

6-23-2021

Active Learning Intelligent Soft Sensor based on Probability Selection

Xuezhi Dai

1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China; ;

Weili Xiong

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

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Active Learning Intelligent Soft Sensor based on Probability Selection

Abstract

Abstract: Aiming at lack of tag samples and high cost of sampling tags in complex industrial processes, *an active learning algorithm based on probability selection is proposed. Firstly, unlabeled samples are performed subspace integration by using the principal component analysis. Then, the information of unlabeled samples is evaluated by the uncertainty, which is calculated based on the out put of all sub learners. And the most valuable samples are selected to mark manually. Finally, the function of unlabeled samples and labeled samples are analyzed, and the termination conditions are designed by introducing the performance index of training set.* Through simulations of industrial processes data, it is verified that the proposed method can improve the accuracy of the model while reducing the cost of marking.

Keywords

probability selection, soft sensor, sub learners, uncertainty, termination conditions

Recommended Citation

Dai Xuezhi, Xiong Weili. Active Learning Intelligent Soft Sensor based on Probability Selection[J]. Journal of System Simulation, 2021, 33(6): 1350-1357.

基于概率选择的主动学习智能软测量建模

代学志¹, 熊伟丽^{1,2}

(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: 针对复杂工业过程中有标签样本少, 样本标记成本高等问题, 提出一种基于概率选择的主动学习软测量建模方法。该方法首先采用主成分分析对无标签样本进行子空间集成; 然后基于所有子学习器的输出, 计算无标签样本的不确定度, 从而对无标签样本进行信息评估, 选取最有价值的样本进行人工标记; 最后通过分析无标签样本和有标签样本的作用, 引入训练集的性能指标完成对终止条件的设计。通过实际工业过程数据的应用仿真, 验证了所提方法在减小标记代价的同时, 还能够实现模型精度的提高。

关键词: 概率选择; 软测量; 子学习器; 不确定度; 终止条件

中图分类号: TP274

文献标志码: A

文章编号: 1004-731X(2021)06-1350-08

DOI: 10.16182/j.issn1004731x.joss.20-0093

Active Learning Intelligent Soft Sensor based on Probability Selection

Dai Xuezhi¹, Xiong Weili^{1,2}

(1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China;

2. Key Laboratory of Advanced Process Control for Light Industry (Ministry of Education), Jiangnan University, Wuxi 214122, China)

Abstract: Aiming at lack of tag samples and high cost of sampling tags in complex industrial processes, an active learning algorithm based on probability selection is proposed. Firstly, unlabeled samples are performed subspace integration by using the principal component analysis. Then, the information of unlabeled samples is evaluated by the uncertainty, which is calculated based on the out put of all sub learners. And the most valuable samples are selected to mark manually. Finally, the function of unlabeled samples and labeled samples are analyzed, and the termination conditions are designed by introducing the performance index of training set. Through simulations of industrial processes data, it is verified that the proposed method can improve the accuracy of the model while reducing the cost of marking.

Keywords: probability selection; soft sensor; sub learners; uncertainty; termination conditions

引言

在复杂工业过程中, 一些过程变量的实时监测与控制对工业生产至关重要, 但由于现有技术条件的限制, 使得这些变量很难通过传感器在线测得^[1]。为了实时精确估计这些变量, 软测量技术得到快速发展。常用的软测量模型包括主成分回归(Principal Component Regression, PCR)^[2]、偏最小二乘回归(Partial Least Squares Regression,

PLSR)^[3-4]、支持向量机(Support Vector Machine, SVM)^[5-6]、人工神经网络(Artificial Neural Network, ANN)^[7-8]和高斯过程回归(Gaussian Process Regression, GPR)等。其中, GPR是基于贝叶斯理论发展起来的建模方法, 能够有效地处理复杂回归问题^[9]。

软测量模型基于输入变量和输出变量构建, 其中输入变量可以通过传感器精确测得, 然而, 由于

收稿日期: 2020-02-27 修回日期: 2020-04-29

基金项目: 国家自然科学基金(61773182); 国家重点研发计划子课题(2018YFC1603705-03); 江苏高校“青蓝工程”

