

DOI: 10.19650/j.cnki.cjsi.J2210030

基于时空局部学习的集成自适应软测量方法*

黄成^{1,2}, 金怀平¹, 王彬¹, 钱斌¹, 杨彪¹

(1. 昆明理工大学信息工程自动化学院 昆明 650500; 2. 华能澜沧江水电股份有限公司 昆明 650214)

摘要:集成软测量方法已被广泛应用于流程工业关键质量参数实时估计。但是,常规集成建模方法在基模型构建过程中往往局限于挖掘样本之间的空间关系,忽略了样本间的时序关系,从而导致过程局部状态挖掘不充分、基模型间多样性不足等问题。其次,传统软测量方法由于缺乏自适应机制而无法有效处理过程时变特征,从而导致模型性能发生退化。为此,提出一种基于时空局部学习(STLL)的集成自适应软测量方法。该方法首先通过移动窗口、即时学习技术分别挖掘样本间的时序关系和空间关系,并采用统计假设检验实现冗余状态剔除,进而构建多样性的时空局部高斯混合回归(GMR)模型。然后,基于在线选择性集成策略实现局部预测结果的自适应融合。此外,引入双重自适应机制以缓解模型性能退化问题。实验结果显示,相较于非自适应全局GMR模型、时间局部学习集成GMR模型、空间局部学习集成GMR模型,所提方法在金霉素发酵过程中的预测精度分别提升了70.3%,14.9%,27.8%;在脱丁烷塔过程中,分别提升了31.9%,21.2%,19.3%。

关键词:软测量;集成学习;自适应机制;概念漂移;局部状态辨识;高斯混合回归

中图分类号: TH89 TP274 **文献标识码:** A **国家标准学科分类代码:** 510.80

Ensemble adaptive soft sensor method based on spatio-temporal local learning

Huang Cheng^{1,2}, Jin Huaiping¹, Wang Bin¹, Qian Bin¹, Yang Biao¹

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China;
2. Huaneng Lancang River Hydropower Inc, Kunming 650214, China)

Abstract: Ensemble learning soft sensors have been widely used to estimate key quality parameters in the process industry. However, the conventional ensemble modeling methods are often limited to mining the temporal relationships between samples for building the base models while ignoring the spatial relationships between samples. This may lead to problems such as insufficient local state mining of the process and insufficient diversity among base models. In addition, traditional soft sensor methods cannot effectively deal with the time-varying characteristics of the process due to the lack of adaptive mechanisms, which leads to the degradation of the model performance. Therefore, an ensemble adaptive soft sensor method based on the spatio-temporal local learning (STLL) is proposed. Firstly, the method mines the temporal and spatial relationships of process data, and the redundant states are removed by using statistical hypothesis testing. Then, a set of diverse spatial-temporal local Gaussian mixture regression models (GMR) is formulated. Then, the local prediction results are combined adaptively based on an online selective ensemble strategy. Besides, a dual-updating strategy is proposed for alleviating the model performance degradation. Compared to the non-adaptive global GMR, temporal local learning based ensemble GMR, spatial local learning based ensemble GMR, experimental results show that the prediction accuracy of the proposed STLL approach is improved by 70.3%, 14.9%, and 27.8% in an industrial chlortetracycline fermentation process, while it is improved by 31.9%, 21.2%, and 19.3% in an industrial debutanizer process.

Keywords: soft sensor; ensemble learning; adaptation mechanism; concept drift; local state identification; Gaussian mixture regression

0 引言

在冶金、化工、石油等流程工业中,基于硬件传感器的在线测量往往受到经济或者技术的制约,导致过程关键质量参数无法实时获取。为此,数据驱动软测量技术已被广泛应用于过程控制领域,其核心是根据易测辅助变量和难测主导变量之间的数学模型实现关键变量的实时估计^[1-3]。常用的数据驱动软测量建模方法有偏最小二乘(partial least squares, PLS)^[4]、人工神经网络(artificial neural networks, ANN)^[5]、支持向量回归(support vector regression, SVR)^[6]、高斯过程回归(gaussian process regression, GPR)^[7]、深度学习(deep learning, DL)^[8]等。

根据学习方式的不同,可将软测量建模方法分为全局建模和局部建模。但是全局建模方法无法准确表征过程的局部特征,在线更新困难。相比之下,局部学习方法更具优势,能更好地描述局部过程特征,并且能与自适应机制灵活融合以更好地处理过程时变特征。其中,集成学习作为一种典型的局部学习方式,在软测量领域受到广泛关注^[9]。为有效处理过程的复杂非线性和时变性特征,本文拟研究一种高性能的集成自适应软测量方法。

一般而言,集成自适应软测量建模包含3个关键任务,多样性基模型生成、融合和自适应更新。构建基模型的一种常见策略是对过程数据进行局部划分。聚类分析是实现这一目标的一种流行方法。但是此类方法大多仅考虑样本间空间关系,未考虑样本间的时序关系,从而导致对过程状态信息的挖掘不够充分,而且常规聚类方法在遇到新过程状态出现时,很难进行在线更新。为此,本文致力于提出一种同时考虑时间和空间信息的时空局部区域划分方法,综合样本间的时空信息对局部过程状态进行充分辨识。

基模型构建完成以后,其融合成为建立高性能集成模型的下一关键任务。一般而言,可将模型融合方法分为非自适应加权和自适应加权两种^[10]。非自适应加权通常根据局部模型的离线表现赋予固定权重,无法有效评价模型在线预测时的性能表现。相比之下,自适应加权集成能够根据局部模型对当前查询点的预测性能自适应地赋予局部模型权重。此外,文献[11-13]指出,集成学习中经常出现“Many could be better than all”的现象,即通过集成修剪可能会获得更佳的集成预测性能。

此外,赋予集成模型自适应更新能力也十分重要。软测量模型在线应用时常常因为工业过程的概念漂移问题导致模型预测性能退化^[14]。为此,需要解决好两个关键问题:概念漂移检测和概念漂移处理。概念漂移检测主要通过分析过程数据分布变化或模型预测误差趋势来

实现。概念漂移处理主要通过引进合适的自适应更新机制来应对。但是,每种自适应方法都有一定的局限性,比如时间差分(time difference, TD)建模和偏移补偿(offset compensation, OC)^[15]适合处理缓变型时变特征,在线模型添加擅长于解决突变型时变特征。但是,在过程对象中缓变型和突变型两种时变特征通常同时出现^[16-17]。为此,有必要考虑一种兼备缓变和突变型时变特征处理能力的自适应更新机制。

综上,本文提出了一种融合时空局部状态辨识与概念漂移检测的在线选择性集成自适应软测量建模框架。该方法在离线阶段结合移动窗口(moving window, MW)^[18-19]技术和即时学习(just-in-time learning, JIT)^[20]技术的优势,同时从时间、空间视角构建局部区域,然后采用统计假设检验技术对冗余局部区域进行剔除,随后构建多样性的时空局部预测模型。在线预测阶段,采用在线选择性集成策略实现基模型的自适应融合。同时,引入一种双重自适应更新机制:首先基于库尔贝克-莱布勒(Kullback-Leibler, KL)^[21]散度评价查询点和相邻点的预测误差分布差异性,以此实现概念漂移检测,然后根据检测结果决定是否在线添加局部模型,从而有效处理突变型时变特征;此外,通过OC技术实现局部模型的在线校正,从而有效处理缓变型时变特征。该方法的有效性和优越性通过工业脱丁烷塔过程和金霉素发酵过程进行了验证。

