

面向数据隐私的多工况场景软测量模型复用

范龙飞¹, 史旭东¹, 熊伟丽^{1†}, 黄望芽²

(1. 江南大学 物联网工程学院, 江苏 无锡 214122; 2. 宝山钢铁股份有限公司, 上海 201900)

摘要: 多工况工业过程中工况改变导致的原预测模型失准, 且旧工况历史数据往往不可访问, 仅凭少量新工况数据难以直接建立准确的软测量模型. 为此, 提出一种基于宽度学习系统的缩约核均值嵌入软测量模型复用算法, 其包含训练阶段和应用阶段. 在训练阶段, 针对历史工况, 建立基于宽度学习系统的软测量模型; 设计基于核均值嵌入的缩约集, 将历史工况数据映射到再生核希伯特空间中, 保护历史工况数据隐私的同时获取其分布特征; 利用模型及其对应缩约集构建模型库. 在应用阶段, 构建基于最大均值差异的距离度量准则, 匹配模型库中最优模型实现模型复用, 并动态更新模型参数以适应新工况. 基于硫回收过程和炼钢过程两个工业实例, 验证所提出方法的有效性和优越性.

关键词: 软测量; 多工况; 小样本; 数据隐私; 模型复用; 宽度学习系统

中图分类号: TP273 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.1344

引用格式: 范龙飞, 史旭东, 熊伟丽, 等. 面向数据隐私的多工况场景软测量模型复用 [J]. 控制与决策.

Reuse of soft sensor model based on data privacy in multi condition scenarios

FAN Long-fei¹, SHI Xu-dong¹, XIONG Wei-li^{1†}, HUANG Wang-ya²

(1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China; 2. Baoshan Iron & Steel Co., Ltd., Shanghai 201900, China)

Abstract: In complex industrial processes, significant shifts in operating conditions lead to data distribution variations that challenge the accuracy of a single steady-state prediction model. Moreover, as historical data from previous conditions are often inaccessible, it is difficult to build a reliable new model with only limited data from the new condition. To address these issues, a soft sensor model reuse method based on reduced kernel mean embedding and broad learning system is proposed. The method operates in two stages: training and application. In the training stage, a broad learning system is used to develop a soft sensor model for historical operating conditions. A reduced set based on kernel mean embedding is designed to map historical data into a reproducing kernel Hilbert space. This preserves data privacy while capturing distribution characteristics. The model and its corresponding reduced set together form a model library. In the application stage, a distance metric based on maximum mean discrepancy is constructed to identify the most suitable model from the library. A distance threshold is then designed to dynamically update the model parameters for new operating conditions. The effectiveness and superiority of the proposed method are validated through two industrial case studies: a sulfur recovery process and a steelmaking process.

Keywords: soft sensor; multiple operating condition; scarce sample; data privacy; model reuse; broad learning system

0 引言

现代工业生产对产品质量的要求不断提高, 而与生产直接相关的质量变量通常难以直接测量^[1-3]. 软测量技术利用易获取的辅助变量建立数学模型,

实现对质量变量的有效估计^[4]. 当前, 数据驱动的软测量建模方法能够利用工业生产积累的大量数据快速建立预测模型, 已成为主流的质量变量预测方法^[5-6]. 然而, 随着市场对产品的需求愈发多样化, 工

收稿日期: 2025-12-26; 录用日期: 2026-02-08.

基金项目: 国家自然科学基金项目 (62503200); 江苏省自然科学基金项目 (BK20251611); 中央高校基本科研项目 (JUSRP202501006).

责任编辑: 褚菲.

†通信作者. E-mail: weili_xiong@jiangnan.edu.cn.

业生产过程的操作条件频繁切换以满足需求,导致其具有多工况特性^[7-8].通常,多工况过程由多个单稳态工况组成,且在不同单稳态工况间进行切换运行,使得关键质量变量的检测模型面临跨工况泛化能力不足的挑战^[9-10].此外,很多工况因生产条件严苛或安全限制,仅能获取少量数据样本,进一步制约了数据驱动模型的有效实施与可靠性^[11-12].

现有多工况小样本建模的研究聚焦于迁移学习、领域自适应等策略,通过挖掘跨工况共享特征或引入正则化约束来提升模型适应性.文献[13]提出了测地线流式核算法,利用主成分分析将数据投影至流形空间,并通过构造测地线流实现分布对齐,是一种有效的特征迁移方法.然而,主成分分析本质上是一种线性降维方法,难以捕捉数据中复杂的非线性特征,这限制了该算法在非线形场景下的性能.文献[14]提出了域适应极限学习机(DAELM)模型,该模型同时使用源域和目标域数据进行建模,但是源域与目标域数据直接混合训练,若分布差异较大,源域数据会干扰目标域学习,容易出现负迁移的问题.文献[15]提出了基于极限学习机参数迁移的域适应(DAPT)算法,其核心思想是将目标域极限学习机输出的参数迁移到源域中,使两个域享有共同的参数空间,通过参数迁移去实现两个域的分布自适应.这些方法本质上都是利用历史相似工况的数据来辅助新工况进行建模.然而,在实际多工况工业场景下,历史数据是需要保护的资源,具有不可访问性,给上述方法的实施带来了困难^[16];而训练完成的模型的参数是可以公开和共享的.因此,多工况场景下,可以复用已有工况的预训练模型帮助建立新工况模型,类似方法在已有文献中被称为从辅助分类器中学习^[17]或假设迁移学习^[18].

目前模型复用方法大致分为两类,一是在当前工况上更新预训练模型,如微调神经网络^[19];另一类是在已有模型的帮助下重新训练当前工况模型,如知识蒸馏^[20].这两类方法都假设已知工况模型是对当前工况建模是有帮助的,没有考虑模型是否可复用,更重要的是,这些方法通常需要直接访问历史模型的原始训练数据或中间层特征,这在数据隐私要求严格的工业场景中往往无法满足.如何在保护历史工况训练数据不公开的前提下评估已有模型对当前工况的可用性,以及如何复用至关重要.文献[21]提出了基于简约核均值嵌入的模型复用方法,实现了在不泄露原始数据的同时刻画了模型的复用场景.具体来说,其将原始数据分布映射到再生核希尔伯特空间(RKHS)中的一个点,在保持分布表示能力的同时保护了原始数据的隐私.但复杂工业过程下

出现新的操作条件,导致工况分布不能由历史工况分布的凸组合表示,限制了其在软测量建模领域的应用.此外,新工况标签数据稀缺,难以匹配训练工况的RKME,使得软测量模型的高效复用面临挑战.

针对上述问题,本文提出了基于宽度学习系统的简约核均值嵌入软测量模型复用算法,在不暴露历史工况数据隐私的前提下,实现了小样本场景下的跨工况软测量建模.所提复用建模方法分为训练阶段和应用阶段.在训练阶段,通过核均值嵌入(KME)将训练数据的分布映射到RKHS空间,获得分布表示,并在保持KME分布能力的同时构建简约集,以保护原始数据隐私.利用宽度学习系统(BLS)训练效率高的优势训练各历史预测模型^[22],将模型与其对应的简约集一并上传到模型库中.在应用阶段,度量RKHS中新工况KME与模型库中历史工况RKME的距离,找到最匹配模型.构建距离阈值参数,当分布间距小于距离阈值时,直接复用历史工况模型,反之,引入带增量的BLS在新工况上动态更新模型参数,提升预测性能.通过硫回收过程和炼钢过程两个工业实例仿真对所提方法的有效性进行了验证和分析.

1 预备知识

1.1 BLS

BLS是一种单隐层前馈神经网络,其隐藏层由特征节点和增强节点组成,通过岭回归求解伪逆得到相应的输出权重,避免了复杂的训练过程,模型训练效率高.BLS的模型结构如图1所示.

