

基于证据合成规则的多模型软测量

唐 苦¹, 王 昕², 王振雷^{1†}

(1. 华东理工大学 化工过程先进控制和优化技术教育部重点实验室, 上海 200237; 2. 上海交通大学 电工与电子技术中心, 上海 200240)

摘要: 针对传统软测量方法存在的预测性能差、融合能力低和适应性不强等缺点, 本文提出了一种基于证据(D-S)合成规则的多模型软测量方法. 首先, 利用仿射传播(AP)聚类方法和最小二乘支持向量机(LS-SVM)建立多个子模型; 然后, 利用D-S合成规则得到多个证据概率分配函数, 将其作为权值因子对子模型输出进行融合得到多模型的输出, 提高了模型的预测能力和融合能力; 最后, 将上述方法用于非线性系统和酯化率的软测量建模, 仿真结果表明, 相比于单一模型和传统的多模型软测量方法, 本文方法具有更好的预测性能和精度, 是一种有效的软测量方法.

关键词: 证据合成规则; 多模型; 数据融合; 仿射传播聚类; 软测量

中图分类号: TP273 **文献标识码:** A

Multi-model soft sensor based on Dempster-Shafer rule

TANG Ku¹, WANG Xin², WANG Zhen-lei^{1†}

(1. Key Laboratory of Advanced Control and Optimization for Chemical Processes,
East China University of Science and Technology, Shanghai 200237, China;

2. Center of Electrical & Electronic Technology, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: There are disadvantages in traditional model methods for the soft sensor, such as low predictive accuracy, poor fusion ability and weak adaptability. In this paper, a multi-model soft sensor method is proposed based on Dempster-Shafer (D-S) rule. Firstly, the affinity propagation (AP) clustering method and the least squares support vector machine (LS-SVM) are used to establish multiple sub-models. Then, the multi-model output of the soft sensor is obtained through the fusion of the sub-models based on the weighting factor calculated by using D-S rules to improve the model prediction ability and fusion ability. The proposed method is used to build the soft sensor model of a nonlinear system and the ester rate. Simulation results and industry application indicate that the proposed method has better predictive performance and higher accuracy in comparison with the traditional soft sensor

Key words: Dempster-Shafer rule; multi-model; data fuse; affinity propagation cluster; soft sensor

1 引言(Introduction)

在化工生产过程中, 受工艺和技术的限制, 基于单一模型的软测量方法效果并不理想, 存在过程特性匹配不佳、预测精度低等问题. 基于聚类的多模型软测量方法通过将几个模型相加, 可以显著提高模型的预测精度和泛化性能^[1-3]. 文献[4]给出一种多模型软测量方法, 将流形学习思想运用于聚类中, 然后通过开关切换的方法得到各子模型的输出. 文献[5-7]利用仿射传播(affinity propagation, AP)聚类方法对样本聚类后, 通过切换策略选择相应的子模型预测变量最终输出. 文献[8]通过改进的FCM和加权bagging来改善多模型的预测精度. 但是上述基于切换策略得到多模型输出的方法仅适用于局部线性系统中, 而实际流程工

业生产过程往往具有强非线性, 工况复杂和控制性能要求高等特点, 此时使用该方法容易产生切换震荡现象; 此外, 在预测新测试样本的输出时, 直接通过简单计算测试样本与训练样本中各聚类中心的距离来判断测试样本所属的类别, 会出现错误划分的情况, 这会使得后面直接利用相应的子模型去预测样本最终输出的准确度大大降低.

针对上述问题, 本文提出了基于证据合成规则(Dempster-Shafer rule, D-S rule)的多模型软测量方法. 首先利用D-S合成规则处理不确定信息的聚焦优势, 针对AP聚类得到的各子模型建立了多个证据概率分配函数, 然后将其作为子模型的权值因子, 对各子模型的输出进行加权融合得到测试样本的多模型输

出, 避免了切换方式引起的震荡, 消除了样本错误划分对模型输出精度的影响, 提高了模型的预测能力, 最后, 利用本文方法对非线性系统取得了很好的预测效果, 与传统的软测量方法相比, 预测能力和动态性能有了较大改善. 文末, 在化工过程酯化反应中进行应用研究, 实际应用结果证明了该方法的有效性.

