出的精矿品位预测方法融入上位机系统,系统管理界面如图8所示,可实现对精矿品位预

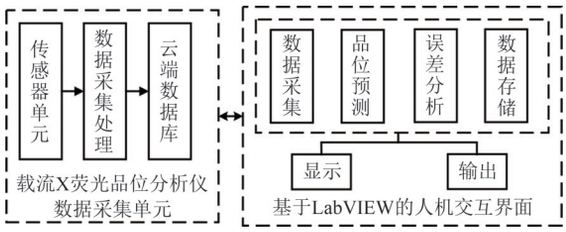


图 7　浮选过程精矿品位预测系统结构框图

Fig.7　Structure diagram of flotation process concentrate grade prediction system

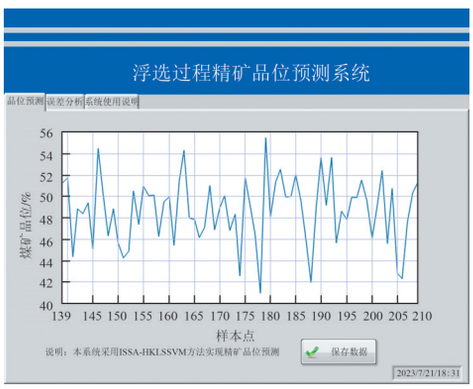


图 8　浮选过程精矿品位预测系统界面

Fig.8　Interface of flotation process concentrate grade prediction system

测、误差分析、数据存储等功能.上位机系统可从矿场的SQL数据库中获取品位仪通道数据,并基于本文提出ISSA-HKLSSVM方法实现精矿品位的预测输出.基于本系统对某选矿厂不同流道品位值进行实际预测,分析结果如表4所示.

表 4　系统实际预测分析结果

Tab.4　The actual prediction and analysis results of the system

流道	MSE	RMSE	MRE	R^2
锌精矿	1.204 6	1.097 5	0.017 9	0.885 1
铅精矿	1.560 3	1.227 3	0.019 7	0.851 7
硫精矿	1.225 1	1.106 8	0.017 7	0.861 3

由表4可见,采集锌精矿、铅精矿、硫精矿三个流道数据,在该系统中进行实例品位预测,结果显示其平均相对误差均低于2%,本文开发的浮选精矿品位预测系统准确率较高,可为实际浮选生产操作提供准确可靠检测结果和有效指导.

5　结 论

针对浮选过程变量滞后、耦合特征及建模样本数量少所导致的精矿品位难以准确预测的问题,本文提出了基于ISSA优化HKLSSVM的精矿品位预测方法.实验分析结果表明:针对浮选过程的强耦合性、滞后性问题,本文在采集载流X荧光品位分析仪数据基础上采用LSSVM方法进行建模,有效解决了精矿品位预测中的非线性、高维数及小样本问题;针对单核LSSVM对核函数类型依赖性强的弱点,本文引入混合核函数解决了单核函数的局限性,提升了LSSVM的鲁棒性;针对LSSVM性能易受惩罚系数等参数影响的问题,本文采用改进麻雀搜索算法,有效提高了模型的准确度和收敛精度,提升了全局搜索能力和收敛速度.本文提出的基于ISSA-HKLSSVM精矿品位预测方法具有良好的学习能力和泛化能力,且相比现有方法,提高了预测准确率,为浮选效率提高和过程优化控制提供了准确可靠判据.

参考文献

[1]　李海波, 柴天佑, 岳恒. 浮选过程自动控制系统[J]. 控制工程, 2013, 20(5): 796-799.
LI H B, CHAI T Y, YUE H, et al. Automatic control system for flotation process [J]. Control engineering, 2013, 20(5): 796-799. (in Chinese)

[2]　HODOUIN D. Methods for automatic control, observation, and optimization in mineral processing plants [J]. Process Control. 2011, 21(2): 211-225.

[3]　桂卫华, 阳春华, 徐德刚, 等. 基于机器视觉的矿物浮选过程监控技术研究进展[J]. 自动化学报, 2013, 39(11): 1879-1888.
GUI W H, YANG C H, XU D G, et al. Research progress in mineral flotation process monitoring technology based on machine vision [J]. Journal of Automation, 2013, 39(11): 1879-1888. (in Chinese)

[4]　刘长鑫, 丁进良, 姜波, 等. 选矿过程精矿品位自适应在线支持向量预测方法[J]. 控制理论与应用, 2014, 31(3): 386-391.
LIU C X, DING J L, JIANG B, et al. Adaptive online support vector regression prediction model for concentrate grade of the ore-dressing processes [J]. Control Theory & Applications, 2014, 31(3):386-391. (in Chinese)

[5]　曹斌芳, 谢永芳, 阳春华, 等. 基于多源数据的铝土矿浮选生产指标集成建模方法[J]. 控制理论与应用, 2014, 31(9): 1252-1261.
CAO B F, XIE Y F, YANG C H, et al. Integrated modeling for production index of bauxite flotation based on multi-source data [J]. Control Theory & Applications, 2014, 31(9): 1252-1261. (in Chinese)

[6]　KAARTINCAL J, HATONEN J, HYOTYNIEMI H, et al. Machine-vision-based control of zinc flotation: a case study [J]. Control Engineering Practice, 2006, 14(12): 1455-1466.