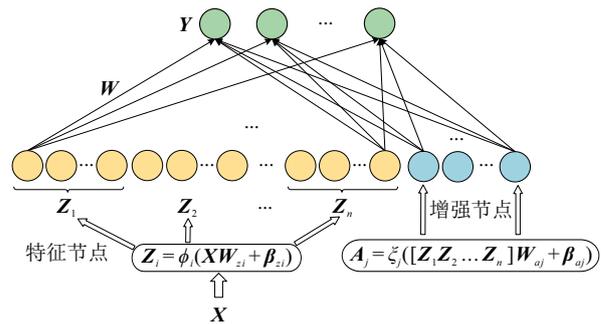


图1 BLS 结构图

给定输入数据 X , BLS 首先将其映射成 n 个特征节点,第 i 个特征节点 Z_i 的计算公式为:

$$Z_i = \phi(XW_{z_i} + \beta_{z_i}) \quad i = 1, 2, \dots, n \quad (1)$$

其中, ϕ 为非线性激活函数, W_{z_i} 和 β_{z_i} 分别为随机生成的权重和偏置.

将 n 个特征拼接为特征节点矩阵 $Z = [Z_1, Z_2, \dots, Z_n]$, Z 经过一个非线性变换得到 m 个增强节点,第 j 个增强节点 A_j 为:

$$\mathbf{A}_j = \xi(\mathbf{Z}\mathbf{W}_{aj} + \beta_{aj}) \quad j = 1, 2, \dots, m. \quad (2)$$

其中, ξ 为非线性激活函数, \mathbf{W}_{aj} 和 β_{aj} 分别为随机生成的权重和偏置.

将 m 个增强特征拼接为增强节点矩阵 $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_m]$, BLS 隐藏层特征为 $\mathbf{H} = [\mathbf{Z}|\mathbf{A}]$, 模型输出为 $\hat{\mathbf{Y}} = \mathbf{H}\mathbf{W}$, 其中 \mathbf{W} 为隐藏层到输出层的权重.

由于 \mathbf{W}_{zi} 、 β_{zi} 、 \mathbf{W}_{ai} 、 β_{ai} 都是随机生成且保持不变的, 模型需要学习更新的参数只有权重 \mathbf{W} , 则 BLS 的优化目标为:

$$\min_{\mathbf{W}} (\|\mathbf{Y} - \mathbf{H}\mathbf{W}\|_2^2 + \lambda \|\mathbf{W}\|_2^2). \quad (3)$$

其中, \mathbf{Y} 表示输出数据, $\|\cdot\|_2$ 为 L2 范数, λ 为正则化系数. 求解公式(3)可得:

$$\mathbf{W} = (\mathbf{H}^T\mathbf{H} + \lambda\mathbf{I})^{-1}\mathbf{H}^T\mathbf{Y}. \quad (4)$$

其中, \mathbf{H}^T 为 \mathbf{H} 的转置矩阵, \mathbf{I} 为单位矩阵.

1.2 BLS 的增量学习

BLS 可以在不重新训练模型的情况下以三种增

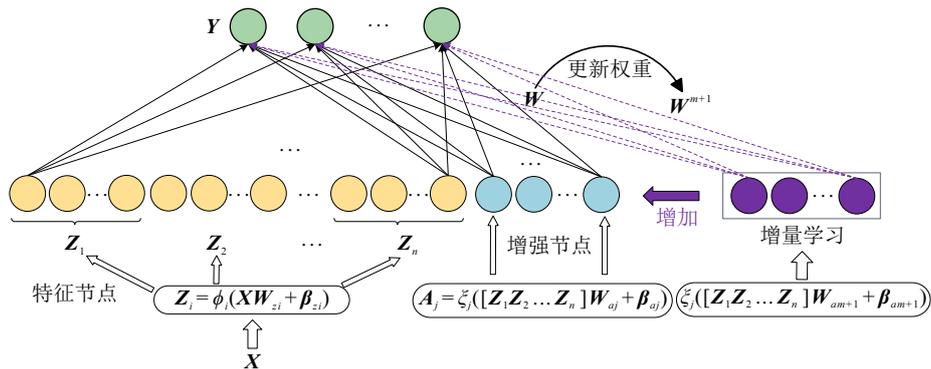


图2 带增量的 BLS 结构图

1.3 核均值嵌入

KME 利用核方法将概率分布映射为 RKHS 中的一个点. 给定一个核函数 $k: \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$, 分布 P 的核均值嵌入的定义为:

$$\mu(P) := \int_{\mathcal{X}} k(x, \cdot) dP(x). \quad (8)$$

其中, \mathcal{X} 表示分布 P 的定义域.

文献 [24] 证明了在使用核函数情况下分布 P 在映射到点 $\mu(P)$ 后没有任何信息损失, 这种特性使得 KME 成为有理论依据的分布刻画技术, 为后续利用缩约集近似该点, 并在此空间内度量分布差异提供了根本的理论可行性.

在实际工业过程中真实分布 P 难以获取, 通常用样本 $\{x_i\}_{i=1}^n \sim P$ 来构建经验 KME $\hat{\mu}(P)$ 近似表示真实分布 P 所对应的 KME:

量学习的方式更新模型, 分别是增强节点、特征节点和输入节点的增量学习^[23].

本文以增强节点的增量学习为例. 如图 2 所示, 该增量学习通过增加 l 个增强节点对 BLS 进行扩展, 扩展后隐藏层可表示为:

$$\mathbf{H}^{m+1} = [\mathbf{H}^m | \xi(\mathbf{Z}\mathbf{W}_{am+1} + \beta_{am+1})]. \quad (5)$$

其中, \mathbf{H}^m 为 BLS 隐藏层, \mathbf{W}_{am+1} 和 β_{am+1} 为随机权重和偏置, \mathbf{H}^{m+1} 的伪逆通过下式更新:

$$(\mathbf{H}^{m+1})^\dagger = \begin{bmatrix} (\mathbf{H}^m)^\dagger - \mathbf{D}\mathbf{B}^T \\ \mathbf{B}^T \end{bmatrix}. \quad (6)$$

其中, $\mathbf{D} = [\mathbf{H}^m | \xi(\mathbf{Z}\mathbf{W}_{am+1} + \beta_{am+1})]$,

$$\mathbf{B}^T = \begin{cases} (\mathbf{E})^\dagger, & \text{if } \mathbf{E} \neq 0, \\ (1 + \mathbf{D}^T\mathbf{D})^{-1}\mathbf{B}^T(\mathbf{H}^m)^\dagger, & \text{if } \mathbf{E} = 0, \end{cases}$$

其中, $\mathbf{E} = \xi(\mathbf{Z}\mathbf{W}_{am+1} + \beta_{am+1}) - \mathbf{H}^m\mathbf{D}$.

新权重由下式递增更新:

$$\mathbf{W}^{m+1} = \begin{bmatrix} \mathbf{W}^m - \mathbf{D}\mathbf{B}^T\mathbf{Y} \\ \mathbf{B}^T\mathbf{Y} \end{bmatrix}. \quad (7)$$

其中, \mathbf{W}^m 为初始 BLS 最优权重.

$$\hat{\mu}(P) = \frac{1}{n} \sum_{i=1}^n k(x_i, \cdot). \quad (9)$$

文献 [25] 证明了, 在 RKHS 范数的度量下, 经验 KME $\hat{\mu}(P)$ 以 $O(1/\sqrt{n})$ 的速率收敛至真实分布 KME $\mu(P)$.