第一作者: 代学志(1995-), 男, 硕士生, 研究方向为复杂工业过程建模。E-mail: 2735864271@qq.com

工业现场的恶劣环境以及经济成本的制约,使得输出变量难以直接检测。因此,工业过程中存在大量的无标签数据和有限的有标签数据。传统的软测量模型仅采用有标签样本集建模,没有利用无标签样本集中的信息,而半监督学习通过把有标签样本和无标签样本同时用于建模,很好地解决了该问题。传统的半监督学习方法包括自训练^[10]、协同训练^[11]、概率生成模型^[12]和图半监督学习^[13]等。半监督学习尽管在一定程度上提升了模型性能,但一般不考虑专家知识,导致模型精度可能仍然无法满足工业生产需要。而主动学习可以根据专家知识对无标签样本进行标记,从而辅助有标签样本进行学习,进一步改善了模型性能。其核心思想是利用较少的人工标记数据获取模型性能提升^[14]。因此,如何从无标签样本集中挑选出对改善模型性能发挥作用的样本,成为主动学习的关键问题。

主动学习作为一种有效的提升模型性能的方法,近年来受到众多学者的研究^[15]。已有相关研究将主动学习用于软测量建模^[16]中,文献[17]提出了一种基于 T^2 和 SPE 统计量的主动学习软测量方法,并在脱丁烷塔的丁烷浓度检测中取得了较好效果。文献[18]将高斯过程回归的预测方差作为评价指标,有效地进行了主动学习的样本评估。然而上述方法仅局限于主成分分析和高斯过程回归模型,适用范围较小。文献[19]通过分析样本间的相互关系,提出一种基于近似线性依靠的主动学习方法,并在硫回收过程中取得了良好的效果。文献[20]利用偏差指标度量无标签样本信息,但是该方法容易受到初始样本集的影响,造成样本评估的偏差。

综上所述,本文提出一种基于概率选择思想的主动学习软测量算法。首先利用 PCA 对训练集进行子空间集成,同时建立相应的 GPR 子学习器,并基于所有子学习器的预测输出,计算无标签样本的不确定度,挑选出合适的无标签样本进行标记,用来更新训练集和软测量模型;其次,利用更新后的标记数据重新优化软测量模型和子学习器,计算训练集的性能指标,并利用该指标

完成对终止条件的设计。所提方法综合考虑了无标签样本的概率选择和训练集的性能指标,能够合理地标记数据,并及时终止迭代过程,从而以最小标记代价提升训练模型的预测性能。

1 高斯过程回归

高斯过程回归是一种基于高斯过程的机器学习算法,对处理高维度、非线性和小样本等问题具有很好的效果^[9,21]。已知训练样本集为 $\{\mathbf{X}, \mathbf{y}\}$, 其中输入 $\mathbf{X} = \{\mathbf{x}_i \in \mathbf{R}^m\}_{i=1,2,\dots,n}$, 输出 $\mathbf{y} = \{y_i \in \mathbf{R}\}_{i=1,2,\dots,n}$, n 为样本个数, m 为辅助变量个数。输入与输出之间的回归关系可以表示为

$$\mathbf{y} = f(\mathbf{x}) + \varepsilon \quad (1)$$

f 为未知函数形式, ε 是均值为 0, 方差为 δ^2 的高斯噪声。并假设回归函数是均值为 0 的高斯先验函数, 即

$$\mathbf{y} = [f(\mathbf{x}_1), f(\mathbf{x}_2), \dots, f(\mathbf{x}_n)] \sim GP(\boldsymbol{\theta}, \mathbf{K}) \quad (2)$$

式中: \mathbf{K} 为协方差矩阵, $\mathbf{K}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$, 本文选取平方指数函数来构建协方差函数:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \delta_f^2 \exp\left[-\frac{(\mathbf{x}_i - \mathbf{x}_j)^T (\mathbf{x}_i - \mathbf{x}_j)}{2l^2}\right] + \delta_y \delta_n^2 \quad (3)$$