[7] SHEAN B J, CILLIERS J J. A review of froth flotation control[J]. International Journal of Mineral Processing, 2011, 100(3): 57-71.

[8] COOK R, MONYAKE K C, HAYAT M B, et al. Prediction of flotation efficiency of metal sulfides using an original hybrid machine learning model [J]. Engineering Reports, 2020, 2(6): 12167.

[9] SHAHBAZI B, CHELGANI S C, MATIN S S. Prediction of froth flotation responses based on various conditioning parameters by random forest method [J]. Colloids and Surfaces A: Physicochemical and Engineering Aspects, 2017, 529: 936-941.

[10] ALLAHKARAMI E, NURI O S, ABDOLLAHZADEH A, et al. Estimation of copper and molybdenum grades and recoveries in the industrial flotation plant using the artificial neural network [J]. International Journal of Nonferrous Metallurgy, 2016, 5(3): 23-32.

[11] WANG Z J, ZHAO Z, DONG L, et al. Data-driven soft sensor modeling for algal blooms monitoring [J]. IEEE Sensors, 2015, 15(11): 4681-4690.

[12] LIU C, HUANG Y H. Short term photovoltaic power prediction based on BP neural network optimized by improved sparrow search algorithm [C]// 2022 4th International Academic Exchange Conference on Science and Technology Innovation (IAECST), Guangzhou: IEEE, 2022:314-317.

[13] HAAVISTO O, KAARTINEN J, HYOTYNIEMI H. Optical spectrum based estimation of grades in mineral flotation [C]// 2006 IEEE International Conference on Industrial Technology, Mumbai: IEEE, 2006:2529-2534.

[14] 刘畅, 郎劲. 基于混核LSSVM的批特征风功率预测方法[J]. 自动化学报, 2020, 46(6): 1264-1273.
LIU C, LANG J. Wind power prediction method using hybrid kernel LSSVM with batch feature [J]. Acta Automatica Sinica, 2020, 46(06): 1264-1273. (in Chinese)

[15] 江岳春, 杨旭琼, 贺飞, 等. 基于EEMD-IGSA-LSSVM的超短期风电功率预测[J]. 湖南大学学报(自然科学版), 2016, 43(10): 70-78.
JIANG Y C, YANG X Q, HE F, et al. Super-short-time wind power forecasting based on EEMD-IGSA-LSSVM [J]. Journal of Hunan University(Natural Sciences), 2016, 43(10): 70-78. (in Chinese).

[16] 王维高, 魏云冰, 滕旭东. 基于VMD-SSA-LSSVM的短期风电预测[J]. 太阳能学报, 2023, 44(3): 204-211.
WANG W G, WEI Y B, TENG X D. Short-term wind power forecasting based on VMD-SSA-LSSVM [J]. Acta Energiae Solaris Sinica, 2023, 44(3): 204-211. (in Chinese)

[17] GAO B W, SHEN W, HAO G, et al. Research on multistrategy improved evolutionary sparrow search algorithm and its application [J]. IEEE Access, 2022, 10:62520-62534.

[18] 毛清华, 张强, 毛承成, 等. 混合正弦余弦算法和Levy飞行的麻雀算法[J]. 山西大学学报(自然科学版), 2021, 44(6): 1086-1091.
MAO Q H, ZHANG Q, MAO C C, et al. Mixing sine and cosine algorithm with Levy flying chaotic sparrow algorithm [J]. Journal of Shanxi University(Natural Science Edition), 2021, 44(6): 1086-1091. (in Chinese)

[19] 蒋珂, 蒋朝辉, 谢永芳, 等. 基于动态注意力深度迁移网络的高炉铁水硅含量在线预测方法[J]. 自动化学报, 2023, 49(5): 949-963.
JIANG K, JIANG Z H, XIE Y F, et al. Online prediction method for silicon content of molten iron in blast furnace based on dynamic attention deep transfer network [J]. Acta Automatica Sinica, 2023, 49(5): 949-963. (in Chinese)