2 基于 BLS 的缩约核均值嵌入软测量模型复用

2.1 问题描述

假设训练阶段有 a 种不同的工况, 每个工况训练好自身的软测量模型并与对应的缩约集一并上传到模型库中以供后续使用. 每个工况的本地数据集 $D_i = \{(x_j, y_j)\}_{j=1}^{N_i}$ 都是不公开的, 工况 C_i 由 (P_i, f_i) 对定义, 其中, P_i 是样本集 D_i 的分布, f_i 是软测量模型.

$$\forall i \in [a], \forall (x, y) \in D_i, f(x) = y. \quad (10)$$

所有训练工况都有足够能力,在本地数据集上训练出高精度的软测量模型. \hat{f}_i 在给定损失函数 L 下,在各自工况分布 P_i 上,具有较小的误差 $\varepsilon > 0$,即

$$\forall i \in [a], \mathcal{J}(P_i, f_i, \hat{f}_i) = \mathbb{E}_{x \sim P_i} [L(\hat{f}_i(x), f_i(x))] \leq \varepsilon. \quad (11)$$

在应用阶段,一个新工况 C_t 想要建立软测量模型,但只有少量标签数据服从分布 P_t ,难以直接建立预测模型.因此,需要利用预训练模型 $\{\hat{f}_i\}_{i=1}^a$ 来辅助训练一个能最小化损失 $\mathcal{J}(P_t, f_t, \hat{f}_t)$ 的模型 \hat{f}_t .

一个简单的想法是:既然所有历史工况都有准确的预测模型 \hat{f}_i ,是否可随意选取一个用于预测?这显然是不合理的,因为没有任何 P_t 和 P_i 之间关系的描述,无法判断所选模型是否有助于当前工况来训练模型.因此本文提出了基于宽度学习系统的集约核均值嵌入(RKME-BLS)软测量模型复用算法,借助历史工况的预训练模型,在无法访问历史工况数据的前提下,利用预训练模型辅助当前工况少量标签数据训练出一个适用于新工况的预测模型 \hat{f}_t .

2.2 训练阶段

以某一历史工况为例,给定建模数据 $D = \{(x_i, y_i)\}_{i=1}^N$,其中 $x_i \sim P_i$,用高斯核函数 k 将样本 $\{x_i\}_{i=1}^N$ 定义的经验分布映射为经验KME,其定义如公式(9)所示.但KME包含全部历史工况训练数据,不满足数据隐私保护的要求.因此,我们运用RKME技术构造更少数量的样本来近似经验KME.具体而言,RKME在原始特征空间中构造一个带权重的集约集 $\{(\alpha_j, u_j)\}_{j=1}^M$ 来近似表示经验KME,通过最小化集约集与原始数据集的最大均值差异得到集约集的最优解.

$$\min_{\alpha, U} \left\| \frac{1}{N} \sum_{i=1}^N k(x_i, \cdot) - \sum_{j=1}^M \alpha_j k(u_j, \cdot) \right\|_{\mathcal{H}_k}^2. \quad (12)$$

其中, u_j 为集约点集, α_j 为 u_j 对应权重, \mathcal{H}_k 为核函数对应的RKHS空间,将公式(12)展开可得:

$$F(\alpha, U) = \sum_{i,j=1}^N \frac{1}{N^2} k(x_i, x_j) + \sum_{i,j=1}^M \alpha_i \alpha_j k(u_i, u_j) - 2 \sum_{i=1}^N \sum_{j=1}^M \frac{\alpha_j}{N} k(x_i, u_j). \quad (13)$$

通过交替优化的方法来最小化公式(13),首先固定 U ,求解 α ,公式(13)可写为:

$$F(\alpha, U) = \alpha^T K \alpha - 2\alpha^T V + C. \quad (14)$$

其中,

$$\alpha^T K \alpha = \sum_{i,j=1}^M \alpha_i \alpha_j k(u_i, u_j),$$

$$\alpha^T V = \sum_{i=1}^N \sum_{j=1}^M \frac{\alpha_j}{N} k(x_i, u_j),$$

$$C = \sum_{i,j=1}^N \frac{1}{N^2} k(x_i, x_j)$$

为常数项.

令 $\frac{\partial F(\alpha, U)}{\partial \alpha} = 0$ 可得 α 的闭式解:

$$\alpha = K^{-1} V. \quad (15)$$

其中, $K_{ij} = k(u_i, u_j)$, $V_i = \frac{1}{N} \sum_{j=1}^M k(u_i, u_j)$, $K \in \mathbb{R}^{N \times M}$, $V \in \mathbb{R}^{N \times 1}$.

接着固定 α ,求解 U ,当 α 固定后,对于 $U = \{u_j\}_{j=1}^M$ 中的每个元素均可以通过梯度下降来求解:

$$z_j^t = z_j^{t-1} - \eta \frac{\partial F(\alpha, U)}{\partial z_j}. \quad (16)$$

其中, η 为步长,当步长足够小时, $F(\alpha, U)$ 单调递减,最终收敛,得到集约集 $\varphi = \{\alpha, U\}$.

训练阶段的结构流程如图3所示,求解完成后,每个历史工况上传BLS预训练模型 \hat{f}_i 以及对应的集约集 φ_i 到模型库中.训练阶段的建模流程如算法1所示.

算法1 RKME-BLS训练阶段算法

输入: 历史工况数据 $D = \{(x_i, y_i)\}_{i=1}^N$,核函数 k ,集约集大小 M ,迭代次数 T .

输出: 集约集 $\varphi = \{\alpha, U\}$,预训练模型 \hat{f}_i

流程:

- 1: 随机初始化权重 W_z 、 W_a ,偏置 β_z 、 β_a , $U = \{u_j\}_{j=1}^M$
- 2: 构建隐藏层输出 H
- 3: **for** $t = 1: T$ **do**
- 4: 根据公式(4)更新 W
- 5: 根据公式(15)更新 α
- 6: 根据公式(16)更新对应的 u_j^t
- 7: **end for**

2.3 应用阶段

在应用阶段,需要从模型库中选择适合当前工况的最佳模型,具体而言,在RKHS中度量当前工况KME与模型库中历史工况RKME的距离 d ,即算法2中采用最大均值差异的平方距离进行计算,找到最匹配的工况,利用其模型 \hat{f}_i 预测新工况.为提升模型预测性能,设置了一个距离阈值 h ,其设定基于所有历史工况对间最大均值差异距离的下四分位数

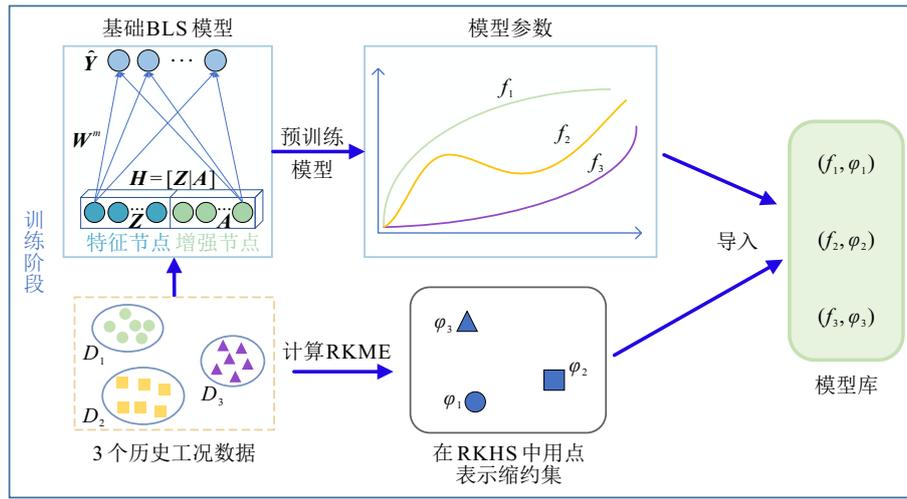


图3 训练阶段结构图

调整. 当 $d \leq h$ 时, 表明新工况的分布落在历史分布范围内, 可直接复用模型; 反之, 则表明出现了显著的新分布特征, 需利用 BLS 增量学习的特性对选中的模型参数进行更新, 提升其预测性能.