1 高斯混合回归

高斯混合回归(Gaussian mixture regression, GMR)^[22]作为高斯混合模型(Gaussian mixture model, GMM)模型^[23]的延伸应用,通过使用高斯混合对数据的概率密度进行线性组合,其可以对任意概率密度函数进行建模。

假设数据向量 \mathbf{x} 由两部分组成:输入 \mathbf{x}^i 和输出 \mathbf{x}^o ,如果 \mathbf{x} 服从含有 k 个分量的高斯混合模型分布,每个高斯分量的均值向量和协方差矩阵可以表示为如下输入和输出部分:

$$\boldsymbol{\mu}_k = \begin{bmatrix} \boldsymbol{\mu}_k^i \\ \boldsymbol{\mu}_k^o \end{bmatrix}, \boldsymbol{\Sigma}_k = \begin{bmatrix} \boldsymbol{\Sigma}_k^i & \boldsymbol{\Sigma}_k^{io} \\ \boldsymbol{\Sigma}_k^{oi} & \boldsymbol{\Sigma}_k^o \end{bmatrix} \quad (1)$$

对于第 k 个高斯分量,给定输入 \mathbf{x}^i 时,相应的输出 \mathbf{x}^o 也服从高斯分布,关于 \mathbf{x}^i 的 \mathbf{x}^o 条件概率定义为:

$$p(\mathbf{x}^o | \mathbf{x}^i, k) \sim f(\mathbf{x}^o | \hat{\mathbf{x}}_k, \hat{\boldsymbol{\Sigma}}_k) \quad (2)$$

其中,均值 $\hat{\mathbf{x}}_k$ 和协方差 $\hat{\boldsymbol{\Sigma}}_k$ 的计算公式为:

$$\hat{\mathbf{x}}_k = \boldsymbol{\mu}_k^o + \boldsymbol{\Sigma}_k^o (\boldsymbol{\Sigma}_k^i)^{-1} (\mathbf{x}^i - \boldsymbol{\mu}_k^i) \quad (3)$$

$$\hat{\boldsymbol{\Sigma}}_k = \boldsymbol{\Sigma}_k^o - \boldsymbol{\Sigma}_k^{oi} (\boldsymbol{\Sigma}_k^i)^{-1} \boldsymbol{\Sigma}_k^{io} \quad (4)$$

由于输入 \mathbf{x}^i 由混合模型生成,输出 \mathbf{x}^o 的分布式将由

K 部分组成,就整个混合模型而言,关于输入 \mathbf{x}^i 的输出 \mathbf{x}^o 的期望条件分布也是一个高斯混合模型:

$$p(\mathbf{x}^o | \mathbf{x}^i) \sim \sum_{k=1}^K h_k f(\mathbf{x}^o | \hat{\mathbf{x}}_k, \hat{\Sigma}_k) \quad (5)$$

式中: h_k 是关于输入 \mathbf{x}^i 的第 k 个高斯分量的后验概率,由贝叶斯公式可得:

$$h_k = p(k | \mathbf{x}^i) = \frac{p(k)p(\mathbf{x}^i | k)}{\sum_{i=1}^K p(i)p(\mathbf{x}^i | i)} = \frac{\omega_k f(\mathbf{x}^i | \boldsymbol{\mu}_k^i, \boldsymbol{\Sigma}_k^i)}{\sum_{i=1}^K \omega_i f(\mathbf{x}^i | \boldsymbol{\mu}_i^i, \boldsymbol{\Sigma}_i^i)} \quad (6)$$

最后,给定一个输入 \mathbf{x}^i ,输出 \mathbf{x}^o 的条件期望可以由高斯分布 $f(\hat{\mathbf{x}}^o, \hat{\Sigma})$ 估计出,基于高斯分布的线性转换,输出均值向量 $\hat{\mathbf{x}}^o$ 和协方差矩阵 $\hat{\Sigma}$ 的计算公式为:

$$\hat{\mathbf{x}}^o = \sum_{k=1}^K h_k \hat{\mathbf{x}}_k, \quad \hat{\Sigma} = \sum_{k=1}^K h_k^2 \hat{\Sigma}_k \quad (7)$$

式中:GMR 高斯分量个数 K 由交叉验证确定。

2 STLL 集成自适应软测量方法

STLL 算法主要包括如下步骤:基于时空相似度准则的局部状态辨识和局部模型构建;多样性时空局部模型的自适应集成和模型自适应更新。

2.1 时空局部状态辨识和多样性局部 GMR 模型构建

局部状态辨识是深入理解多工况复杂过程特征的关键一步。为此,本文综合 MW 技术和 JIT 技术提出一种时空局部状态辨识方法,从时间相关性和空间相关性角度构建多样性局部区域(local domain, LD),为构建多样性的局部模型奠定基础。

1) 基于 MW 和统计假设检验构建多样性时间局部区域

文献[24-25]指出,从时间角度看,MW 技术能有效跟踪过程状态变化。因此,本文采用 MW 技术从时间相关性角度对过程局部状态进行辨识。具体步骤如下:

(1) 首先从历史数据集 $\mathbf{Z} = \{\mathbf{X}, \mathbf{y}\} = \{\mathbf{x}(t), \mathbf{y}(t)\}_{t=0}^{(n-1)T}$ 中选取带有 W 个时间连续样本的数据集 $\{\mathbf{x}_t, \mathbf{y}_t\}_{t=t_{ini}^{ini}+WT}$ 作为初始窗口 $\mathbf{W}_{ini} = \{\mathbf{X}_{ini}, \mathbf{y}_{ini}\}$,可构建初始模型为:

$$\hat{\mathbf{y}}_{ini} = f_{ini}(\mathbf{x}_{ini}) \quad (8)$$

其中, $\mathbf{x}(t), \mathbf{y}(t), n, T$ 表示 t 时刻输入、输出、样本数量和采样周期。随后得到初始窗口对应的预测残差向量:

$$\mathbf{e}_{ini} = \mathbf{y}_{ini} - f_{ini}(\mathbf{X}_{ini}) \quad (9)$$

(2) 在构建初始模型 f_{ini} 后,窗口依次往前移动一步,构建一个新的窗口数据集:

$$\mathbf{W}_{sft} = \{\mathbf{X}_{sft}, \mathbf{y}_{sft}\} = \{\mathbf{x}_t, \mathbf{y}_t\}_{t=t_{ini}^{ini}+T} \quad (10)$$

\mathbf{W}_{sft} 数据对应的预测残差向量可通过 f_{ini} 计算:

$$\mathbf{e}_{sft} = \mathbf{y}_{sft} - f_{ini}(\mathbf{X}_{sft}) \quad (11)$$

(3) 判断两个窗口 \mathbf{W}_{ini} 和 \mathbf{W}_{sft} 之间的相似关系。主要根据 t 检验分析残差向量 \mathbf{e}_{ini} 和 \mathbf{e}_{sft} 之间是否存在显著性差异来判断。构建原假设 H_0 和备择假设 H_1 :

$$\begin{cases} H_0: \mu(\mathbf{e}_{sft}) = \mu(\mathbf{e}_{ini}) \\ H_1: \mu(\mathbf{e}_{sft}) \neq \mu(\mathbf{e}_{ini}) \end{cases} \quad (12)$$