2 仿射传播聚类(Affinity propagation clustering)

多模型建模步骤为: 子数据集划分、子模型建立和多模型的输出. 与k-means、模糊C-均值等方法相比, AP聚类方法有两个优点: 一是它不需事先给出聚类个数, 各样本点迭代竞争聚类中心, 达到最优聚类结果; 二是它能更好地根据数据自身的特性聚类, 使聚类结果更加吻合对象特征. 因此本节利用仿射传播(AP)聚类方法和最小二乘支持向量机(LS-SVM)对训练样本数据集进行聚类并建立多个子模型. 对训练样本集 $\mathbf{X} = \{\mathbf{x}_i, i = 1, \dots, n\}$, AP算法首先算出 n 个数据点之间的相似度矩阵 $\mathbf{S}_{n \times n}$, 然后, 不断从各数据点 \mathbf{x}_i 为各候选的聚类中心 \mathbf{v}_j 搜集证据, 同时也从候选的聚类中心 \mathbf{v}_j 中为数据点 \mathbf{x}_i 搜寻证据, 这两个证据参数的定义分别为

$$\mathbf{R}(i, j) = \mathbf{S}(i, j) - \max\{\mathbf{A}(i, k) + \mathbf{S}(i, k)\},$$

$$k = 1, \dots, n, k \neq j, \quad (1)$$

$$\mathbf{A}(i, j) = \min\{0, \mathbf{R}(i, j) + \sum_k \{\max(0, \mathbf{R}(k, j))\}\},$$

$$k = 1, \dots, n, k \neq i, j, \quad (2)$$

其中: $\mathbf{R}(i, j)$ 表示 \mathbf{x}_j 适合作为 \mathbf{x}_i 的聚类中心的程度, $\mathbf{A}(i, j)$ 表示 \mathbf{x}_i 选择 \mathbf{x}_j 作为其聚类中心的适合程度. $\mathbf{R}(i, j)$ 和 $\mathbf{A}(i, j)$ 越大, 则 \mathbf{x}_j 作为聚类中心的可能性就越大. 在 $\mathbf{R}(i, j)$ 和 $\mathbf{A}(i, j)$ 的基础上, 其更新公式为

$$\mathbf{R}^{\text{new}}(i, j) = (1 - \lambda)\mathbf{R}^{\text{old}}(i, j) + \lambda\mathbf{R}^{\text{old}}(i, j), \quad (3)$$

$$\mathbf{A}^{\text{new}}(i, j) = (1 - \lambda)\mathbf{A}^{\text{old}}(i, j) + \lambda\mathbf{A}^{\text{old}}(i, j). \quad (4)$$

AP聚类根据式(1)–(4)不断进行循环迭代, 通过调节阻尼系数 λ 实现迭代更新速度. 对 \mathbf{x}_i , 若 \mathbf{x}_j 能够使 $\mathbf{R}(i, j) + \mathbf{A}(i, j)$ 成为 $\mathbf{R}(i, k) + \mathbf{A}(i, k)$ 中的最大值, 那么就认为 \mathbf{x}_j 是 \mathbf{x}_i 的聚类中心. 通过这样迭代竞争的方式实现聚类过程, 可得到含有 c 个最优聚类中心 \mathbf{v}_j 的集合 \mathbf{V} , 也可得到各样本点的类属情况.

聚类结束后, 针对上面得到的 c 个子样本数据集 subset1, \dots , subsetc, 采用LS-SVM方法建立 c 个子模型LS-SVM1, \dots , LS-SVMc.