式中: δ_f 为信号标准差; l 为尺度参数; δ_n 为噪声标准差, $i = j$ 时 $\delta_{ij} = 1$, 否则 $\delta_{ij} = 0$ 。 $\boldsymbol{\theta} = \{\delta_f^2, l^2, \delta_n^2\}$ 为 GPR 的超参数, 利用最大似然估计可以求得

$$L(\boldsymbol{\theta}) = -\frac{n}{2} \ln(2\pi) - \frac{1}{2} \ln(\det(\mathbf{K})) - \frac{1}{2} \mathbf{y}^T \mathbf{K}^{-1} \mathbf{y} \quad (4)$$

对于测试样本 \mathbf{x}_q , 其对应的均值和方差为

$$\mathbf{y}_q = \mathbf{k}_q^T \mathbf{K}^{-1} \mathbf{y} \quad (5)$$

$$\delta_{y_q}^2 = k(\mathbf{x}_q, \mathbf{x}_q) - \mathbf{k}_q^T \mathbf{K}^{-1} \mathbf{k}_q \quad (6)$$

式中: $\mathbf{k}_q = [k(\mathbf{x}_q, \mathbf{x}_1), k(\mathbf{x}_q, \mathbf{x}_2), \dots, k(\mathbf{x}_q, \mathbf{x}_n)]^T$ 为测试样本 \mathbf{x}_q 与训练样本集的协方差向量; $k(\mathbf{x}_q, \mathbf{x}_q)$ 为测试样本 \mathbf{x}_q 的协方差。

2 子空间集成

给定一个数据集 $\mathbf{X} \in \mathbf{R}^{n \times m}$, m 为辅助变量的个数, n 为样本个数, PCA 模型描述为

$$\mathbf{X} = \mathbf{T}\mathbf{P}^T + \mathbf{E} \quad (7)$$

其中 $\mathbf{T} \in \mathbf{R}^{n \times d}$ 和 $\mathbf{P} \in \mathbf{R}^{m \times d}$ 分别是主成分子空

间的得分矩阵和载荷矩阵， $E \in R^{n \times m}$ 为残差矩阵， d 表示划分的子空间个数。载荷矩阵可以进行如下划分：

$$P = [P_1, P_2, \dots, P_d] \quad (8)$$

第 i 个辅助变量在子空间 j 的贡献指数^[22]定义为

$$CI(i, j) = \frac{P_{ij}^2}{P_{1j}^2 + \dots + P_{ij}^2 + \dots + P_{mj}^2} \quad (9)$$

式中： $i = 1, 2, \dots, m$ ， $j = 1, 2, \dots, d$ ， P_{ij} 表示载荷矩阵的第 i 行、第 j 列元素。其中 $CI(i, j)$ 值越大，表明该变量在第 j 子空间中包含的信息越多。根据贡献指数大小对矩阵的列向量进行降序排列，较大的变量索引即被确定为子空间 j 的辅助变量。

3 基于概率选择的主动学习算法

主动学习主要是利用无标签样本信息提升模型的泛化性能，具体的学习过程是先对无标签样本进行信息评估，进而挑选出改善模型性能的样本，并将这些样本交给专家进行标记，用于更新训练集和软测量模型。

本文从样本评估和终止条件两个角度，进行主动学习算法的改进。一方面，利用无标签样本的不确定度进行样本评估；另一方面，引入训练集的性能指标完成对终止条件的设计；最终实现了以最小的标记代价最大限度地提升模型性能的目的。所提

算法具体分析如下。

3.1 子空间集成与不确定度计算

假设训练集中的有标签样本集和无标签样本集分别为 $\{X_L \in R^{n_l \times m}, y_L \in R^{n_l}\}$ 和 $\{X_U \in R^{n_u \times m}\}$ ，其中 n_l 和 n_u 分别为有标签样本集和无标签样本集样本个数， m 为辅助变量个数。

利用 PCA 对有标签样本集进行子空间划分，得到 d 个子集 $\{D_1, D_2, \dots, D_d\}$ ，然后进行 GPR 建模，得到 d 个子模型，最后对于每一个无标签样本 x_u ，都可以得到 d 个预测输出 $\{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_d\}$ 。