如果 H_0 接受 给定显著性水平,则认为 \mathbf{W}_{ini} 和 \mathbf{W}_{sft} 的样本属于同一过程状态,窗口将继续向前移动。反之,则认为 \mathbf{W}_{sft} 是一个新的过程状态,应该基于 \mathbf{W}_{sft} 构建一个新的模型并将其设为一个新的初始状态模型 f_{ini} ,转到步骤(2)重复上述状态识别过程,直到所有历史数据都划入了不同的过程状态。

上述过程中,用于过程状态判别的统计假设检测详细步骤如下:

①假设 \mathbf{W}_{ini} 和 \mathbf{W}_{sft} 中的样本均服从正态分布,构造如下的 E 统计量:

$$E = \frac{\mu_{sft} - \mu_{ini}}{\sigma_{sft} / \sqrt{W}} \quad (13)$$

式中: μ_{sft} 和 σ_{sft} 分别代表 \mathbf{e}_{sft} 的样本均值和标准差, μ_{ini} 是由 \mathbf{e}_{ini} 估计的均值。如果原假设 H_0 成立,检验统计量 E 服从自由度为 $W-1$ 的 t 分布,即 $E \sim t(W-1)$,即:

$$|E| < t_{\alpha/2}(W-1) \quad (14)$$

其中, $t_{\alpha/2}$ 表示显著性水平 α 下的 E 统计量,得到相应的累积概率为:

$$P\{|E| < t_{\alpha/2}(W-1)\} = 1 - \alpha \quad (15)$$

②假设式(14)成立,则表明 \mathbf{W}_{ini} 和 \mathbf{W}_{sft} 之间没有显著性差异;反之,认为它们之间存在明显差异。其中,为了不失一般性, t 检验中的 α 设定为 0.05。

(4) 通过上述统计假设检验和 MW 技术将过程数据划分为 M_1 个局部区域:

$$\{LD_{time,1}, \dots, LD_{time,m}, \dots, LD_{time,M_1}\} \quad (16)$$

(5) 基于已建局部区域建立相应的时间局部模型 $\{GMR_{time,1}, \dots, GMR_{time,M_1}\}$ 。

(6) 由时间相关划分的局部区域可能存在冗余,因此产生的冗余模型可能会影响到模型预测性能的提升^[26]。为此本文依然采用预测误差 t 检验技术对局部区域进行冗余剔除,具体过程如下:

①假设当前状态辨识到一个新的局部区域 $\mathbf{W}_{new} = \{\mathbf{X}_{new}, \mathbf{y}_{new}\}$,并构建相应的局部模型 f_{new} 。随后应计算 f_{new} 和已构建无冗余局部模型 $\{f_q\}_{q=1}^{Q-1}$ 在 $\{\mathbf{X}_{new}, \mathbf{y}_{new}\}$ 上的预测残差向量:

$$\mathbf{R}_{new} = \mathbf{y}_{new} - f_{new}(\mathbf{X}_{new}) \quad (17)$$

$$\mathbf{R}_q = \mathbf{y}_{new} - f_q(\mathbf{X}_{new}), \quad 1 \leq q \leq Q-1 \quad (18)$$

②借助步骤(3)中的统计假设检验技术完成冗余判

别。若 \mathbf{R}_{new} 和 \mathbf{R}_q 之间无显著性差异,则意味着 f_m 和 f_{new} 之间存在冗余,需要移除对应的 LD_q 和 f_q 。反之,可认为 f_m 和 f_{new} 属于不同的过程状态,需要将 f_{new} 添加到时空模型池中。

2) 基于 JIT 和统计假设检验构建多样性空间局部区域

JIT 建模作为一种典型的在线局部学习方法,通常基于空间距离指标构建局部模型,以有效处理过程非线性及时变性问题。为此,本文借鉴 JIT 模型构建思想通过离线方式完成对过程历史数据的局部区域辨识。详细过程描述如下:

根据 JIT 建模策略,让每一个历史样本模拟查询点,得到一个被认为来自相同过程状态的样本组成局部区域。为了不失一般性,在此选用基于欧氏距离 (Euclidean distance, ED) 的相似度:

$$\text{sim}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|) \quad (19)$$

以第 1 个训练样本模拟查询点 \mathbf{x}_{new} , 它与历史样本 $(\mathbf{x}_i, \mathbf{y}_i)$ 之间的相似度计算如下:

$$s_i = \text{sim}(\mathbf{x}_{\text{new}}, \mathbf{x}_i), \quad i = 1, 2, \dots, n \quad (20)$$

挑选相似度最高的 D 个样本作为初始局部区域 $LD_{\text{init}} = \{\mathbf{X}_{\text{init}}, \mathbf{y}_{\text{init}}\}$, 随后基于 LD_{init} 生成局部模型 f_{init} 。

移动到下一个训练样本,重复上述步骤,建立相应的局部区域 $LD_{\text{fit}} = \{\mathbf{X}_{\text{fit}}, \mathbf{y}_{\text{fit}}\}$ 和局部模型 f_{fit} 。通过这种方式能辨识出所有潜在局部区域。但是,由此建立的局部模型也存在大量冗余。JIT 模型在构建过程中依然采用 2.1 节 1) 中的预测误差 t 检验作为模型的冗余判别机制剔除冗余 LD 和局部模型。最终获得 M_2 个局部区域并建立相应的空间局部模型:

$$\{LD_{\text{space}, m}, GMR_{\text{space}, M_2}\}_{m=1}^{M_2} \quad (21)$$

综上,通过 MW 和 JIT 技术离线构建 $M = M_1 + M_2$ 个时空局部区域和模型如下:

$$\text{ST:} \left\{ \begin{array}{l} \left\{ \left\{ LD_{\text{time}, 1}, \dots, LD_{\text{time}, M_1} \right\} \right. \\ \left. \left\{ LD_{\text{space}, 1}, \dots, LD_{\text{space}, M_2} \right\} \right\} \\ \left\{ \left\{ GMR_{\text{time}, 1}, \dots, GMR_{\text{time}, M_1} \right\}, \right. \\ \left. \left\{ GMR_{\text{space}, 1}, \dots, GMR_{\text{space}, M_2} \right\} \right\} \end{array} \right\} \quad (22)$$

2.2 多样性时空局部 GMR 模型的在线选择性集成

STLL 算法采用在线选择性集成策略 (online selective ensemble, OSE) 实现模型融合,主要包含 3 步,模型性能评估、模型挑选和局部预测结果融合。

1) GMR 模型性能评估。鉴于考虑到仅从单一时间或者空间视角构造验证集,描述当前状态存在较大的局限性^[27-28]。为此,本文采用时空验证集对模型性能进行评估。首先选取 \mathbf{x}_{new} 最近一段时间的数据集,然后从中使用 ED 相似度获得时空验证集 $\mathbf{Z}_{\text{sim}} = [\mathbf{X}_{\text{sim}}, \mathbf{y}_{\text{sim}}]$ 。最

