

DOI: 10.11992/tis.201809040

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20190409.0946.018.html>

## 基于二阶相似度的即时学习软测量建模方法

祁成<sup>1</sup>, 史旭东<sup>1</sup>, 熊伟丽<sup>1,2</sup>

(1. 江南大学 物联网工程学院, 江苏 无锡 214122; 2. 江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122)

**摘要:** 针对即时(惰性)学习模型频率降低间接导致的精度下降问题, 提出一种二阶相似性的即时学习方法。该方法综合顾及到样本集的整体分布特性, 在传统一阶相似度准则的基础上建立二阶相似度准则, 采用与测试样本具有绝大部分相同近邻的二阶相似样本建立当前时刻的模型; 同时将累计相似度因子用于建立局部模型时样本量的确定, 并采用相似度阈值的方式判断此刻模型是否需要重新建立。该方法在青霉素发酵过程产物浓度的预测实验中得到了有效的验证。

**关键词:** 即时学习; 更新频率; 二阶相似度; 相似度准则; 一阶相似度; 局部模型; 累计相似度因子; 相似度阈值  
**中图分类号:** TP273   **文献标志码:** A   **文章编号:** 1673-4785(2020)05-0910-09

中文引用格式: 祁成, 史旭东, 熊伟丽. 基于二阶相似度的即时学习软测量建模方法[J]. 智能系统学报, 2020, 15(5): 910-918.

英文引用格式: QI Cheng, SHI Xudong, XIONG Weili. A just-in-time learning soft sensor modeling method based on the second-order similarity[J]. CAAI transactions on intelligent systems, 2020, 15(5): 910-918.

## A just-in-time learning soft sensor modeling method based on the second-order similarity

QI Cheng<sup>1</sup>, SHI Xudong<sup>1</sup>, XIONG Weili<sup>1,2</sup>

(1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China; 2. Key Laboratory of Advanced Process Control for Light Industry Jiangnan University, Ministry of Education, Wuxi 214122, China)

**Abstract:** Aiming at the indirect accuracy reduction caused by the frequency reduction of just-in-time (lazy) learning model, a second-order similarity just-in-time learning method is proposed. This method takes into account the overall distribution characteristics of the sample set, establishes a second-order similarity criterion based on the traditional first-order similarity criterion, and uses a second-order similarity sample with most of the same neighbors as the test sample to establish the model at the current time. At the same time, the cumulative similarity factor is used to determine the sample size when the local model is established, and the similarity threshold is used to determine whether the model needs to be rebuilt at this time. This method has been effectively validated in the prediction experiment of the product concentration in the fermentation process of penicillin.

**Keywords:** just-in-time learning; update frequency; second-order similarity; similarity criterion; first-order similarity; local model; cumulative similarity factor; similarity threshold

在某些复杂、环境恶劣的工业生产过程中, 由于产品可靠性要求的不断提高, 因此需要严格地监控一些直接或间接影响产品质量的关键变量。然而考虑到测量成本或者一些技术条件的

制约, 导致这些关键变量无法采用在线仪器测量获得。为了实时精确地预测这些难以测得的变量, 基于数据驱动的软测量技术<sup>[1-3]</sup>得到了快速的发展, 并逐渐地应用到了化工、制药等工业过程中。

针对某些工况容易随时间发生变化的工业过程, 传统的全局软测量模型难以满足工业过程的

收稿日期: 2018-09-21. 网络出版日期: 2019-04-10.

基金项目: 国家自然科学基金项目(61773182); 江苏省自然科学基金项目(BK20170198).

通信作者: 熊伟丽. E-mail: [greenpre@163.com](mailto:greenpre@163.com).

实时性要求且外推能力差<sup>[4]</sup>, 比较普遍的一种解决方案是采用即时学习<sup>[5-6]</sup>(just-in-time learning, JITL)策略, 对于JITL相似度准则这一核心, 学者们做出了大量的研究。Chen等<sup>[7]</sup>考虑到常见的相似度准则仅将样本的输入信息联系起来, 没有综合样本的输出信息, 因此其把输入和输出信息共同考虑构造自适应加权距离作为相似度指标; Niu等<sup>[8]</sup>结合模糊C-均值和传统的JITL这两种方法, 首先采用模糊C-均值方法重构收集的历史样本, 然后采用JITL方法在重构的历史样本集中选取当前的局部相似样本建立软测量模型。然而, 该类方法没有考虑到JITL的耗时问题, 在一些实时性要求较高的工业过程中无法有效运用。