应用阶段的结构图如图 4 所示, 为保护历史工况数据隐私, 本文仅利用其训练好的模型参数不涉

及输入数据. 利用测试工况带标签的输入数据 \mathbf{X}_t 构建增量学习所需的额外增强节点, 对公式 (5) 做如下修改:

$$\mathbf{H}^{m+1} = [\mathbf{H}^m | \xi(\mathbf{Z}^* \mathbf{W}_{am+1} + \beta_{am+1})]. \quad (17)$$

其中, $\mathbf{Z}^* = [\mathbf{Z}_1^*, \mathbf{Z}_2^*, \dots, \mathbf{Z}_n^*]$, $\mathbf{Z}_i^* = \phi(\mathbf{X}_t \mathbf{W}_{zi} + \beta_{zi})$, $i = 1, 2, \dots, n$.

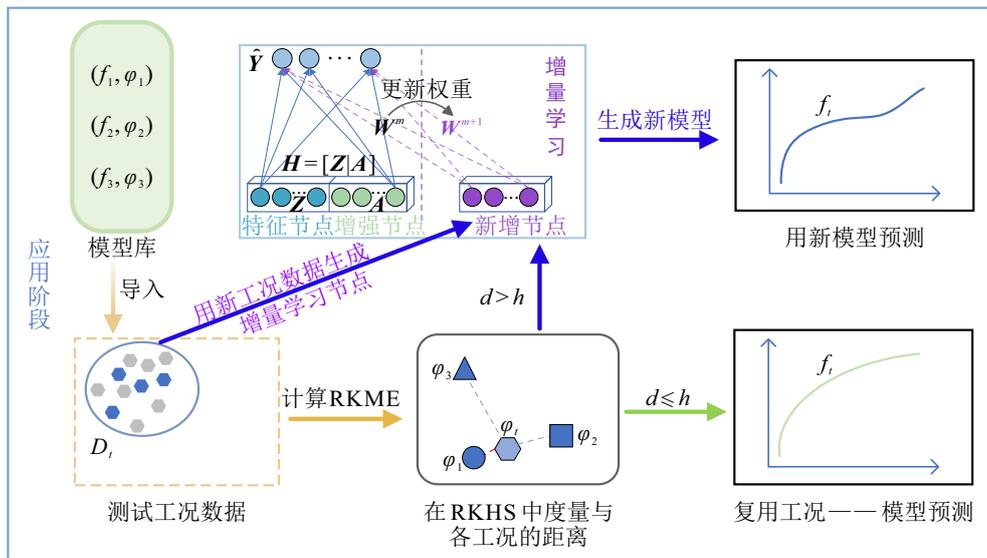


图4 应用阶段结构图

后续权重由公式 (7) 递增更新, 应用阶段的建模流程如算法 2 所示.

算法2 RKME-BLS应用阶段算法

输入: 测试工况少量带标签数据 $(\mathbf{X}_t, \mathbf{y}_t)$ 及其待测数据 \mathbf{X}_{te} , 距离阈值 h , 历史工况预训练模型 $\{\hat{f}_i\}_{i=1}^a$ 及其对应约简集 $\{\varphi_i\}_{i=1}^a$.

输出: 测试工况预测值 y_{te}

流程:

1: 将测试集数据映射到RKHS中 $\varphi_t = \frac{1}{N} \sum_{i=1}^N k(x_i, \cdot)$

2: 在RKHS中计算新旧工况的距离 $d = \min_i \|\varphi_t - \varphi_i\|_{\mathcal{H}_k}^2$, 找出距离最近历史工况

3: **if** $d \leq h$ **then**

4: $y_{te} = \hat{f}_i(D_{te})$

5: **end if**

6: **if** $d > h$ **then**

7: 在原模型上新增 l 个用标签数据生成的增强节点

8: 根据公式(7)更新权重 \mathbf{W}^{m+1}

9: 计算预测值 $y_{te} = \mathbf{H}^{m+1} \mathbf{W}^{m+1}$

10: **end if**

3 仿真实验

通过硫回收过程及炼钢过程两个工业实例, 来验证所提模型在多工况建模中的准确性. 在本文实验中模型预测性能评价指标为均方根误差 (RMSE)、平均绝对误差 (MAE) 以及相关指数 (R^2), 它们的计算公式为:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_{i(p)})^2}, \quad (18)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y_{i(p)}|, \quad (19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_{i(p)})^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}. \quad (20)$$

其中, n 为样本数, y_i 为实际值、 $y_{i(p)}$ 为模型预测值、 \bar{y}_i 为实际值均值.

为体现所提 RKME-BLS 算法的优势所在, 将其与基础 BLS 算法、模型复用基线算法以及迁移学习

算法进行对比:

- (1) BLS: 基于测试工况少量数据训练的宽度学习模型.
- (2) RAND: 随机选取一个预训练模型.
- (3) AVG: 将所有模型的输出平均后作为输出.
- (4) DAELM: 域适应极限学习机模型.
- (5) DAPT: 基于极限学习机参数迁移的域适应算法模型.

3.1 硫回收过程

硫回收工艺是炼油生产行业环保处理的核心流程^[26]. 在实际生产中会产生 MEA 和 SWS 两类酸性气体, 若未经处理直接排放将对空气质量造成严重破坏. 其中, MEA 富含硫化氢 (H_2S), SWS 为 H_2S 和氨气 (NH_3) 的混合物. 如图 5 所示, 硫回收装置 (SRU) 首先将两者通入加热器进行预热, 再引入焚烧炉中进行高温焚烧, 将酸性气体转化为 H_2S 和 SO_2 混合气体. 该混合气体经催化反应器转化后进入冷凝系统, 最终形成纯硫和水的混合物, 反应后的尾气还需经过分液罐进行多层分离, 以实现硫元素的彻底回收.

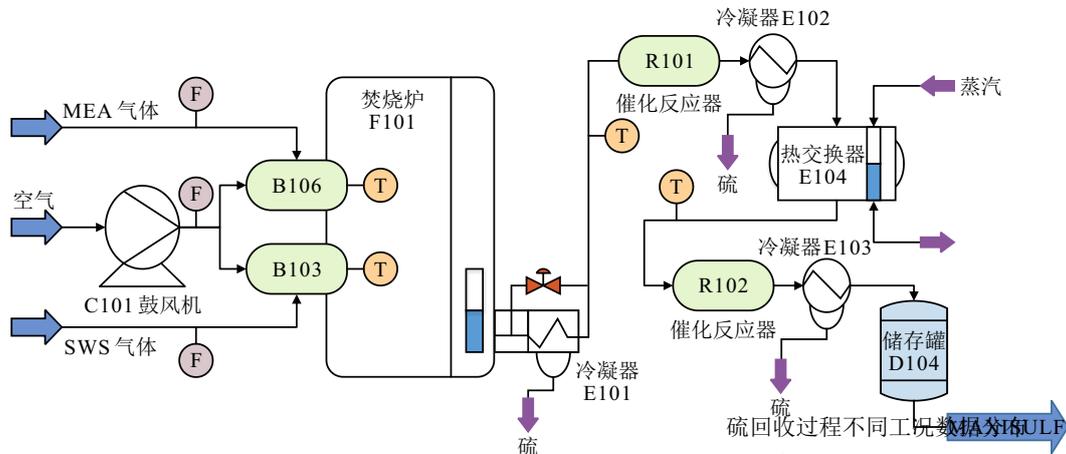


图5 硫回收装置示意图

为建立软测量模型, 本实验选取 H_2S 作为预测的质量变量, 选取 5 个相关变量作为输入的辅助变量, 分别为 MEA_GAS 气流、MEA_AIR 气流、MEA_AIR 二次气流、SWS_GAS 气流、SWS_AIR 气流. 通过设置不同的 MEA_GAS 气流输入值, 模拟不同工况的数据^[27], 本实验共设置了 6 种不同的工况, 每个工况 800 组数据. 如图 6 所示, 为探究多工况数据的非线性结构特征, 采用 t-SNE 方法实现高维数据的低维可视化, 直观呈现各工况间的分布差异.