那么，无标签样本的不确定度可表示为

$$\delta = \frac{1}{d} \sqrt{\sum_{i=1}^d (\bar{y} - \hat{y}_i)^2} \quad (10)$$

其中：

$$\bar{y} = \frac{1}{d} \sum_{i=1}^d \hat{y}_i \quad (11)$$

利用不确定度对无标签样本进行信息评估，挑选不确定度最大的 n_s 个样本进行人工标记，记为 $\{x_s, y_s\}$ ，再将这些样本加入到有标签样本集中，用于更新训练集、软测量模型和 GPR 子学习器，而剩余的无标签样本进入新一轮的迭代，直到模型精度满足终止条件。主动学习策略的训练集更新过程如图 1 所示。

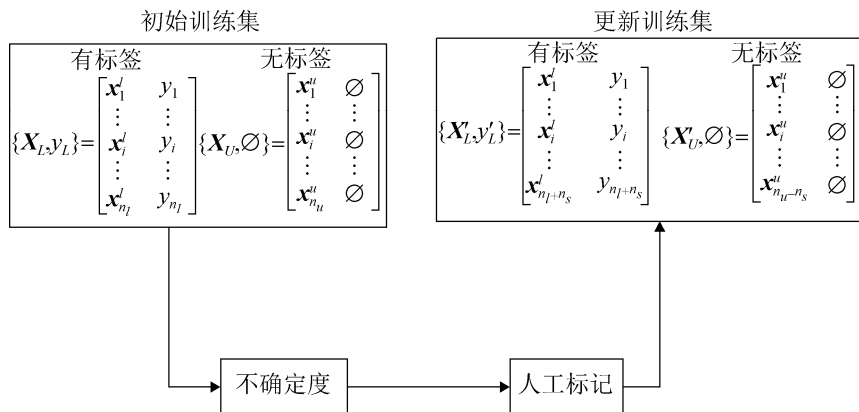


图 1 主动学习策略的训练集更新过程

Fig. 1 Training set renewal process of active learning strategy

3.2 终止条件设计

主动学习需要预设终止条件来限定算法的迭代次数, 通常采用已标记样本的均方误差(MSE)作为模型性能评估指标:

$$MSE(f(x_l, \hat{y}_l)) = \frac{1}{n_l} \sum_{i=1}^{n_l} (y_l - \hat{y}_l)^2 \quad (12)$$

式中: n_l 为已标记样本个数; y_l 和 \hat{y}_l 分别为已标记样本的真实值和估计值。由于本文采用子空间集成的方法挑选样本, 因此可以利用训练集的性能指标对终止条件进行设计:

$$const = \alpha \cdot MSE(f(x_l, \hat{y}_l)) + (1 - \alpha) \cdot var(f(x_u, \hat{y}_i)) \quad (13)$$

式中: $const$ 为训练集的性能指标; $var(f(x_u, \hat{y}_i))$ 为未标记样本在不同 GPR 子学习器上产生的方差的均值, 反映了模型变化程度; α 为 2 种性能指标的权重系数, 若 α 的取值大于 0.5, 则侧重于有标签样本对模型性能的影响; 反之, 则侧重于无标签样本对模型性能的影响。本文为了均衡 2 个训练集对模型性能的作用, 将 α 设置为 0.5。在主动学习迭代过程中, 随着训练集中已标记样本

个数的逐渐增加, $MSE(f(x_l, \hat{y}_l))$ 和 $var(f(x_u, \hat{y}_i))$ 逐渐趋于稳定, 当 $const$ 值小于设定的终止阈值时, 可终止迭代过程, 终止阈值为经验值, 可根据工业过程实际需要进行设定。

3.3 主动学习算法流程

基于主动学习策略, 通过不确定度对无标签样本进行信息评估, 并利用训练集的性能指标对终止条件进行设计。所提算法的建模流程如图 2 所示, 详细步骤如下:

- (1) 将训练集分为有标签训练集 $\{X_L \in \mathbb{R}^{n \times m}, Y_L \in \mathbb{R}^n\}$ 和无标签训练集 $\{X_U \in \mathbb{R}^{n_u \times m}\}$;
- (2) 通过子学习器的预测输出计算无标签样本的不确定度 δ , 并挑选不确定度最大的 n_s 个样本进行人工标记;
- (3) 将所挑选样本进行人工标记, 根据图 1 更新训练集, 并建立新的软测量模型和 GPR 子学习器;
- (4) 利用式(13)计算 $const$ 值, 若 $const$ 值小于终止阈值, 则主动学习结束, 否则转到(2)进入新一轮的迭代。

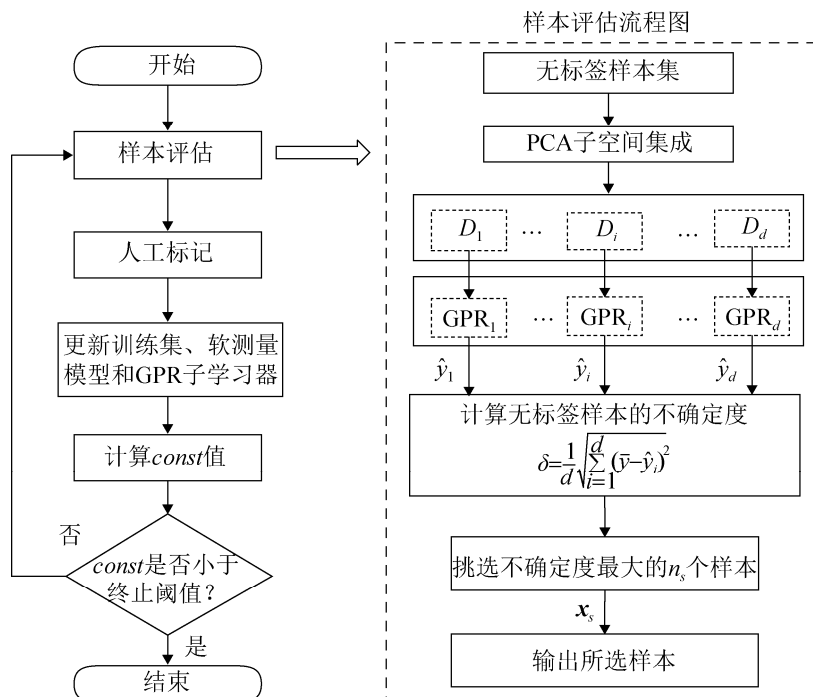


图 2 基于概率选择的主动学习算法流程图

Fig. 2 Flow chart based on probability selection active learning algorithm

4 实验仿真

为了进一步验证本文所提方法的有效性,选用硫回收过程数据作为仿真对象。硫回收装置(Sulfur

Revoery Unit, SRU)主要对含硫气体(主要含有 H₂S, SO₂)进行硫的回收,以防止对大气造成污染。其简要装置如图 3 所示,详细的工艺过程描述见文献[1],硫回收过程输入变量的具体说明如表 1 所示。




图 3 硫回收装置图
Fig. 3 Sulfur recovery unit

表 1 硫回收过程输入变量的具体说明
Tab. 1 Specific description of input variables in Sulfur recovery process

输入变量	描述
u_1	MEA_GAS 气体流
u_2	初级空气流
u_3	二级空气流
u_4	SWS 区域气体流
u_5	SWS 区域空气流

该过程共收集 1 000 组数据,从中选择 500 组数据作为训练集,500 组数据作为测试集,在训练集中,假设仅有 20 个有标签样本,480 个无标签样本,样本标签率为 4%。为了验证所提方法的优越性,将本文所提方法(Proposed)与现有的 Random、RSAL^[20]、DAL^[23]主动学习方法进行对比。其中,学习步长设置为 25,即每一次迭代过程标记 25 个样本。表 2 为 4 种主动学习方法的性能指标。图 4 为 H₂S 的均方根误差(RMSE)随迭代次数的变化。