针对上述提出的问题, Ge等<sup>[9]</sup>首先计算相邻待测样本之间的一阶相似度, 然后与相似度阈值比较判断是否更新当前时刻模型, 仿真结果表明可以有效地解决模型耗时问题。但是, 此方法忽略了过程变化较慢时产生的累计误差问题, 文献<sup>[10]</sup>将计算相邻两待测数据之间的相似度改进为计算当前时刻待测样本与前一模型更新时刻待测样本之间的相似度, 可以很好地解决累计误差问题。但是, 上述方法在选择局部样本建模时均采用的一阶相似度(first-order similarity, FOS)准则, 若只在FOS的基础上降低模型更新频率, 那么可以很好地解决模型的耗时问题, 但是局部模型的精度会有所降低。牛大鹏等<sup>[11]</sup>在文献<sup>[9]</sup>的框架上增加时序性, 同时将投影算法用于估计模型未更新时刻的输出, 取得了良好的成果。

综上, 本文在FOS选取局部样本建模的基础上, 提出一种二阶相似度(second-order similarity, SOS)准则, SOS准则既考虑到样本总体分布特性, 同时可以更有效地判断当前模型是否需要更新。对于当前到来的待测样本, 采用给定的相似度阈值判定模型是否更新, 若更新, 采用所提的SOS策略选择与待测样本邻居最多的二阶相似数据, 同时采用累积相似度因子自适应的确定局部建模样本的个数, 并将得到的二阶相似样本代入高斯过程回归(Gaussian process regress, GPR)建立当前模型, 否则, 继续采用前一更新之初的模型估计当前待测样本, 最后, 采用青霉素发酵过程对所提方法进行验证, 结果表明该方法既解决JITL耗时问题, 且提高了模型精度。

## 1 基于二阶相似度的即时学习方法

### 1.1 传统的即时学习方法

JITL是根据相似输入产生相似输出的思想,

假设有 $N$ 个历史训练样本的数据集 $X\{x_i \in \mathbb{R}^m, i=1, 2, \dots, N\}$ , 其中 $m$ 表示输入数据的维度。若预测某一时刻待测样本 $x_q$ , JITL的方式是在历史集中选择与 $x_q$ 拥有最高相似性的一组样本来构建当前的局部模型, 同时采用该模型预测 $x_q$ 。相似度准则是JITL的核心, 现对常用的FOS进行描述:

$$SI = \gamma \sqrt{\exp(-d^2)} + (1 - \gamma) \cos \theta \quad (1)$$

式中:SI表示某一时刻待测数据 $x_q$ 与训练数据 $x_i$ 之间的相似度值; $\gamma$ 表示权重系数且 $\gamma \in [0, 1]$ ;  $d$ 为两样本的欧氏距离; $\theta$ 为两样本间的夹角, 二者计算公式为

$$d = \|x_q - x_i\|_2 \quad (2)$$

$$\theta = \arccos \frac{x_q^T x_i}{\|x_q\|_2 \cdot \|x_i\|_2} \quad (3)$$

### 1.2 二阶相似度策略

#### 1.2.1 二阶相似度的定义

SOS<sup>[12]</sup>定义为: 如果两样本的一阶相似样本大多相同, 那么认为两样本拥有较高的二阶相似性。FOS准则仅关注单独两样本之间的相似度, 忽略了样本集总体的二阶相似性。如图1所示, 数据1与2的FOS很高, 数据1和8的近邻大多数相同, 因此, 二者的SOS很高, 同理数据2与8的二阶相似性也较高。假设当前到来待测数据1, 若采用FOS准则选取相似集, 仅仅选择到数据2; 但改用SOS策略时, 不仅可以选择到数据2, 还能选择到数据8。




图1 二维空间例子

Fig. 1 Two-dimensional space example

SOS算法的伪代码如下:

输入 训练样本集  $X\{x_i \in \mathbb{R}^m, i=1, 2, \dots, N\}$ , 测试样本  $x_q$

for  $i = 1 : N$

for  $j = 1 : N$

通过式(1)计算训练样本  $x_i$  和  $x_j$  之间的FOS

end for

end for

得到训练样本两两之间的相似度矩阵  $S_{N \times N}$

对列方向上进行降序排序, 得到对应的索引值矩阵  $I = [i_1 \ i_2 \ i_i \ \cdots \ i_N]$

for  $i = 1 : N$

通过式 (1) 计算测试样本  $x_q$  和训练样本  $x_i$  之间的 FOS

end for

得到  $x_q$  和  $x_i$  相似度的列向量  $S_{N \times 1}$ , 对其进行降序排序, 得到索引值向量  $i_q$ , 取  $i_q$  和  $I$  的前半行得到  $\bar{i}_q$  和  $\bar{I} = [\bar{i}_1 \ \bar{i}_2 \ \bar{i}_i \ \cdots \ \bar{i}_N]$

for  $i = 1 : N$

计算  $\bar{i}_q$  和  $\bar{i}_i$  拥有相同索引值的个数

end for

输出 索引值的个数, 即是  $x_q$  和  $x_i$  的 SOS

### 1.2.2 SOS 的特性分析

采用二维空间中的数值仿真, 进一步探讨 FOS、SOS 准则的区别及特点。图 2 为二维空间中以 3 个类别中心随机产生的三类数据集。对于“星型”标记类上一点 (3,2.3), 图 3(a)、(b) 中正方形标记框标记的样本分别是通过 FOS 与 SOS 准则选择到的, 与 FOS 准则相比, SOS 准则选择到的相似数据全是同类数据集, 这是由于 SOS 准则在选择相似数据时不仅考虑数据单点间的相似性, 而且充分考虑了数据集总体分布特征。选择同类数据建立的局部模型更合理, 精度更高。






图 2 产生的 3 类训练样本集

Fig. 2 Three types of training sample sets generated

如图 3(a) 所示, 假设当前时刻到来椭圆中“叉号”标记类的数据点, 使用 FOS 方法计算其与数据点 (3,2.3) 之间的相似度, 那么计算出来的 FOS 很高, 致使模型不会更新, 仍采用更新之初模型估计会使模型精度下降; 而将 SOS 准则用于计算其与点 (3,2.3) 的相似度, 二者的 SOS 较低, 使得模型会更新, 进而选择到的局部相似数据更合理。因此, 无论从数据集选取的角度还是从更新模型角度考虑, SOS 在某种程度上都具有优势。



(a) FOS 方法



(b) SOS 方法

图 3 FOS 方法与 SOS 方法的区别

Fig. 3 The difference between FOS and SOS

### 1.3 累计相似度因子

建立局部模型时, 数据集个数的选取也是影响 JITL 模型精度的一个重要因素。若选择的数据过多会导致信息的冗余, 失去了 JITL 相似输入产生相似输出的本意; 过少会引起信息的丢失, 这两种情况都不利于模型精度的提升。常用的解决方式是根据经验选取局部模型的数据个数, 然而这样的选取方式具有盲目性。为了有效解决这一问题, 本文引用累积相似度因子<sup>[13-14]</sup>自适应的选取相似数据的数量, 其计算公式为

$$s_k = \frac{\sum_{i=1}^k s_{qi}}{\sum_{i=1}^N s_{qi}}, 0 \leq k \leq N \quad (4)$$

式中:  $s_{qi}$  为待测数据  $x_q$  与第  $i$  个训练样本之间的相似度, 且  $s_{qi}$  是经过降序排序, 即  $s_{q1} > s_{q2} > \cdots s_{qi} \cdots > s_{qN}$ , 类似于 PCA, 取  $s_k$  的值为 0.85 或 0.9, 表示前  $k$  个最大的相似度占总相似度的贡献率, 采用这样的方式可以在避免冗余的情况下获得大部分数据信息, 比经验选取更有意义。

## 2 自适应更新机制的 GPR 模型

### 2.1 模型更新机制

针对每个新来的待测数据, JITL 都是通过选

择到的相似样本建立局部模型,并对待测数据进行估计。但是,一般的工业生产过程不会频繁发生工况变化。因此,可以继续采用之前建立好的局部模型预测工况变化较小时刻的待测样本,从而减少模型耗时。