后,计算局部模型在验证集上的预测性能:

$$J_m(\mathbf{x}_{\text{new}}) = \|\hat{\mathbf{y}}_{\text{sim}, m} - \mathbf{y}_{\text{sim}}\|^2, \quad m = 1, 2, \dots, M \quad (23)$$

2) 挑选局部 GMR 模型。将局部模型按性能指标 J_m 升序排列,挑选出性能最好的前 S ($\leq M$) 个模型参与在线集成,所选模型索引为 $\{q_1, q_2, \dots, q_S\}$, 对应的局部区域为 $\{LD_1, LD_2, \dots, LD_4, \dots, LD_S\}$ 。

3) 局部预测结果融合。本文采用 GPR^[29] 模型对 GMR 基模型进行 Stacking 集成^[30]。主要思想是:基于原始的局部区域数据集构建初级学习器,然后根据在线验证集 $\mathbf{Z}_{\text{sim}} = [\mathbf{X}_{\text{sim}}, \mathbf{y}_{\text{sim}}]$ 预测输出与实际输出数据训练次级学习器。其中,多样性 GMR 模型的预测输出作为次级学习器 GPR 模型的输入。在线预测阶段,根据所选的 S 个局部模型对 \mathbf{x}_{new} 的输出值进行预测:

$$\hat{y}_s = f_s(\mathbf{x}_{\text{new}}), \quad 1 \leq s \leq S \quad (24)$$

对于 \hat{y}_{new} 的过程输出估计值可由 \hat{y}_s 得到:

$$\hat{y}_{\text{new}} = \text{GPR}_{\text{stacking}}(\hat{\mathbf{y}}_{\text{sel}}) \quad (25)$$

式中: \hat{y}_{new} 是最终全局输出, $\hat{\mathbf{y}}_{\text{sel}} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_S]$ 为局部预测结果。

2.3 STLL 模型自适应更新

为了有效解决过程时变特性引发的模型性能退化问题,STLL 算法实施了 4 个层面的在线更新:

1) 过程建模数据库更新。采用 MW 技术及时将最新数据加入数据库中,以确保所构建的验证集能真实反映当前过程状态,从而保证模型评价结果的可靠性。

2) 集成模型更新。STLL 采用自适应集成策略。首先构造查询点 \mathbf{x}_{new} 的动态时空验证集,根据其性能指标评估局部模型对 \mathbf{x}_{new} 的预测能力,然后挑选出性能最好的部分模型用于构建 GPR Stacking 集成模型。

3) 时空局部 GMR 模型在线添加。当过程发生概念漂移时,原先构建的预测模型将难以适用于新的过程状态,在线添加新的局部模型变得十分必要^[31-33]。为此,本文提出一种基于预测误差分布 KL 散度评价的概念漂移检测及局部模型在线添加方法。具体如下:

(1) 根据离线 GMR 局部模型获得查询点 \mathbf{x}_{new} 和相邻点 \mathbf{x}_{near} 的预测误差分布。假设 M 个时空局部 GMR 模型对当前查询点 \mathbf{x}_{new} 的预测输出为 \mathbf{y}_{new} 对应预测误差为 \mathbf{e}_{new} , 同理可得 M 个时空局部 GMR 模型对相邻点 \mathbf{x}_{near} 的预测结果为 \mathbf{y}_{near} 及预测误差 $\mathbf{e}_{\text{near}} \circ \boldsymbol{\mu}_{\text{new}}, \boldsymbol{\mu}_{\text{near}}$ 和 $\boldsymbol{\Sigma}_{\text{new}}, \boldsymbol{\Sigma}_{\text{near}}$ 分别表示 $\mathbf{e}_{\text{new}}, \mathbf{e}_{\text{near}}$ 对应的均值向量和协方差矩阵。

(2) 根据 KL 散度评价两个预测误差分布之间的差异性来判别是否出现新的过程状态:

$$\text{KL}(N(\boldsymbol{\mu}_{\text{new}}, \boldsymbol{\Sigma}_{\text{new}}) \| N(\boldsymbol{\mu}_{\text{near}}, \boldsymbol{\Sigma}_{\text{near}})) = \frac{1}{2} \left\{ \log \frac{|\boldsymbol{\Sigma}_{\text{near}}|}{|\boldsymbol{\Sigma}_{\text{new}}|} - 1 + \text{tr}(\boldsymbol{\Sigma}_{\text{near}}^{-1} \boldsymbol{\Sigma}_{\text{new}}) + \left(\boldsymbol{\mu}_{\text{near}} - \boldsymbol{\mu}_{\text{new}} \right)^T \boldsymbol{\Sigma}_{\text{near}}^{-1} \left(\boldsymbol{\mu}_{\text{near}} - \boldsymbol{\mu}_{\text{new}} \right) \right\} \quad (26)$$

式中: $\text{tr}(\cdot)$ 表示矩阵迹算子。

(3) 在线添加模型。基于 KL 指标的预测误差分布变化可以看出是否出现新的过程状态。将式 (26) 获得的 KL 散度评价结果与设定阈值 ε 相比较, 如果未超过阈值, 则不需要添加局部模型; 如果超过阈值, 则表明出现了新的过程状态, 需要考虑添加新的局部模型。出现新状态后, 首先通过 MW 和 JIT 在线构建时空局部区域, 随后采用 2.1 节 1) 中的方法对添加的时空局部 GMR 模型进行冗余检测。如果冗余, 则采用新建局部模型替换冗余模型; 否则, 将新建局部模型直接加入时空模型池。

4) 模型输出偏移补偿。研究表明^[34], 在线增添模型对处理突变型时变特征较为有效, 而偏移补偿对处理缓变型时变特征具有较好效果。为此, STLL 算法采用偏移补偿技术对集成预测输出进行误差校正。通过当前的偏差 $\varepsilon_0(t)$ 和相邻时刻的总体偏移 $\varepsilon(t-1)$ 可确定 t 时刻的总体偏移 $\varepsilon(t)$:

$$\varepsilon(t) = \lambda \varepsilon_0(t) + (1 - \lambda) \varepsilon(t - 1) \quad (27)$$

式中: λ 作为一个加权参数, 代表了新旧补偿值的贡献权重, 一般可设为 0.1~0.9。若 $\varepsilon(0) = 0$ 时, 则当前时刻偏差 $\varepsilon_0(t)$ 为:

$$\varepsilon_0(t) = y(t - 1) - y_{\text{model}}(t - 1) \quad (28)$$

式中: $y(t-1)$ 和 $y_{\text{model}}(t-1)$ 分别是 $t-1$ 时刻的测量值和预测值。模型预测输出可校正为:

$$y_{\text{cor}}(t) = y_{\text{model}}(t) + \varepsilon(t) \quad (29)$$

由于上述方法的 λ 值需提前固定, 不利于处理过程变化。为此参照文献 [35] 中的自适应偏移补偿策略, λ 考虑 $\{0.1, 0.2, \dots, 0.9\}$ 中的所有权值以保证偏移补偿的有效性:

$$y_{\text{cor,avg}}(t) = \frac{1}{n - 1} \sum_{i=1}^{n_\lambda} y_{\text{cor},i}(t) \quad (30)$$