在训练阶段, 每个工况训练好一个 BLS 预测模型, 再利用 RKME 构造每个工况对应的缩约集 ($M = 40$, 高斯核为 0.5), 缩约集大小为原数据集的

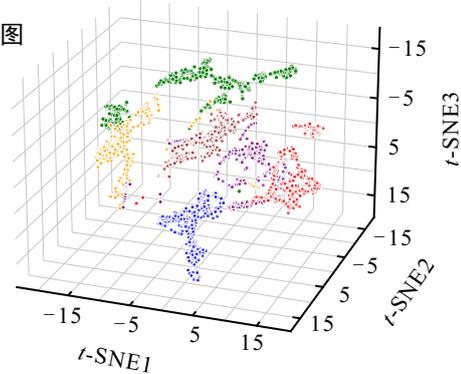


图6 硫回收过程不同工况三维数据分布图

5%, 在保证分布信息的同时保护其隐私, 高斯核的选取对本实验并无明显影响, 为方便对比, 本文所涉

及高斯核的方法其值均设为 0.5, 将模型和缩约集一起导入到模型库中.

在应用阶段, 考虑到每个工况均可作为待测工况, 因此本文做 6 次实验. 同时, 在小样本条件的限制下, 待测工况仅拥有 10 组带标签的数据. 如图 7 所示, 从 0.3(历史工况对间距离的下四分位数) 开始, 减小阈值设定来对比预测性能, 从图中可知, 当阈值小于 0.12 时, 两种方法预测性能没有明显差异, 因此本实验设定距离阈值 $h = 0.12$, 当 $d < h$ 时, 将两种工况视为相近工况, 直接复用原模型进行预测, 否则构建 BLS 的增量学习来更新模型.

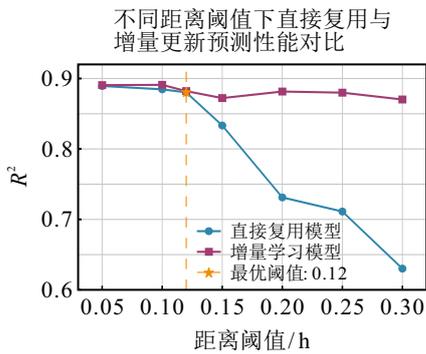


图7 不同阈值下 H₂S 浓度预测性能对比图

为了更充分的分析和对比, 本小节对 BLS、RAND、AVG、DAELM、DAPT 以及本文所提的 RKME-BLS 的预测结果和预测误差进行了可视化(以工况 1 为待测工况为例), 如图 8-9 所示. 同时表 1 给出了各模型对 H₂S 浓度预测的评价指标. 总体来看, BLS 仅使用少量待测工况数据进行建模, 预测曲线明显偏离真实值. 模型复用的基线算法 RAND 和 AVG, 在预测新工况时, 并未对历史工况模型参数进行更新, 只有在工况非常相近的情况下, 预测曲线才

能跟踪真实值. 从图 9 中可以明显看出, 这三种模型有着较大的误差. 另外, 从图 8 和图 9 中可以看出, 迁移学习算法 DAELM 和 DAPT 的预测曲线可以很好的跟踪真实值且预测误差较低. 但需要注意的是, 迁移学习算法在建模时需同时访问历史工况数据及新工况数据, 并未保护历史数据隐私. 本文所提的 RKME-BLS 在各项预测指标上远超模型复用的基线算法, 由表 1 可以看出, 相较于三种基线方法 (BLS、RAND、AVG), 其 R² 的平均值分别提升了约 86%、119% 和 66%, 而与需要共享原始数据的两种迁移学习算法相比, RKME-BLS 的 R² 平均值仍存在约 11% 和 12% 的差距. 本文方法在完全不暴露历史工况数据的前提下, 仅以牺牲微小的预测性能为代价, 保护了历史工况的数据隐私.

3.2 炼钢过程

以某炼钢厂的硅钢冶炼过程为例, 现代硅钢制造是以铁水为原料, 经冶炼去除杂质, 再通过精炼对硅、铝等成分进行精确控制, 得到合格钢水后, 通过连铸技术凝固成铸坯, 最后经轧制等压力加工制成各类钢材产品的复杂工业过程. 实际业炼钢过程环境恶劣, 过程数据获取受限且具有高保密性, 因而工业炼钢过程数据具有极高的研究价值与应用价值.

为建立软测量模型, 本实验选用铁损值作为预测的质量变量, 选取炉温、钢厚度、热轧宽度、钢胚在炉内停留时间等 33 个相关变量作为输入的辅助变量. 通过选取不同的初始材料、钢材厚度、POS 码等产生不同工况的数据, 本实验共选取 6 种不同的工况, 每个工况 700 组数据. 为深入理解各工况数据分布特征及其差异, 采用 t-SNE 对各工况数据进行降维, 如图 10 所示.