通常通过比较两相邻样本相似度与当前阈值 (THR) 的大小来降低模型更新频率,若小于 THR,则更新模型估计当前待测数据;否则,沿用之前建立的局部模型进行估计输出。然而,当生产过程的工况变化较为缓慢时,如果仅计算相邻数据之间的相似度,可能会一直大于 THR,从而使模型未及时更新引起累计误差问题。所以,可以改进为计算当前时刻与前一模型更新时刻数据间的相似度来克服累计误差问题。详细描述如下:

1) 若当前为  $q$  时刻,经过计算且模型需要更新,当来到新的测试数据  $\mathbf{x}_q$ ,采用 1.2 节的方法从历史样本集中选择与  $\mathbf{x}_q$  SOS 最高的一批数据建立当前的 GPR 模型,同时估计  $\mathbf{x}_q$ ,并将 SOS 最高的值乘以某一数值 (参数) 用于判断之后时刻模型是否需要更新的 THR。

2) 当  $q+1$  时刻数据  $\mathbf{x}_{q+1}$  到来,计算其与  $\mathbf{x}_q$  之间的 SOS,同时与 THR 比较,若小于 THR,则更新模型进行估计,同时更新相似度阈值,否则,认为当前工况变化较小,仍采用  $q$  时刻的局部模型对  $\mathbf{x}_{q+1}$  进行估计。

3) 如果  $q+1$  未更新模型,在  $q+2$  时刻,计算测试数据  $\mathbf{x}_{q+2}$  和前一模型更新时刻数据  $\mathbf{x}_q$  之间的 SOS,其他的判断方式与  $\mathbf{x}_{q+1}$  相同。

## 2.2 GPR 建模方法

GPR 是一种非参数概率模型,已经成为机器学习领域的一种重要的建模方法,并在近些年来得到广泛关注与应用<sup>[15-17]</sup>,其基本原理描述如下。

现有历史训练数据集  $\mathbf{X}\{\mathbf{x}_i \in \mathbf{R}^m, i=1,2,\dots,N\}$  和  $\mathbf{Y}\{y_i \in \mathbf{R}, i=1,2,\dots,N\}$ , 分别代表  $m$  维输入样本和 1 维输出标签。可以采用如下的关系式表示输入与输出间的关系:

$$y_i = f(\mathbf{x}_i) + \varepsilon \quad (5)$$

式中:  $f$  为某种未知的函数;  $\varepsilon$  为均值为 0, 方差为  $\sigma_N^2$  的高斯白噪声。

对于某一待测数据  $\mathbf{x}_q$ , 它的输出预测值  $y_q$  满足高斯分布,其均值和方差可以分别表示为

$$y_q(\mathbf{x}_q) = \mathbf{c}^T(\mathbf{x}_q)\mathbf{C}^{-1}\mathbf{Y} \quad (6)$$

$$\sigma_{y_q}^2(\mathbf{x}_q) = \mathbf{c}(\mathbf{x}_q, \mathbf{x}_q) - \mathbf{c}^T(\mathbf{x}_q)\mathbf{C}^{-1}\mathbf{c}(\mathbf{x}_q) \quad (7)$$

其中,  $\mathbf{c}(\mathbf{x}_q) = [c(\mathbf{x}_q, \mathbf{x}_1), c(\mathbf{x}_q, \mathbf{x}_2), \dots, c(\mathbf{x}_q, \mathbf{x}_N)]^T$  为待测输入数据与每个历史数据协方差构成的矩阵,  $\mathbf{C} = \mathbf{\Sigma} + \sigma_N^2\mathbf{I}$  是历史输入数据自身之间的协方差矩阵,  $\mathbf{c}(\mathbf{x}_q, \mathbf{x}_q)$  为待测输入自身的协方差值。

GPR 有不同的协方差函数可以选择,本文选取径向基协方差函数,其详细描述如下:

$$c(\mathbf{x}_i, \mathbf{x}_j) = v \exp \left[ -\frac{1}{2} \sum_{t=1}^m \omega_t (\mathbf{x}_{it} - \mathbf{x}_{jt})^2 \right] + \sigma_N^2 \delta_{ij} \quad (8)$$

其中,  $v$  是先验知识的总体度量;  $\omega_t$  为第  $t$  维样本的权重;  $\delta_{ij}$  是 Kronecher 算子,代表每个辅助变量的重要程度。