式中: $y_{\text{cor},i}$ 是第 i 个 λ 值的校正输出, n_λ 是 λ 的备选个数, $y_{\text{cor,avg}}$ 是最终的校正输出。

2.4 实施步骤

所提 STLL 自适应集成软测量方法的实施原理如图 1 所示。主要步骤如下:

1) 收集过程数据, 并完成数据预处理。主要考虑 3 方面的预处理: 基于机理分析法选取建模特征; 基于 3σ 准则剔除异常点; 基于 Z-score 归一化方法实现数据的去量纲化, 将建模数据转化为均值为 0、方差为 1 的数据, 以避免原始过程变量幅值差异太大导致较高的建模误差。

2) 采用 2.1 节的时空局部状态辨识方法对过程数据进行划分, 构建多样性的局部区域和局部 GMR 模型。

3) 当查询样本 \mathbf{x}_{new} 到来时, 采用 2.2 节所提方法完成局部 GMR 模型性能评估、挑选、自适应融合, 最后实现对 \mathbf{x}_{new} 的输出预测。

4) 当获得一个新的离线检测值时, 通过 MW 更新方

式将新样本加入到数据库中。

5) 计算 M 个时空局部 GMR 模型对查询点 \mathbf{x}_{new} 与相邻点 \mathbf{x}_{near} 的预测误差分布, 并通过 KL 散度评价两个误差分布的差异性。如果 KL 值指示出现新的过程状态, 则需要建立新的时空局部模型。如果新模型与历史模型不冗余, 则将其添加入局部模型池; 否则, 用最新局部模型替换历史冗余模型。

6) 对 STLL 的输出值进行在线偏移补偿校正。

7) 当新的查询样本 \mathbf{x}_{new} 到来时回到步骤 3)。

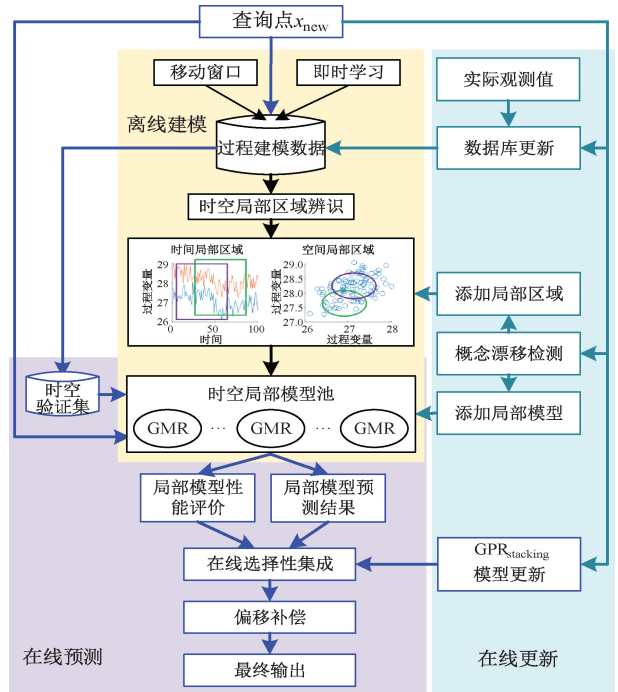


图 1 STLL 集成自适应软测量算法原理

Fig. 1 Schematic diagram of the STLL ensemble adaptive soft sensing algorithm

3 应用研究

通过脱丁烷塔过程丁烷浓度预测和金霉素发酵过程基质浓度预测两个工业案例验证了 STLL 软测量方法的有效性和优越性。实验中比较了如下方法:

- 1) GPR: 全局 GPR 模型。
- 2) GMR: 全局 GMR 模型。
- 3) JITGMR: 即时学习 GMR 模型。
- 4) EGMR: 基于时空局部模型的全集成 GMR 模型。考虑了两种集成策略, EGMR_A 采用简单平均法, EGMR_B 采用 GPR Stacking 集成。
- 5) OSEGMR: 在线选择性集成 GMR, 验证集基于样本空间相关性构造。对比了两种集成策略, OSEGMR_A 采用简单平均法, OSEGMR_B 采用 GPR stacking 集成。

6) STLL_A: 基于时空验证集的 GPR Stacking 选择性集成。

7) STLL_B: 在 STLL_A 的基础上考虑了偏移补偿策略。

8) STLL_C: 在 STLL_A 的基础上考虑了在线添加模型。

9) TLL: 本文提出方法的退化版, 仅使用 MW 技术构建时间局部模型。

10) SLL: 本文提出方法的退化版, 仅使用 JIT 技术构建空间局部模型。

11) STLL (本文提出方法): 构建时空局部模型用于集成建模, 考虑动态验证集集成修剪, 概念漂移检测, 模型在线添加, 偏移补偿。

模型性能评价指标为均方根误差 (RMSE) 和决定系数 (R^2):

$$RMSE = \sqrt{\frac{1}{N_{\text{test}}} \sum_{n=1}^{N_{\text{test}}} (\hat{y}_i - y_i)^2} \quad (31)$$

$$R^2 = 1 - \frac{\sum_{n=1}^{N_{\text{test}}} (\hat{y}_i - y_i)^2}{\sum_{n=1}^{N_{\text{test}}} (y_i - \bar{y})^2} \quad (32)$$

其中, N_{test} 为测试样本数目; \hat{y}_i 和 y_i 分别为估计值、实际值, \bar{y} 为实际观测值的均值。

3.1 工业脱丁烷塔过程

1) 过程描述

脱丁烷塔作为工业炼油中分离脱硫和石脑油的重要装置, 主要目的是去除石脑油气体中的丙烷和丁烷^[36]。在生产过程中需将底部丁烷浓度最小化, 才能实现该过程的有效控制。其中, 脱丁烷塔过程中有 7 个重要的过程变量可实时监测, 分别为塔顶温度 (x_1)、塔顶压力 (x_2)、塔顶回流量 (x_3)、塔顶产品流出量 (x_4)、第 6 层塔板温度 (x_5)、塔低温度 1 (x_6)、塔底温度 2 (x_7)。但是, 通过气相色谱仪进行分析得到的底部丁烷含量测量结果往往具有较大的滞后性。为保障在线预测的及时性可通过软测量方法对丁烷浓度进行实时预测。为此, 将 7 个过程变量选为模型输入变量, 构建丁烷浓度软测量模型。脱丁烷塔过程数据可以从 <http://www.springer.com/1-84628-479-1> 下载。

鉴于脱丁烷塔过程的动态特性, 输入变量基于延迟和非延迟变量构造, 表示为 $\mathbf{x}' = [\mathbf{x}(t)^T, \dots, \mathbf{x}(t - \tau)^T]^T$, 式中 T 为采样周期, τ 为最大延迟周期数。本研究中 τ 选为 6, 共获得 2 388 个建模样本, 每个样本包含 49 个输入变量。随后将建模数据划分成 2 组: 1 200 个样本用于模型离线训练, 1 188 个样本用于模型在线测试。