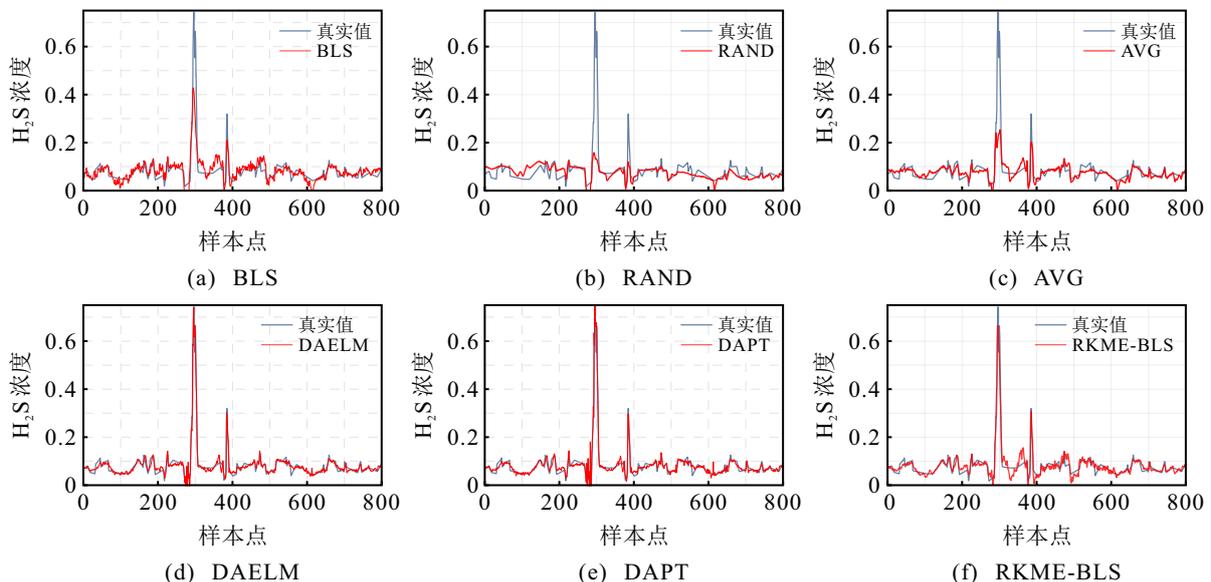
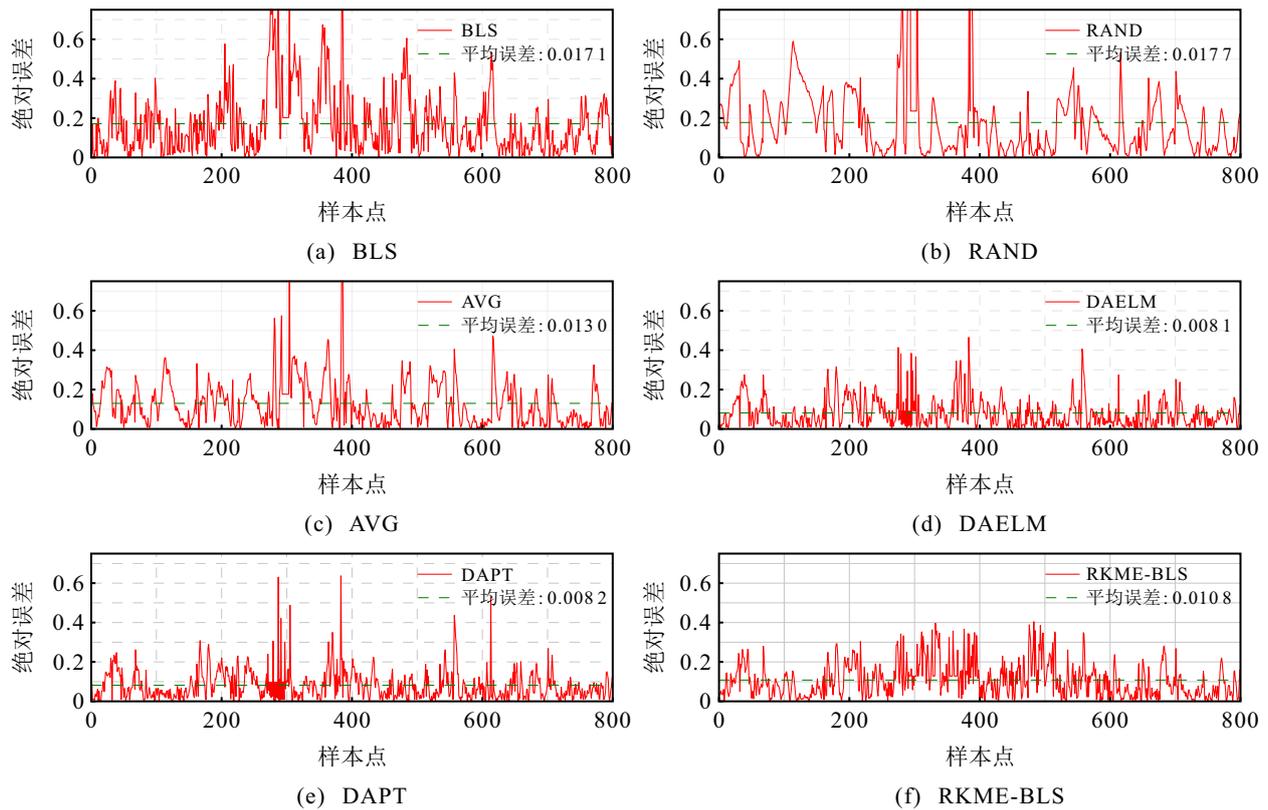


图8 各模型对 H₂S 浓度预测曲线

图9 各模型对 H_2S 浓度预测误差曲线表1 各模型对 H_2S 浓度预测评价指标对比

待测工况	指标	BLS	RAND	AVG	DAELM	DAPT	RKME-BLS
工况1	RMSE	0.0361	0.0554	0.0454	0.0148	0.0157	0.0145
	MAE	0.0199	0.0329	0.0223	0.0097	0.0088	0.0112
	R^2	0.4733	0.3149	0.5149	0.9517	0.9486	0.8809
工况2	RMSE	0.0487	0.0457	0.0412	0.0214	0.0201	0.0291
	MAE	0.0256	0.0244	0.0231	0.0151	0.0162	0.0191
	R^2	0.2504	0.3214	0.4125	0.8703	0.8814	0.8014
工况3	RMSE	0.0255	0.0324	0.0342	0.0167	0.0154	0.0213
	MAE	0.0291	0.0257	0.0224	0.0101	0.0092	0.0127
	R^2	0.3415	0.4144	0.3924	0.9217	0.9413	0.8332
工况4	RMSE	0.0301	0.0291	0.0254	0.0103	0.0130	0.0174
	MAE	0.0201	0.0198	0.0214	0.0078	0.0084	0.0101
	R^2	0.5411	0.6014	0.6245	0.9647	0.9745	0.8614
工况5	RMSE	0.0254	0.0314	0.0255	0.0104	0.0104	0.0154
	MAE	0.0156	0.0201	0.0197	0.0079	0.0077	0.0099
	R^2	0.5309	0.5144	0.5547	0.9565	0.9547	0.8574
工况6	RMSE	0.0399	0.0355	0.0301	0.0134	0.0145	0.0208
	MAE	0.0351	0.0271	0.0245	0.0095	0.0092	0.0128
	R^2	0.2914	0.4574	0.5987	0.9214	0.9345	0.8218

在训练阶段, 每个工况训练好一个 BLS 预测模型, 再利用 RKME 构造每个工况对应的缩约集 ($M = 35$, 高斯核为 0.5), 然后将模型和缩约集一起导入到模型库中.

在应用阶段, 考虑到每个工况均可作为待测工况, 因此做 6 次实验. 同时, 在小样本条件的限制下, 待测工况仅拥有 10 组带标签的数据. 如图 11 所示,

从 0.43(历史工况对间距离的下四分位数) 开始, 减小阈值设定来对比预测性能, 当阈值小于 0.12 时, 两种方法预测性能没有明显差异, 因此本实验设定距离阈值 $h = 0.12$, 当 $d < h$ 时, 将两种工况视为相近工况, 直接复用原模型进行预测, 否则构建 BLS 的增量学习来更新模型.