从图 4 可以看出,随着标记样本数量的逐渐增加,4 种方法的模型性能均有所提升。其中,Random

利用随机方法挑选无标签样本,由于选择的随机性,新样本并不能对模型性能起到明显改善作用。RSAL 通过建立偏差模型挑选无标签样本进行标记,由于偏差模型精度较差,导致信息评估不准确。DAL 利用样本间欧式距离进行样本评估,获得了部分模型性能的提升,然而由于多维样本数据的关系较为复杂,DAL 很难精确度量样本信息。本文所提方法利用不确定度挑选样本,在迭代过程中,其模型精度一直高于 Random,RSAL 和 DAL,这也就意味着使用相同的标记代价,基于概率选择的主动学习算法能够使软测量模型性能提升更高。

表 2 4 种主动学习方法在标记 100 和 300 次后的性能指标
Tab. 2 Performance index of four active learning methods after marking 100 and 300 times

Method	标记样本数	均方根误差	标记样本数	均方根误差
Random	100	0.042 9	300	0.027 6
DAL	100	0.046 5	300	0.038 8
RSAL	100	0.076 2	300	0.050 1
Proposed	100	0.025 9	300	0.021 5

为了更直观地比较 4 种方法对 GPR 模型回归

性能的提升效果, 图 5 给出了各方法在第 8 次迭代时 GPR 模型的跟踪效果, 其中纵坐标为真实值与预测值之间的差值。从图 5 可以看出, 与其他 3 种方法相比, 本文方法能够更好地跟踪 H_2S 浓度的变化趋势。

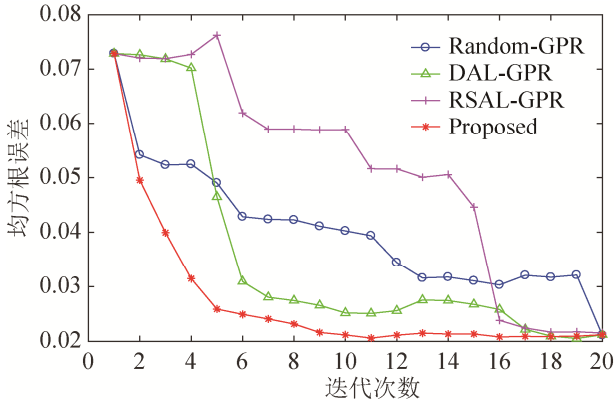


图 4 H_2S 的均方根误差随迭代次数的变化

Fig. 4 Change of RMSE of H_2S with the number of iterations

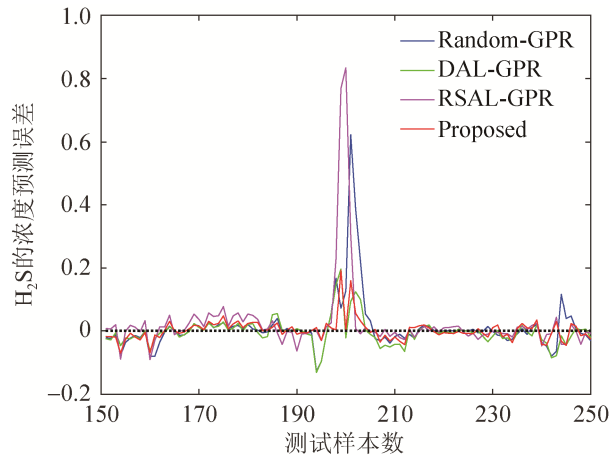



图 5 第 8 次迭代时 4 种方法预测误差对比


Fig. 5 Comparison of prediction errors of four methods in the eighth iteration

图 6 为无标签样本在第 5、第 10 和第 15 次迭代后不确定度 δ 的变化。通过对比发现, 不确定度值越来越小, 这是由于随着迭代的进行, 更多的标记样本添加到训练集中优化模型, 使得软测量模型和 GPR 子学习器的模型性能逐渐提升, 从而对无标签样本的信息评估更加准确。并且随着无标签数据集中的信息减少, 模型性能不再有明显提升。由图 4 可以看出, 第 8 次迭代后, 尽