2) 实验结果及讨论

表 1 比较了不同软测量方法对丁烷浓度的预测性能。可以发现, 全局模型中 GMR 的预测性能明显优于 GPR, 这主要是因为 GMR 具有多个概率密度函数能较好地拟合复杂过程数据间的非线性输入输出关系。JITGMR 通过在线反复构建局部模型, 预测性能得到了进一步提升。鉴于全局模型在处理局部过程特征和模型在线自适应更新上的不足, 构建集成软测量模型成为了一个主流方向。对比 EGMR 和 OSEGMR 可以看出, 固定权重难以获得较好的集成预测性能, 自适应策略才是最佳选择。此外, 对比 EGMR_B 模型, OSEGMR_B 预测性能下获得了稳步提升, 这主要得益于选择性集成策略的引入。相比 OSEGMR_B, STLL_A 在验证集上综合考虑样本间的时空相关性, 进一步确保了其性能的稳定性。

表 1 基于不同软测量方法的丁烷浓度预测结果
Table 1 Prediction results of butane concentration by different soft sensor methods

方法	RMSE	R^2
GPR	0.173 0	0.012 3
GMR	0.166 9	0.081 1
JITGMR	0.146 8	0.288 6
EGMR_A	0.171 6	0.028 0
EGMR_B	0.099 7	0.672 0
OSEGMR_A	0.111 0	0.593 5
OSEGMR_B	0.078 4	0.797 1
STLL_A	0.073 5	0.822 0
STLL_B	0.059 9	0.881 6
STLL_C	0.065 3	0.859 5
TLL	0.058 2	0.888 1
SLL	0.068 6	0.844 9
STLL	0.049 5	0.919 2

为了有效处理过程时变特征, 赋予软测量模型在线更新能力尤为重要。比较 STLL_B、STLL_C 和 STLL 的预测性能, 可以发现, 虽然 STLL_B 和 STLL_C 的性能都得到了显著提升, 但是 STLL 的效果更佳。这主要是因为过程时变特征中主要存在突变型和缓变型时变特征。STLL_B 引入 OC 策略擅长于处理缓变型时变行为; STLL_C 通过在线添加模型能更好地处理突变型新特征; 而 STLL 同时引入两种技术, 综合了两者的优势, 进一步提高了模型的预测性能。

从表 1 中还可看出, 尽管在同样的集成框架下, TLL 和 SLL 性能却逊色于所提方案 STLL 的性能。这一结果得益于 STLL 中多重更新策略的有效结合, 同时也说明时

空局部状态辨识方法对构造多样性基模型更为有效。另外,如图 2 所示,以部分样本为例,不同软测量方法获得的预测趋势曲线也充分说明了 STLL 方法的优越性。图 3 给出了 STLL 和全局 GMR 在所有测试样本上的的预测曲线。此外,除了预测精度,在线模型的实时性能也非常重要,STLL 算法通过使用本文提出的概念漂移检测方法有针对性地在线添加模型,有效降低了模型更新的计算复杂度。如图 4 所示,STLL 的在线预测 CPU 平均时间仅为 0.327 7 s,可有效确保其在线预测实时性。

3.2 工业金霉素发酵过程

1) 过程描述

金霉素^[37](chlortetracycline, CTC)是一种饲料抗生素添加剂,是目前养殖业中用量最大的抑菌促生长剂之一。金霉素的发酵过程一般持续 100 h,发酵罐体积

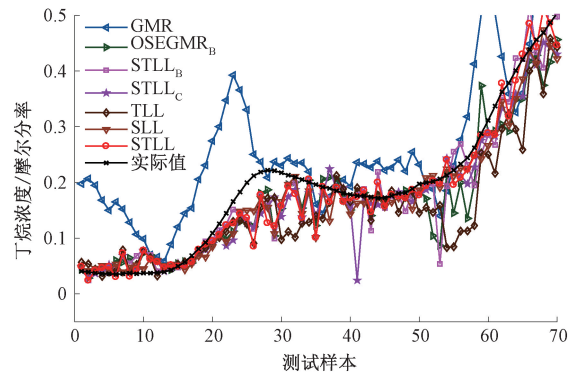


图 2 不同软测量方法对丁烷浓度的预测趋势曲线 (部分测试样本)

Fig. 2 Trend plots of butane concentration prediction using different soft sensing methods (part of test samples)




图 3 基于 GMR 和 STLL 方法的丁烷浓度预测趋势曲线

Fig. 3 Trend plots of butane concentration prediction using GMR and STLL methods




图 4 基于 STLL 方法的丁烷浓度预测 CPU 时间曲线

Fig. 4 CPU time curve for butane concentration prediction based on the STLL method

为 136 m³。金霉素发酵过程主要包含 5 个被控参数:温度、pH、溶解氧浓度、泡沫液位和基质浓度。目前,前 4 种参数均实现了在线检测,而基质浓度依然采用人工采样分析获得,并且离线分析通常需要 4~6 h,造成了大量滞后,严重阻碍了发酵过程的自动化水平。为此,以表 2 中的易测辅助变量作为模型的输入变量,基质浓度

作为模型的输出变量,进而实现基质浓度的在线实时估计。共收集 82 个批次数据,其中训练集 55 批,共 1 366 个样本;测试集 27 批,共 615 个样本。

表 2 工业金霉素发酵过程软测量模型输入变量
Table 2 Input variables for soft sensor development of industrial chlortetracycline fermentation process

序号	变量	单位
1	发酵时间	min
2	温度	℃
3	pH	—
4	溶解氧浓度	%
5	空气流量	m ³ /h
6	空气消耗量	m ³
7	补料速率	L/h
8	基质消耗量	L
9	氨水消耗量	L
10	发酵体积	m ³

2) 实验结果及分析

表3比较了不同软测量方法对金霉素发酵过程基质浓度的预测性能。首先分析全局模型的预测性能,可看出GMR和JITGMR模型表现比GPR模型要好得多,这是因为单一概率密度函数难以有效描述复杂过程数据分布。尽管EGMR_A和EGMR_B均引入了局部学习,但它们的预测结果差异却非常大,甚至出现了恶化,这表明非自适应加权集成策略难以适应复杂的时变过程,同时也说明了基模型间的预测差异比较大。与EGMR相比,OSEGMR引入在线选择性集成策略后模型的估计精度得到了进一步改善,表明选择性集成优于全集成预测。通过比较STLL_A和OSEGMR_B发现,STLL_A由于时空验证集的引入其预测性能得到了极大的提升,表明了验证集的构造方式至关重要。此外还可看出,与OSEGMR_B相比,STLL_B和STLL_C的预测性能获得了进一步提升,这主要是因为STLL_B引入了OC校正技术,STLL_C引入了模型在线添加策略。然而两者的改善幅度差异却比较大。这主要是因为金霉素发酵过程中的突变型时变问题不太突出,OC校正技术比较擅长于处理缓变型时变特征,而在线添加模型更偏向于突变型时变特征。该结果也表明仅靠局部模型在线选择和自适应加权无法有效处理过程的时变特征。接下来比较STLL算法和其退化版TLL和SLL,不难发现STLL表现最佳。这表明了多样性基模型的构建对集成模型预测性能的提升至关重要。此外,图5以单批样本为例,比较了不同软测量方法对基质浓度的预测曲线,图6比较了基于GMR和STLL方法的基质浓度预测趋势曲线。这些结果再次验证了所提方法STLL的有效性。此外,如图7所示,STLL在线预测基质浓度的CPU平均时间为0.7320s,完全满足补料优化控制的需求。