为全面评估所提模型的优越性, 将各模型预测

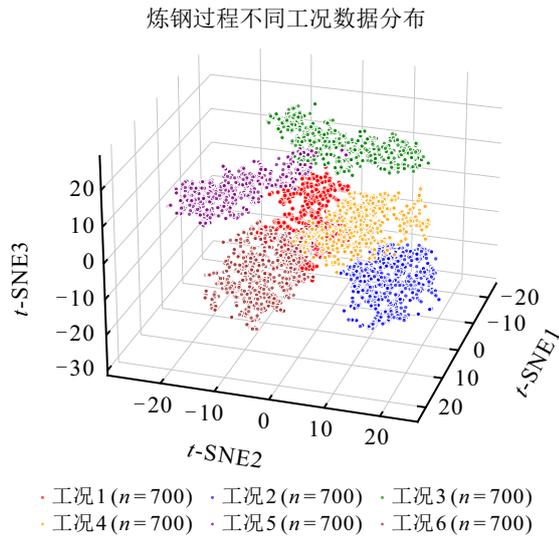


图10 炼钢过程不同工况三维数据分布图

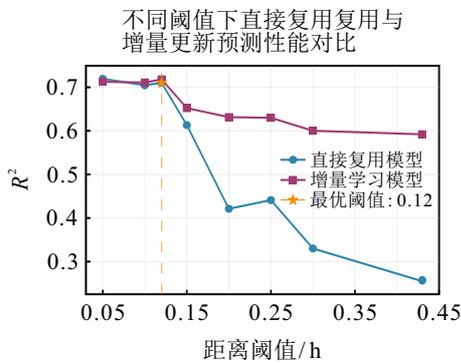


图11 不同阈值下铁损值预测性能对比图

误差进行可视化 (以工况 1 为待测工况), 结果显示

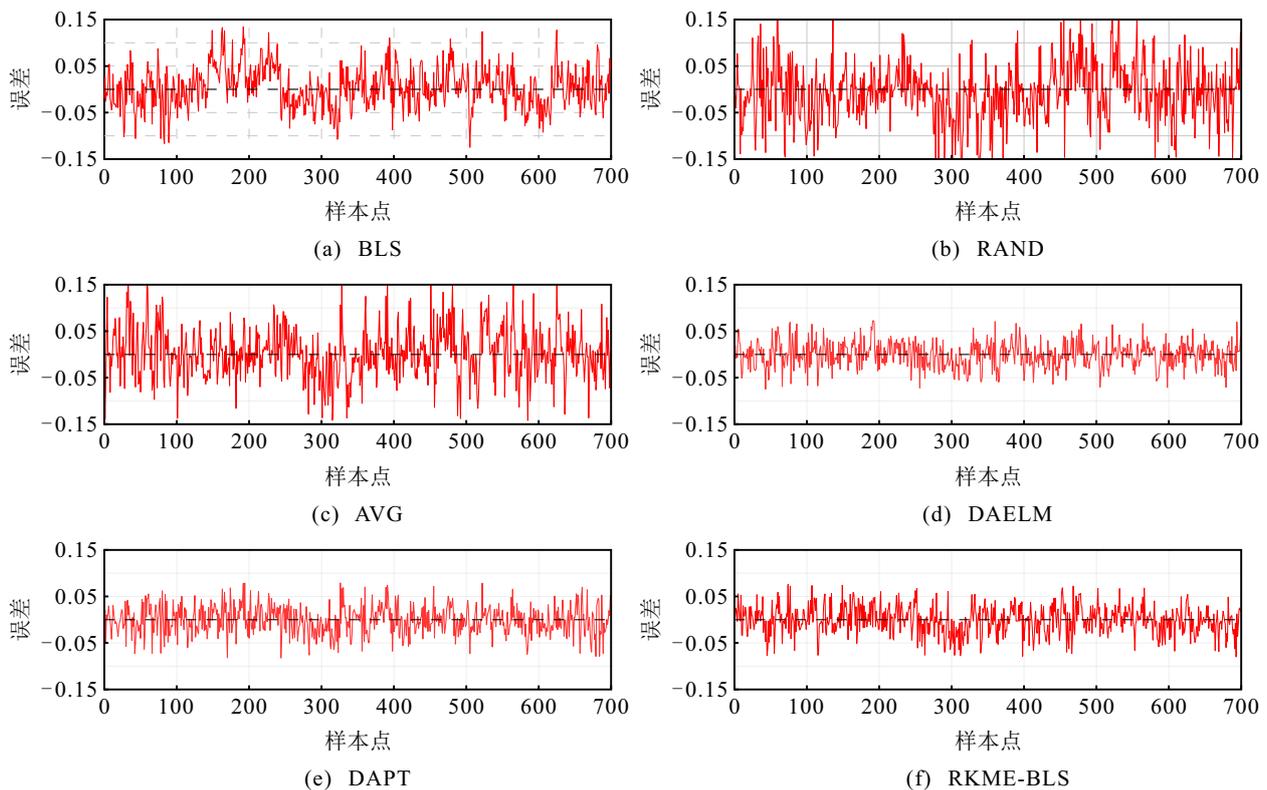


图12 各模型对铁损量预测的误差曲线

在图 12-13 中, 表 2 给出了各模型对铁损值预测的评价指标. 从图 10 中可以看出各个工况分布的差异较为明显, 因而模型复用的两个基线算法预测误差较大; 而 BLS 模型因训练数据量稀少, 预测结果也存在明显失真, 表中数据同样表明这三个模型预测性能较差. 迁移学习的两种算法同时利用历史与当前工况数据进行训练, 预测误差显著降低, 但因其需访问本应受保护的历史工况数据, 在实际隐私约束场景中难以实施. 本文所提的 RKME-BLS 算法, 则在完全隔离历史原始数据的条件下, 仍取得了与迁移学习相近的预测性能. 具体由表 2 可知, RKME-BLS 的 R^2 平均值较 BLS、RAND、AVG 分别提升约 54%、284% 和 147%, 显著增强了模型对新工况的解释能力. 与 DAELM 和 DAPT 相比, RKME-BLS 的 R^2 平均值仅下降约 13% 和 14%, 且其 RMSE 与 MAE 均保持在相同数量级的较低水平. 这一结果表明, 在炼钢过程这类数据分布差异明显、隐私要求严苛的工业场景中, 所提方法能够以极小的性能代价, 实现历史数据全隐私保护下的模型有效复用, 兼顾了可行性、安全性与预测准确性.

4 结论

针对多工况场景下, 新工况数据稀缺且历史工况数据无法用于训练的软测量建模问题, 本文提出一种基于宽度学习系统的缩约核均值嵌入软测量模型复用算法. 该模型分为训练阶段和应用阶段, 训练阶段利用基础的 BLS 训练好各个工况的软测量模

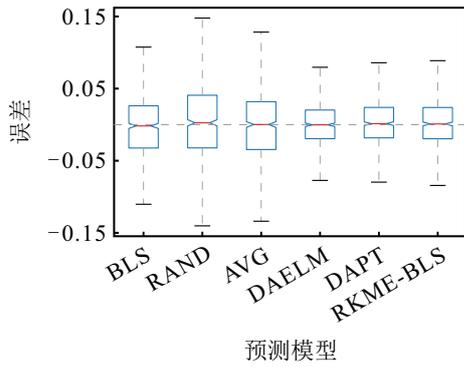


图13 各模型对铁损量预测的误差箱线图

型, 保证计算精度的同时提高了建模效率. 为保护历

史工况数据隐私, 利用 KME 在 RKHS 空间中构建历史工况分布点. 同时, 构建简约集在保持分布能力不变的情况下, 进一步加强数据隐私保护, 再将对应工况简约集以及模型一起上传到模型库中. 应用阶段, 在 RKHS 中度量新旧工况分布的距离, 找到最匹配的模型进行复用, 并于设定的距离阈值比较, 判断是否需要更新模型. 设计带增量的 BLS 在新工况更新模型参数, 实现最终预测. 通过硫回收过程和炼钢过程验证所提算法的有效性, 结果表明与迁移软测量算法相比, 所提算法在处理多工况软测量问题时, 仅以微小的预测精度为代价, 全方位的保护了数据

表2 各模型对铁损预测评价指标对比

待测工况	指标	BLS	RAND	AVG	DAELM	DAPT	RKME-BLS
工况1	RMSE	0.0521	0.1047	0.0851	0.0287	0.0309	0.0397
	MAE	0.0394	0.0855	0.0611	0.0251	0.0242	0.0273
	R ²	0.5119	0.1521	0.3112	0.8201	0.8124	0.7235
工况2	RMSE	0.0557	0.0968	0.0887	0.0292	0.0299	0.0387
	MAE	0.0397	0.0732	0.0601	0.0247	0.0214	0.0287
	R ²	0.4788	0.1978	0.3214	0.8154	0.8244	0.7014
工况3	RMSE	0.0642	0.0845	0.0804	0.0321	0.0307	0.0401
	MAE	0.0478	0.0694	0.0678	0.0257	0.0224	0.0302
	R ²	0.3214	0.2141	0.2574	0.7845	0.7896	0.6987
工况4	RMSE	0.0527	0.0901	0.0701	0.0288	0.0289	0.0387
	MAE	0.0424	0.0744	0.0511	0.0232	0.0207	0.0287
	R ²	0.4121	0.1745	0.2847	0.8241	0.8314	0.7124
工况5	RMSE	0.0874	0.1011	0.0821	0.0289	0.0297	0.0421
	MAE	0.0601	0.0799	0.0677	0.0242	0.0217	0.0311
	R ²	0.2904	0.1474	0.2547	0.8014	0.8091	0.6977
工况6	RMSE	0.0701	0.0912	0.0802	0.0292	0.0279	0.0399
	MAE	0.0501	0.0714	0.0687	0.0219	0.0214	0.0301
	R ²	0.3142	0.1874	0.2674	0.8074	0.8111	0.7022

安全, 为实际工业过程的优化控制提供有力的技术保障. 未来可研究面向工况特性的参数自适应调整机制与可学习的距离度量函数, 以提升分布匹配的精度与泛化能力, 拓展实际多工况场景下软测量模型复用的范围.