通常采用极大似然估计计算式 (8) 中的参数  $\theta = [v, \sigma_N^2, \omega_1, \dots, \omega_m]$ , 其对数似然函数为

$$L(\theta) = -\frac{1}{2} \log(\det(\mathbf{C})) - \frac{1}{2} \mathbf{Y}^T \mathbf{C}^{-1} \mathbf{Y} - \frac{N}{2} \log(2\pi) \quad (9)$$

首先对超参  $\theta$  进行初始化,然后采用共轭梯度法得到优化的参数<sup>[18]</sup>。参数确定后,当来到新的待测样本,根据式 (6) 得到模型输出。

## 3 基于二阶相似度的即时学习建模步骤

基于 SOS-JITL 软测量建模流程图如图 4,具体建模步骤如下:

1) 采用式 (1) 计算历史数据相互间的 FOS,得到相似度矩阵,同时将其降序排序返回索引值矩阵  $\mathbf{I}$ 。

2) 假如当前  $q$  时刻模型需要更新,针对待测数据  $\mathbf{x}_q$ ,计算其与历史数据之间的 FOS,并返回索引值向量  $\mathbf{i}_q$ 。

3) 通过 1.2 节计算  $\bar{\mathbf{i}}_q$  与  $\bar{\mathbf{i}}_i$  间的 SOS,同时采用累积相似度因子自适应选取与  $\mathbf{x}_q$  近邻最多的一批数据建立此刻的 GPR 模型,并估计  $\mathbf{x}_q$  同时更新模型的 THR。

4) 若  $q+1$  时刻测试数据  $\mathbf{x}_{q+1}$  到来,计算其与当前模型更新之初时刻数据  $\mathbf{x}_q$  间的 SOS,并与 THR 比较,若小于 THR,如步骤 3) 更新模型和 THR,并采用新模型估计  $\mathbf{x}_{q+1}$ ,同时将  $q+1$  时刻设置为模型更新之初时刻;否则,仍采用  $q$  时刻模型估计  $\mathbf{x}_{q+1}$ 。