表3 基于不同软测量方法的基质浓度预测结果

Table 3 Prediction results of substrate concentration by different soft sensor methods

方法	RMSE	R^2
GPR	0.405 0	0.911 4
GMR	0.350 0	0.933 8
JITGMR	0.357 5	0.930 9
EGMR_A	0.422 9	0.903 4
EGMR_B	0.312 4	0.947 3
OSEGMR_A	0.339 0	0.937 9
OSEGMR_B	0.308 3	0.948 6
STLL_A	0.282 6	0.956 8
STLL_B	0.249 7	0.966 3
STLL_C	0.270 7	0.960 4
TLL	0.302 4	0.950 6
SLL	0.295 4	0.952 8
STLL	0.238 3	0.968 3




图5 不同软测量方法对基质浓度的预测趋势曲线(单批示例)

Fig. 5 Trend plots of substrate concentration prediction using different soft sensing methods (single batch example)

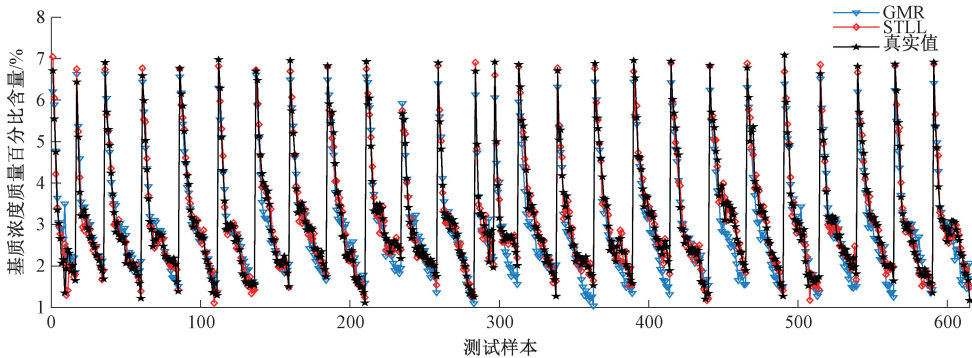


图6 基于GMR和STLL方法的基质浓度预测趋势曲线

Fig. 6 Trend plots of butane substrate prediction using GMR and STLL methods

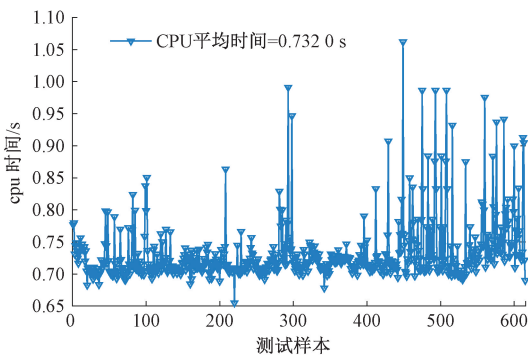


图7 基于STLL方法的基质浓度预测CPU时间曲线

Fig.7 CPU time curve for butane substrate prediction based on the STLL method

4 结 论

为实现非线性时变过程的关键质量预测,本文提出了一种融合时空局部学习及概念漂移检测的集成学习自适应软测量建模方法STLL,并通过工业脱丁烷塔过程和金霉素发酵过程两个案例进行了有效性验证。主要贡献如下:1)提出一种时空局部状态辨识方法,基于 t 检验结合MW和JIT技术从时间和空间的视角划分局部区域,有效增强了基模型的多样性,为建立高性能的集成模型奠定了基础;2)提出了一种在线选择性集成策略实现基模型的自适应融合;3)提出一种双重更新机制:首先基于概念漂移检测决定是否在线添加模型,然后引入偏移补偿技术对集成预测输出进行校正,使得STLL算法能同时有效应对缓变型和突变型时变过程特征,以确保模型保持较高的预测性能。尽管文中从时间和空间的视角构建多样性的基模型,但是如何融入其他多样性生成机制还需进一步探讨。此外,文中概念漂移检测主要从预测误差分布的变化进行识别,如何结合输入隐特征空间信息进行综合决策也是一个值得研究的问题。

参考文献

- [1] YUAN X F, GE Z Q, HUANG B, et al. A probabilistic just-in-time learning framework for soft sensor development with missing data[J]. IEEE Transactions on Control Systems Technology, 2016, 25(3): 1124-1132.
- [2] GE Z, SONG Z, DING S X, et al. Data mining and analytics in the process industry: The role of machine learning[J]. IEEE Access, 2017, 5: 20590-20616.
- [3] 徐志强,任密峰,程兰,等.基于时间近邻拉氏正则的多工况软测量回归[J].仪器仪表学报,2021,42(11): 279-287.
- XU ZH Q, REN M F, CHEN L, et al. Multi-conditions

soft sensor regression based on the time-nearest neighbor Laplacian regularization[J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 279-287.

- [4] AGUADO D, NORIEGA-HEVIA G, FERRER J, et al. PLS-based soft-sensor to predict ammonium concentration evolution in hollow fibre membrane contactors for nitrogen recovery[J]. Journal of Water Process Engineering, 2022, 47: 102735.
- [5] WANG Y, PAN Z, YUAN X, et al. A novel deep learning based fault diagnosis approach for chemical process with extended deep belief network[J]. ISA Transactions, 2020, 96: 457-467.
- [6] CHEN X, CAO W, GAN C, et al. Semi-supervised support vector regression based on data similarity and its application to rock-mechanics parameters estimation[J]. Engineering Applications of Artificial Intelligence, 2021, 104: 104317.
- [7] JIN H, CHEN X, WANG L, et al. Adaptive soft sensor development based on online ensemble Gaussian process regression for nonlinear time-varying batch processes[J]. Industrial & Engineering Chemistry Research, 2015, 54(30): 7320-7345.
- [8] 付华,赵俊程,付昱,等.基于量子粒子群与深度学习的煤矿瓦斯涌出量软测量[J].仪器仪表学报,2021, 42(4): 160-168.
- FU H, WANG J CH, FU Y, et al. Soft measurement of coal mine gas emission based on quantum-behaved particle swarm optimization and deep learning [J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 160-168.
- [9] JIN H, CHEN X, YANG J, et al. Multi-model adaptive soft sensor modeling method using local learning and online support vector regression for nonlinear time-variant batch processes [J]. Chemical Engineering Science, 2015, 131: 282-303.
- [10] 袁小锋,葛志强,宋执环.基于时间差分 and 局部加权偏最小二乘算法的过程自适应软测量建模[J].化工学报,2016,67(3): 724-728.
- YUAN X F, GE ZH Q, SONG ZH H. Adaptive soft sensor based on time difference model and locally weighted partial least squares regression [J]. CIESC Journal, 2016, 67(3): 724-728.
- [11] GOEL K, BATRA S. Two-level pruning based ensemble with abstained learners for concept drift in data streams[J]. Expert Systems, 2021, 38(3): e12661.