管迭代过程还在继续, 但软测量模型性能基本保持不变。



(a) 第 5 次迭代



(b) 第 10 次迭代



(c) 第 15 次迭代

图 6 无标签样本的不确定度值的变化

Fig. 6 Uncertainty value of unlabeled samples

图 7 为主动学习的选择策略中不同学习步长对模型性能的影响, 可以看出, 随着学习步长的增加, 每次迭代过程中需要标记的样本数量增多, 从

而使更多的标记样本参与到模型更新中以改善模型性能,然而需要的标记成本也随之增加。进一步在相同标记代价的情况下,进行仿真对比,从图8可以看出,在迭代初期越小的学习步长对模型精度的提升越明显,而当标记200个样本后,不同学习步长的模型性能基本相同。




图7 在不同学习步长下 H₂S 的均方根误差随迭代次数的变化

Fig. 7 Change of RMSE of H₂S with the number of iterations under different learning steps




图8 在不同学习步长下 H₂S 的均方根误差随标记样本个数的变化

Fig. 8 Change of RMSE of H₂S with the number of labeled samples under different learning steps

图9为不同终止阈值对模型性能的影响,可以看出,随着终止阈值逐渐增大,模型精度逐渐下降。这是由于越小的终止阈值对模型性能要求越严格,从而需要标记更多的数据来提升模型性能,这就意味着标记成本的增加。因此应在不影响模型性能的前提下尽可能选择较高的终止阈值,故本实验中的终止阈值设置为 2.0×10^{-4} 。




图9 终止阈值对模型性能的影响

Fig. 9 Effect of termination threshold on model performance

5 结论

本文提出了一种基于概率选择的主动学习建模方法,主要从样本评估和终止条件两个方面进行了研究。一方面利用不确定度对无标签样本进行信息评估,挑选不确定度较大的样本进行人工标记,并结合已标记样本优化软测量模型;另一方面基于有标签样本集和无标签样本集的作用,利用两者的性能指标完成终止条件的设计。仿真结果表明,所提方法在有标签样本较少时,能够以最小的标记代价提升模型性能,为软测量建模提供了新思路。在下一步工作中,将研究如何结合 GPR 模型本身,进一步优化从概率角度考虑无标签样本评估策略。

参考文献:

- [1] Fortuna L, Graziani S, Rizzo A, et al. Soft Sensors for Monitoring and Control of Industrial Processes[M]. Berlin: Springer Science & Business Media, 2007.
- [2] Wang H Z, Yu J S. Studies on Soft Sensor Modeling Using Mixtures of Kernels PCR[J]. Control and Instruments in Chemical Industry (S1000-3932), 2005, 32(2): 23-25.
- [3] Shao W M, Tian X M. Adaptive Soft Sensor for Quality Prediction of Chemical Processes based on Selective Ensemble of Local Partial Least Squares Models[J]. Chemical Engineering Research and Design (S0263-8762), 2015, 95: 113-132.
- [4] 汤健, 柴天佑, 余文, 等. 在线 KPLS 建模方法及在磨