5) 对于  $q+n$  时刻的待测数据  $\mathbf{x}_{q+n}$ ,重复步骤 4),可得估计值  $y_{q+n}$ 。



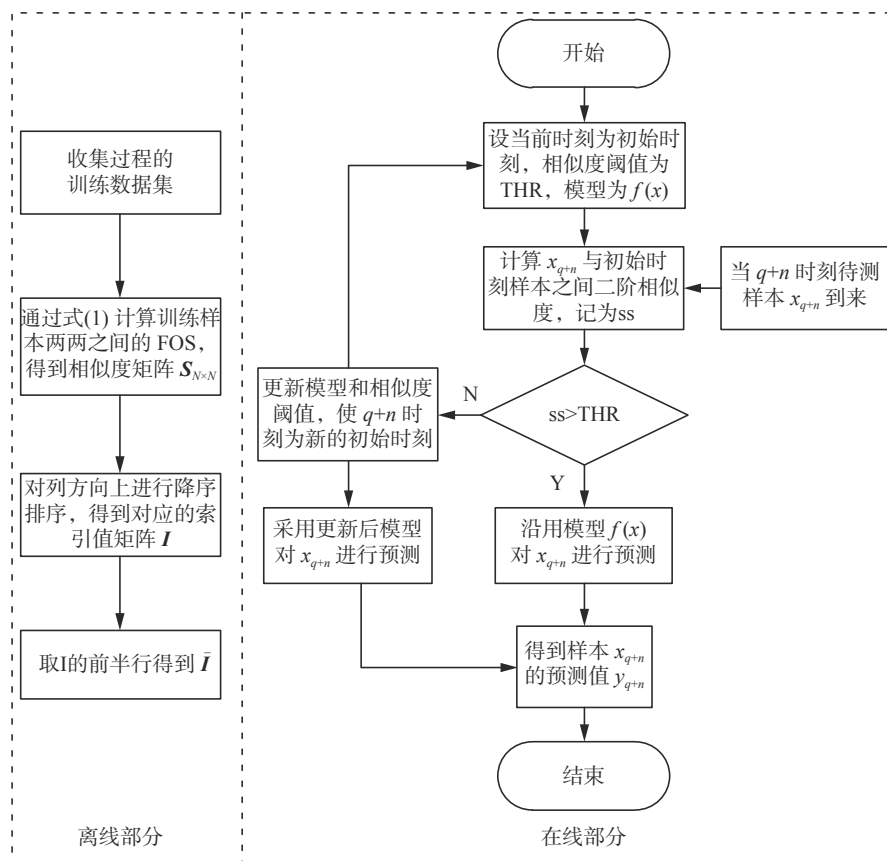


图4 基于 SOS-JITL 方法的建模流程图



Fig. 4 Modeling flow chart based on SOS-JITL method

## 4 实验仿真

青霉素产生菌在适当的温度、pH 值等外部环境条件下生长与抗生素合成这一过程称为青霉素发酵过程, 此过程分为 3 个阶段, 即产生菌生长阶段、青霉素合成阶段与产生菌的自溶阶段<sup>[19]</sup>。作为模拟青霉素发酵过程的 Pensim 仿真平台, 其包含了众多的输入变量与输出变量, 其中青霉素这一重要产物的浓度在实际发酵过程中难以测得, 因此可以采用软测量建模进行在线预测。本文采用通气速率、CO<sub>2</sub> 浓度和 pH 值等 6 个变量作为输入变量, 青霉素浓度作为输出变量, 建立软测量模型。采用 Pensim 仿真平台产生 400 组样本, 选取其中 200 组作为训练数据, 剩余的作为测试数据来验证所提方法。

为了对比建模方法的性能, 分别采用 SVM、PLS、ANN、GPR 建模方法预测青霉素浓度。其中定义 ANN 的网络层为 3 层、隐藏层节点数为 20、步长为 0.01、迭代次数为 100 次、训练目标最小误差为 0.001; SVM 采用高斯核函数。图 5 给出了 4 种方法的预测结果, 图中实线表示青霉素浓度的实际值, 虚线表示各方法的预测值。从图

中可以得到, GPR 方法的预测值更逼近于实际真值, 表明 GPR 建模方法的精度更高。







图5 4种基本建模方法的预测曲线

Fig. 5 Prediction curve of the four basic modeling methods

为了进一步分析 GPR 方法的优势,采用均方根误差<sup>[20]</sup>(RMSE)这一指标对比各种建模方法,其计算公式为

$$\text{RMSE} = \sqrt{\frac{\sum_{j=1}^M (y_j - y_j^*)^2}{M}} \quad (10)$$

式中:  $y_j$  表示第  $j$  测试样本的真实值;  $y_j^*$  为测试样本的估计值;  $M$  表示测试样本的数目。




表1给出了4种方法的RMSE,从表中可以清晰地看出本文所采用GPR方法的RMSE最小,进一步表明该方法建立的模型估计精度更高,跟踪能力更强。

表1 4种基本建模方法的RMSE  
Table 1 RMSE of the four basic modeling methods

方法/指标	RMSE
SVM	0.079 7
PLS	0.067 2
ANN	0.021 1
GPR	0.019 3

为了验证本文所提方法的预测性能,分别选取GPR方法、一阶相似度的GPR方法(简称为

JITL-GPR)、减少模型耗时的一阶相似度GPR方法(简称为RJITL-GPR)3种方法与本文方法(proposed)对比,且JITL在选取局部相似样本数目时均采用累积相似度因子。4种方法预测曲线如图6所示,将样本130~190的预测曲线进行放大,可以直观的看出,与前3种方法相比,所提方法的跟踪性能更好。4种方法的预测误差如图7所示,其中,图7(d)中的误差曲线在0处抖动幅度更小,表明该方的预测精度更高。








图6 4种方法的预测曲线


Fig. 6 Prediction curve of the four methods




(a) GPR



(b) JITL-GPR



(c) RJITL-GPR



(d) 本文方法

图7 4种方法的预测误差曲线

Fig. 7 Prediction error curve of the four methods

表2 4种方法的RMSE和建模时间

Table 2 RMSE and modeling time of the four methods

方法/指标	RMSE	建模时间/s
GPR	0.019 3	1.6
JITL-GPR	0.015 3	106.9
RJITL-GPR	0.019 5	8.4
本文方法	0.012 4	20.2