- [12] 汤健, 乔俊飞. 基于选择性集成核学习算法的固废焚烧过程二噁英排放浓度软测量[J]. 化工学报, 2019, 70(2): 696-706.
- TANG J, QIAO J F. Dioxin emission concentration soft measuring approach of municipal solid waste incineration based on selective ensemble kernel learning algorithm[J]. *CIESC Journal*, 2019, 70(2): 696-706.
- [13] 熊伟丽, 李妍君. 选择性集成 LTDGPR 模型的自适应软测量建模方法[J]. 化工学报, 2017, 68(3): 984-991.
- XIONG W L, LI Y J. Adaptive soft sensor based on selective ensemble of LTDGPR models[J]. *CIESC Journal*, 2017, 68(3): 984-991.
- [14] 孙子健, 汤健, 乔俊飞. 联合样本输出与特征空间的半监督概念漂移检测法及其应用[J]. 自动化学报, 2022, 48(5): 1259-1272.
- SUN Z J, TANG J, QIAO J F. Semi-supervised concept drift detection method by combining sample output space and feature space with its application[J]. *Acta Automatica Sinica*, 2022, 48(5): 1259-1272.
- [15] MU S, ZENG Y, LIU R, et al. Online dual updating with recursive PLS model and its application in predicting crystal size of purified terephthalic acid (PTA) process[J]. *Journal of Process Control*, 2006, 16(6): 557-566.
- [16] SAPTORO A. State of the art in the development of adaptive soft sensors based on just-in-time models[J]. *Procedia Chemistry*, 2014, 9: 226-234.
- [17] ALAKENT B. Online tuning of predictor weights for relevant data selection in just-in-time-learning[J]. *Chemometrics and Intelligent Laboratory Systems*, 2020, 203: 104043.
- [18] ALAKENT B. Soft sensor design using transductive moving window learner[J]. *Computers & Chemical Engineering*, 2020, 140: 106941.
- [19] LIU Y, HUANG D, LIU B, et al. Adaptive ranking based ensemble learning of Gaussian process regression models for quality-related variable prediction in process industries[J]. *Applied Soft Computing*, 2021, 101: 107060.
- [20] JIN H, LI J, WANG M, et al. Ensemble just-in-time learning-based soft sensor for mooney viscosity prediction in an industrial rubber mixing process[J]. *Advances in Polymer Technology*, 2020.
- [21] GOLDBERGER J, GORDON S, GREENSPAN H. An efficient image similarity measure based on approximations of KL-divergence between two gaussian mixtures[C]. *ICCV*, 2003, 3: 487-493.
- [22] CEDERBORG T, LI M, BARANES A, et al. Incremental local online gaussian mixture regression for imitation learning of multiple tasks[C]. *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*, IEEE, 2010: 267-274.
- [23] ZONG B, SONG Q, MIN M R, et al. Deep autoencoding gaussian mixture model for unsupervised anomaly detection[C]. *International Conference on Learning Representations*, 2018.
- [24] SHAO W, CHEN S, HARRIS C J. Adaptive soft sensor development for multi-output industrial processes based on selective ensemble learning[J]. *IEEE Access*, 2018, 6: 55628-55642.
- [25] QIU K, WANG J, WANG R, et al. Soft sensor development based on kernel dynamic time warping and a relevant vector machine for unequal-length batch processes[J]. *Expert Systems with Applications*, 2021, 182: 115223.
- [26] 金怀平, 黄思, 王莉, 等. 基于进化多目标优化的选择性集成学习软测量建模[J]. 高校化学工程学报, 2019, 33(3): 680-691.
- JIN H P, HUANG S, WANG L, et al. Selective ensemble learning based on evolutionary multi-objective optimization for soft sensor development[J]. *Chemical Journal of Chinese University*, 2019, 33(3): 680-691.
- [27] URHAN A, ALAKENT B. Integrating adaptive moving window and just-in-time learning paradigms for soft-sensor design[J]. *Neurocomputing*, 2020, 392: 23-37.
- [28] JIN H, CHEN X, YANG J, et al. Multi-model adaptive soft sensor modeling method using local learning and online support vector regression for nonlinear time-variant batch processes[J]. *Chemical Engineering Science*, 2015, 131: 282-303.
- [29] WILLIAMS C K, RASMUSSEN C E. *Gaussian processes for machine learning*[M]. Cambridge, MA: MIT press, 2006.
- [30] 金怀平, 王建军, 董守龙, 等. 基于深度学习特征提取与多目标优化集成修剪的选择性集成学习软测量方法[J/OL]. *控制与决策*: 1-13 [2022-12-27]. <http://kns.cnki.net/kcms/detail/21.1124.tp.20220102.2157.013.html>.
- JIN H P, WANG J J, DONG SH L, et al. Selective

- ensemble learning for soft sensor development based on deep learning for feature extraction and multi-objective optimization for ensemble pruning [J/OL]. *Control and Decision*; 1-13 [2022-12-27]. <http://kns.cnki.net/kcms/detail/21.1124.tp.20220102.2157.013.html>.
- [31] LIU T, CHEN S, LIANG S, et al. Selective ensemble of multiple local model learning for nonlinear and nonstationary systems [J]. *Neurocomputing*, 2020, 378: 98-111.
- [32] IWASHITA A S, PAPA J P. An overview on concept drift learning [J]. *IEEE Access*, 2018, 7: 1532-1547.
- [33] GUO F, WEI B, HUANG B. A just-in-time modeling approach for multimode soft sensor based on Gaussian mixture variational autoencoder [J]. *Computers & Chemical Engineering*, 2021, 146: 107230.
- [34] ALAKENT B. Soft-sensor design via task transferred just-in-time-learning coupled transductive moving window learner [J]. *Journal of Process Control*, 2021, 101: 52-67.
- [35] NI W, BROWN S D, MAN R. A localized adaptive soft sensor for dynamic system modeling [J]. *Chemical Engineering Science*, 2014, 111: 350-363.
- [36] FORTUNA L, GRAZIANI S, XIBILIA M G. Soft sensors for product quality monitoring in debutanizer distillation columns [J]. *Control Engineering Practice*, 2005, 13(4): 499-508.
- [37] JIN H, PAN B, CHEN X, et al. Ensemble just-in-time learning framework through evolutionary multi-objective

optimization for soft sensor development of nonlinear industrial processes [J]. *Chemometrics and Intelligent Laboratory Systems*, 2019, 184: 153-166.

作者简介



黄成, 2018年、2022年于昆明理工大学分别获得工学学士学位、硕士学位, 现为华能澜沧江水电股份有限公司工程师, 主要研究方向为过程数据解析与智能监测。

E-mail: 17308894046@163.com

Huang Cheng received his B. Sc. and M. Sc. degrees both from Kunming University of Science and Technology in 2018 and 2022, respectively. He is currently an engineer at Huaneng Lancang River Hydropower Inc. His main research interests include process data analytics, intelligent monitoring, etc.



金怀平(通信作者), 2010年、2016年于北京理工大学分别获得工学学士、博士学位, 现为昆明理工大学副教授, 主要研究方向为过程数据解析、智能制造、软测量技术与应用、机器学习与数据挖掘等。

E-mail: jinhuaiping@kust.edu.cn

Jin Huaping (Corresponding author) received his B. Sc. and Ph. D. degrees both from Beijing Institute of Technology in 2010 and 2016, respectively. He is currently an associate professor at Kunming University of Science and Technology. His main research interests include process data analytics, intelligent manufacturing, soft sensor technology and application, machine learning and data mining, etc.