参考文献 (References)

[1] 廖开继, 隋璘, 熊伟丽. 基于双阶段注意力的双流记忆调节 GRU 软测量建模[J]. *控制与决策*, 2025, 40(9): 2848-2858.
(Liao K J, Sui L, Xiong W L. Soft sensor modeling based on dual-stream memory-modulated GRU with dual-stage attention mechanism[J]. *Control and Decision*, 2025, 40(9): 2848-2858.)

[2] 范龙飞, 史旭东, 熊伟丽. 跨工况下基于参数迁移的域适应宽度学习软测量建模[J]. *化工学报*, 2025, 76(9): 4644-4657.
(Fan L F, Shi X D, Xiong W L. Domain adaptive broad learning system with parameter transferring for cross-

condition soft sensor modeling[J]. *CIESC Journal*, 2025, 76(9): 4644-4657.)

[3] Yuan X F, Li L, Shardt Y A W, et al. Deep learning with spatiotemporal attention-based LSTM for industrial soft sensor model development[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(5): 4404-4414.

[4] 赵健程, 冯良骏, 岳嘉祺, 等. 从零样本学习理论模型到工业应用——动机、演变与挑战[J]. *控制与决策*, 2024, 39(9): 2833-2857.
(Zhao J C, Feng L J, Yue J Q, et al. From zero-shot learning theoretical model to its industrial application: Motivation, evolution and challenges[J]. *Control and Decision*, 2024, 39(9): 2833-2857.)

[5] Sun Q Q, Ge Z Q. A survey on deep learning for data-driven soft sensors[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(9): 5853-5866.

[6] Peña-Mangas D, Cernuda C, Reguera-Bakhache D. Data-driven glass viscosity soft sensor development and validation in a glass container manufacturing line[J]. *Journal of Manufacturing Processes*, 2025, 141: 1060-1070.

- [7] 张景欣,周东华,陈茂银,等.数据驱动的多工况过程异常监测方法:综述与展望[J].中国科学:信息科学,2023,53(11):2087-2106.
(Zhang J X, Zhou D H, Chen M Y, et al. Data-driven anomaly monitoring methods for multimode processes: overview and perspectives[J]. Science China Information Sciences, 2023, 53(11): 2087-2106.)
- [8] 杨超.多工况过程迁移建模方法与应用研究[D].浙江工业大学,2019.
(Yang C. Transfer learning modeling method and its application for multi-grade processes[D]. Zhejiang University of Technology, 2019.)
- [9] Takagi S, Kaneko O. Graph-regularized data-driven control: Simultaneous optimization across multiple operating conditions[J]. Journal of Process Control, 2025, 152: 103486.
- [10] 庄福振,罗平,何清,等.迁移学习研究进展[J].软件学报,2015,26(1):26-39.
(Zhuang F Z, Luo P, He Q, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1): 26-39.)
- [11] 柴铮,汪嘉业,赵春晖,等.面向工业监控典型监督任务的深度迁移学习方法:现状、挑战与展望[J].中国科学:信息科学,2023,53(5):821-840.
(Chai Z, Wang J Y, Zhao C H, et al. Deep transfer learning methods for typical supervised tasks in industrial monitoring: state-of-the-art, challenges, and perspectives[J]. Science China Information Sciences, 2023, 53(5): 821-840.)
- [12] Zhao P, Cai L W, Zhou Z H. Handling concept drift via model reuse[J]. Machine Learning, 2020, 109(3): 533-568.
- [13] Gong B Q, Shi Y, Sha F, et al. Geodesic flow kernel for unsupervised domain adaptation[C]. IEEE Conference on Computer Vision and Pattern Recognition. Providence, 2012: 2066-2073.
- [14] Zhang L, Zhang D. Domain adaptation extreme learning machines for drift compensation in E-nose systems[J]. IEEE Transactions on Instrumentation and Measurement, 2015, 64(7): 1790-1801.
- [15] 许夙晖,慕晓冬,柴栋,等.基于极限学习机参数迁移的域适应算法[J].自动化学报,2018,44(2):311-317.
(Xu S H, Mu X D, Chai D, et al. Domain adaption algorithm with ELM parameter transfer[J]. Acta Automatica Sinica, 2018, 44(2): 311-317.)
- [16] Xiao Y S, Liang F, Liu B. A transfer learning-based multi-instance learning method with weak labels[J]. IEEE Transactions on Cybernetics, 2022, 52(1): 287-300.
- [17] Duan L X, Tsang I W, Xu D, et al. Domain adaptation from multiple sources via auxiliary classifiers[C]. Proceedings of the 26th Annual International Conference on Machine Learning. Montreal, 2009: 289-296.
- [18] Du S S, Koushik J, Singh A, et al. Hypothesis transfer learning via transformation functions[J]. Advances in Neural Information Processing Systems, 2017, 30: 574-584.
- [19] 张钦彤,王昱超,王鹤羲,等.大语言模型微调技术的研究综述[J].计算机工程与应用,2024,2024(17):17-33.
(Zhang Q T, Wang Y C, Wang H X, et al. Comprehensive review of large language model fine-tuning[J]. Computer Engineering and Applications, 2024, 2024(17): 17-33.)
- [20] 黄震华,杨顺志,林威,等.知识蒸馏研究综述[J].计算机学报,2022,45(3):624-653.
(Huang Z H, Yang S Z, Lin W, et al. Knowledge distillation: A survey[J]. Chinese Journal of Computers, 2022, 45(3): 624-653.)
- [21] Wu X Z, Xu W K, Liu S, et al. Model reuse with reduced kernel mean embedding specification[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(1): 699-710.
- [22] Chen C L P, Liu Z L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10-24.
- [23] Yang L, Yang Z L, Li F, et al. Single-layer feedforward neural networks with dynamic width for domain adaptation[J]. Science China Information Sciences, 2025, 68(8): 182205.
- [24] Zhu S Y, Chen B, Chen Z T, et al. Asymptotically optimal one- and two-sample testing with kernels[J]. IEEE Transactions on Information Theory, 2021, 67(4): 2074-2092.
- [25] Lopez-Paz D, Muandet K, Schölkopf B, et al. Towards a learning theory of cause-effect inference[C]. PMLR: International Conference on Machine Learning. Lille, 2015: 1452-1461.
- [26] di Bella A, Fortuna L, Graziani S, et al. Soft sensor design for a sulfur recovery unit using genetic algorithms[C]. IEEE International Symposium on Intelligent Signal Processing. Alcalá de Henares, 2007: 1-6.
- [27] 霍海丹,阎高伟,程兰,等.基于低秩重构表示的动态回归迁移模型[J].控制与决策,2024,39(8):2511-2520.
(Huo H D, Yan G W, Cheng L, et al. Dynamic transfer regression model based on low-rank reconstruction representation[J]. Control and Decision, 2024, 39(8): 2511-2520.)

作者简介

范龙飞(2000-),男,硕士生,主要研究方向为复杂工业过程建模,E-mail: fll202@163.com;

史旭东(1993-),男,博士,讲师,主要研究方向为智能软测量技术及应用、工业大数据分析,E-mail: shixudong@jiangnan.edu.cn;

熊伟丽(1978-),女,教授,博士,博士生导师,主要研究方向为智能软测量技术及应用、基于数据的工业过程监测,E-mail: weili_xiong@jiangnan.edu.cn;

黄望芽(1976-),男,高级工程师,博士生,主要研究方向为钢铁产品工艺技术、大数据应用技术,E-mail: huangwy@baosteel.com.