为了进一步分析所提方法的优越性,采用RMSE和模型时耗作为评价标准。表2给出了4种方法的RMSE和建模耗时。由表中的信息可以得到,与单一GPR方法相比,JITL-GPR尽管提高了模型的精度,但是建模所花费的时间太长,对于一些实时性要求较高的生产过程,该方法可能无法满足实际要求;RJITL-GPR由于降低了模型的更新频率使得建模时间大大缩短,与此同时降低了模型精度;与前3种方法对比,所提方法不仅降低了模型的时耗,同时提高了模型的精度。这是由于SOS在选择局部相似数据时,可以更合理地选取到相似数据,同时也更准确地判断模型是否更新,使当前选取的二阶相似样本建立的局部模型更适用于模型未更新时刻的数据。

## 5 结束语

从工业过程实时性角度出发,提出一种基于SOS的JITL-GPR方法,在自适应模型更新机制的框架下,采用SOS方法从历史数据中选取与当前待测数据用于更多邻居的样本建立此时的局部GPR模型,同时引入累计相似度因子优化局部模型的样本数目。与FOS准则相比,SOS准则在选取相似样本时,既关注了两数据单点间的相似

度,同时也考虑了单个数据与历史集总体分布特征之间的关系。因此,所提方法在选择相似样本时更合理,同时也可以更为准确地判断模型是否更新。采用青霉素发酵过程中青霉素浓度对所提方法进行验证,结果表明该方法不仅减少模型的时耗,同时提高了模型的精度。

## 参考文献:

- [1] 汤健,柴天佑,刘卓,等. 基于更新样本智能识别算法的自适应集成建模[J]. 自动化学报, 2016, 42(7): 1040–1052.  
TANG Jian, CHAI Tianyou, LIU Zhuo, et al. Adaptive ensemble modelling approach based on updating sample intelligent identification[J]. Acta automatica sinica, 2016, 42(7): 1040–1052.
- [2] ZHENG Junhua, SONG Zhihuan. Semisupervised learning for probabilistic partial least squares regression model and soft sensor application[J]. Journal of process control, 2018, 64: 123–131.
- [3] LI Han, YOU Shijun, ZHANG Huan, et al. Analyzing the impact of heating emissions on air quality index based on principal component regression[J]. Journal of cleaner production, 2018, 171: 1577–1592.
- [4] ZHENG Jianqiao, WANG Hongfang, ZHOU Hongpeng, et al. A using of just-in-time learning based data driven method in continuous stirred tank heater[C]//Proceedings of the 7th International Conference on Intelligent Control and Information Processing. Siem Reap, Cambodia, 2016: 98–104.
- [5] PENG Xin, TANG Yang, HE Wangli, et al. A just-in-time learning based monitoring and classification method for hyper/hypocalcemia diagnosis[J]. IEEE/ACM transactions on computational biology and bioinformatics, 2018, 15(3): 788–801.
- [6] YIN Shen, GAO Huijun, QIU Jianbin, et al. Fault detection for nonlinear process with deterministic disturbances: a just-in-time learning based data driven method[J]. IEEE transactions on cybernetics, 2017, 47(11): 3649–3657.
- [7] CHEN Kun, LIU Yi. Adaptive weighting just-in-time-learning quality prediction model for an industrial blast furnace[J]. ISIJ international, 2017, 57(1): 107–113.
- [8] NIU Dapeng, GAO Huiyuan, LIU Yuanqing. Modeling of penicillin fermentation process based on FCM and improved Just-in-Time learning algorithm[C]//Proceedings of the 36th Chinese Control Conference. Dalian, China, 2017: 10328–10332.
- [9] GE Zhiqiang, SONG Zhihuan. A comparative study of just-in-time-learning based methods for online soft sensor modeling[J]. Chemometrics and intelligent laboratory systems, 2010, 104(2): 306–317.
- [10] 张宏伟,李鹏飞,景军锋,等. 基于即时学习的软测量建模实时性改进[J]. 西安工程大学学报, 2014, 28(6): 750–754.  
ZHANG Hongwei, LI Pengfei, JING Junfeng, et al. A real-time performance improvement strategy of Just-In-Time-Learning based on soft sensor[J]. Journal of Xi'an Polytechnic University, 2014, 28(6): 750–754.
- [11] 牛大鹏,刘元清. 基于改进即时学习算法的湿法冶金浸出过程建模[J]. 化工学报, 2017, 68(7): 2873–2879.  
NIU Dapeng, LIU Yuanqing. Modeling hydrometallurgical leaching process based on improved just-in-time learning algorithm[J]. CIESC journal, 2017, 68(7): 2873–2879.
- [12] CRIBBIN T. Discovering latent topical structure by second-order similarity analysis[J]. Journal of the American society for information science and technology, 2011, 62(6): 1188–1207.
- [13] 刘毅,金福江,高增梁. 时变过程在线辨识的即时递推核学习方法研究[J]. 自动化学报, 2013, 39(5): 602–609.  
LIU Yi, JIN Fujiang, GAO Zengliang. Online identification of time-varying processes using just-in-time recursive kernel learning approach[J]. Acta automatica sinica, 2013, 39(5): 602–609.
- [14] LIU Yi, GAO Zengliang. Industrial melt index prediction with the ensemble anti-outlier just-in-time Gaussian process regression modeling method[J]. Journal of applied polymer science, 2015, 132(22): 41958.
- [15] WANG Haijun, GAO Xinbo, ZHANG Kaibing, et al. Single image super-resolution using Gaussian process regression with dictionary-based sampling and student-t likelihood[J]. IEEE transactions on image processing, 2017, 26(7): 3556–3568.
- [16] HAN Jianan, ZHANG Xiaoping, WANG Fang. Gaussian process regression stochastic volatility model for financial time series[J]. IEEE journal of selected topics in signal processing, 2016, 10(6): 1015–1028.
- [17] XIONG Weili, SHI Xudong. Soft sensor modeling with a selective updating strategy for Gaussian process regression based on probabilistic principle component analysis[J]. Journal of the franklin institute, 2018, 355(12): 5336–5349.
- [18] 何志昆,刘光斌,赵曦晶,等. 高斯过程回归方法综述[J]. 控制与决策, 2013, 28(8): 1121–1129, 1137.  
HE Zhikun, LIU Guangbin, ZHAO Xijing, et al. Overview of Gaussian process regression[J]. Control and decision, 2013, 28(8): 1121–1129, 1137.
- [19] YU Jie. Multiway Gaussian mixture model based adaptive kernel partial least squares regression method for soft sensor estimation and reliable quality prediction of nonlinear multiphase batch processes[J]. Industrial & engin-