- 机负荷参数集成建模中的应用[J]. 自动化学报, 2013, 39(5): 471-486.
- Tang Jian, Chai Tianyou, Yu Wen, et al. On-line KPLS Algorithm with Application to Ensemble Modeling Parameters of Mill Load[J]. Acta Automatica Sinica, 2013, 39(5): 471-486.
- [5] 郑小霞, 钱锋. 基于 PCA 和最小二乘支持向量机的软测量建模[J]. 系统仿真学报, 2006, 18(3): 217-219.
- Zheng Xiaoxia, Qian Feng. Soft Sensor Modeling Based on PCA and Support Vector Machines[J]. Journal of System Simulation, 2006, 18(3): 217-219.
- [6] Zhang S, Wang F, He D, et al. Online Quality Prediction for Cobalt Oxalate Synthesis Process using Least Squares Support Vector Regression Approach with Dual Updating[J]. Control Engineering Practice (S0967-0661), 2013, 21(10): 1267-1276.
- [7] Zhang Z, Wang T, Liu X. Melt Index Prediction by Aggregated RBF Neural Networks Trained with Chaotic Theory[J]. Neurocomputing (S0925-2312), 2014, 131(9): 368-376.
- [8] 杨尔辅, 周强, 胡益锋, 等. 基于 PCA-RBF 神经网络的工业裂解炉收率在线预测软测量方法[J]. 系统仿真学报, 2001, 13(增 1): 194-197.
- Yang Erfu, Zhou Qiang, HU Yifeng, et al. A Soft-sensing Approach to On-line Predict the Yields of Industrial Pyrolysis Furnace Based on PCA-RBF Neural Networks[J]. Journal of System Simulation, 2001, 13(S1): 194-197.
- [9] 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(8): 1121-1129.
- He Zhikun, Liu Guangbin, Zhao Xinjing, et al. Overview of Gaussian Process Regression[J]. Control and Decision, 2013(8): 1121-1129.
- [10] 曲昭伟, 吴春叶, 王晓茹. 半监督自训练的方面提取[J]. 智能系统学报, 2019, 14(4): 635-641.
- Qu Zhaowei, Wu Chunye, Wang Xiaoru. Aspects Extraction based on Semi-supervised Self-training[J]. CAAI Transactions on Intelligent Systems, 2019, 14(4): 635-641.
- [11] Zhou Z H, Li M. Semi-supervised Regression with Cotraining-style Algorithms[J]. IEEE Transactions on Knowledge & Data Engineering (S1041-4347), 2007, 19(11): 1479-1493.
- [12] Deng J, Xie L, Chen L, et al. Development and Industrial Application of Soft Sensors with Online Bayesian Model Updating Strategy[J]. Journal of Process Control (S0959-1524), 2013, 23(3): 317-325.
- [13] Huang G, Song S, Gupta J N D, et al. Semi-Supervised and Unsupervised Extreme Learning Machines [J]. IEEE Transactions on Cybernetics (S1083-4419), 2017, 44(12): 2405-2417.
- [14] Cohn D A, Ghahramani Z, Jordan M I. Active Learning with Statistical Models[J]. Journal of Artificial Intelligence Research (S1076-9757), 1996, 4(1): 705-712.
- [15] Zhou Z H, Li M. Semi-supervised Learning by Disagreement[J]. Knowledge and Information Systems (S 0219-1377), 2010, 24(3): 415-439.
- [16] Tang Q, Li D, Xi Y. A New Active Learning Strategy for Soft Sensor Modeling based on Feature Reconstruction and Uncertainty Evaluation[J]. Chemometrics and Intelligent Laboratory Systems (S0169-7439), 2018, 172: 43-51.
- [17] Ge Z Q. Active Learning Strategy for Smart Soft Sensor Development under a Small Number of Labeled Data Samples[J]. Journal of Process Control (S0959-1524), 2014, 24(9): 1454-1461.
- [18] Ge Z Q. Active Probabilistic Sample Selection for Intelligent Soft Sensing of Industrial Processes[J]. Chemometrics and Intelligent Laboratory Systems (S0169-7439), 2016, 151: 181-189.
- [19] Shi X D, Xiong W L. Approximate Linear Dependence Criteria with Active Learning for Smart Soft Sensor Design[J]. Chemometrics and Intelligent Laboratory Systems (S0169-7439), 2018, 180: 88-95.
- [20] Douak F, Melgani F, Benoudjit N. Kernel Ridge Regression with Active Learning for Wind Speed Prediction[J]. Applied Energy (S0306-2619), 2013, 103(5): 328-340.
- [21] 熊伟丽, 张伟, 徐保国. 一种基于 EGMM 的高斯过程回归软测量建模[J]. 信息与控制, 2016, 45(1): 14-19.
- Xiong Weili, Zhang Wei, Xu Baoguo. A Soft Sensor Modeling Method Based on EGMM Using Gaussian Process Regression[J]. Information and Control, 2016, 45(1): 14-19.
- [22] Ge Z Q, Song Z H. Subspace Partial Least Squares Model for Multivariate Spectroscopic Calibration[J]. Chemometrics and Intelligent Laboratory Systems (S0169-7439), 2013, 125(Complete): 51-57.
- [23] Douaka F, Melgania F, Alajlanc N, et al. Active Learning for Spectroscopic Data Regression[J]. Journal of Chemometrics (S0886-9383), 2012, 26(7): 374-383.