engineering chemistry research, 2012, 51(40): 13227–13237.

- [20] LIU Ziwei, GE Zhiqiang, CHEN Guangjie, et al. Adaptive soft sensors for quality prediction under the framework of Bayesian network[J]. *Control engineering practice*, 2018, 72: 19–28.

#### 作者简介:



祁成, 硕士研究生, 主要研究方向为工业过程建模。



史旭东, 硕士研究生, 主要研究方向为工业过程建模。



熊伟丽, 教授, 博士。主要研究方向为复杂工业过程建模及优化、智能优化算法及应用。发表学术论文 130 余篇。

## 第三届中国智能教育大会

### The 3rd China Intelligence Education Conference (2020)

2020 年 10 月 10-11 日, 由中国人工智能学会、中国教育技术协会、中国语言智能研究中心、中国职业技术教育学会联合主办的第三届中国智能教育大会将在西安召开。本届大会的举办旨在开展政策、理论、技术、产品等多层面交流, 分析发展机遇, 总结实践得失, 并进一步探讨人工智能与教育深度融合的趋势与策略, 探索智能教育与教育均衡发展新模式, 为实现教育现代化, 迈入教育强国行列, 推动我国成为学习大国、人力资源强国和人才强国做出重要贡献, 使智能教育真正服务于国计、服务于民生, 促进我国教育的全面发展。

大会设置 9 场主题报告、10 场专题论坛, 汇集李德毅院士、戴琼海院士、郑南宁院士、吾守尔·斯拉木院士、黄维院士、王耀南院士、管晓宏院士、张建伟院士、汉斯·乌思克尔特院士、任福继院士、李明院士、孙茂松院士、李世鹏院士, 13 位中外院士在内的超百位知名专家学者, 议题覆盖大政方针、学术理论、技术创新、产品应用等多个方面, 将是一场清晰洞察未来教育全貌, 精准把握智能教育产业机遇的综合盛会。

第三届中国智能教育大会在前两届成功举办的基础上, 将进一步发挥集聚资源、展示成果、促进交流的平台作用, 汇聚人工智能及教育领域的先进思想和研究成果, 驱动教育信息化智能化发展。

(相关会议信息参见 <http://ccai.caii.cn/>)