3 基于证据合成规则的多模型输出(Multi-model output based on D-S rule)

对于新获得的测试样本, 如何预测其输出至关重要. 一般通过计算测试样本集 \mathbf{X}^t 中各测试样本 \mathbf{x}_i^t ($i = 1, \dots, n^t$) 与训练样本集中各聚类中心 \mathbf{v}_j 的距离相似度, 将 \mathbf{x}_i^t 归到与其相似度最大的类中, 选择相应

的子模型预测其输出. 但是, 这种方法对于图1所示的情况会出现错误划分, A类的样本点 M 按这种方法分类时会被误分为B类, 这种情况下, 直接用B类样本对应的子模型预测点 M 的输出就会出现一定误差. 为了更为准确地预测测试样本的输出, 本节提出了一种基于D-S合成规则的多模型输出方法.

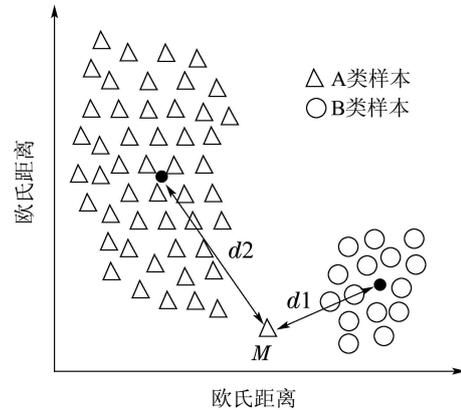


图 1 样本分布情况

Fig. 1 Sample distribution

为了利用D-S合成规则^[9-11], 首先, 定义 μ_{ij} 为 m 维测试样本 \mathbf{x}_i^t 对应于上节求得的第 j 个聚类中心 \mathbf{v}_j 的隶属度, 可表示为下式所示:

$$\mu_{ij} = 1 / \sqrt{\sum_{p=1}^m |\mathbf{x}_{pi}^t - \mathbf{v}_{pj}|^2}, \quad (5)$$

$$\forall i, j, \mu_{ij} \in [0, 1]; \sum_{j=1}^c \mu_{ij} = 1; \sum_{i=1}^{n^t} \mu_{ij} > 0. \quad (6)$$

由于隶属度函数需满足式(6), 故权值作如下处理:

$$\hat{\mu}_{ij} = \mu_{ij} / \sum_{j=1}^c \mu_{ij}, j = 1, \dots, c. \quad (7)$$

按照上式求得 \mathbf{X}^t 中各样本的模糊类隶属度集合 $\mathbf{U} = [\mu_{ij}]$. 然后, 将聚类所得的 c 个子模型作为证据理论的辨识框架 Θ , 并将任一子模型视为焦点 C_j ($j = 1, \dots, c$). 那么, 对 \mathbf{x}_1^t , 由式(5)–(7)求出其对应第1个子模型, 即第1个焦点 C_1 的模糊类隶属度. 根据证据理论^[12-13], 将其作为一条证据, 记该证据的概率分配函数为 $m(C_1|\mathbf{x}_1^t) = \mu_{11}$. 对 n^t 个样本, 同理, 可得 n^t 条证据, 其概率分配函数记为 $m(C_1|\mathbf{x}_i^t) = \mu_{i1}$ ($i = 1, \dots, n^t$). 再使用D-S合成规则对这些概率分配函数进行融合, 将融合后的概率分配函数作为第1个子模型的概率分配函数, 如式(8)所示:

$$\begin{cases} m(C_1|\mathbf{X}^t) = \frac{\sum_{C_1|\mathbf{x}_1^t \cap \dots \cap C_1|\mathbf{x}_n^t = C_1|\mathbf{X}^t} m(C_1|\mathbf{x}_1^t) \cdots m(C_1|\mathbf{x}_n^t)}{1 - k}, \\ m(\emptyset) = 0, \end{cases} \quad (8)$$

其中: 矛盾因子 k 的大小反应了证据间的冲突程度,

$$k = \sum_{C_1|x_1^t \cap \dots \cap C_c|x_n^t = \emptyset} m(C_1|x_1^t) \cdots m(C_c|x_n^t).$$

同理, 对于所有的 c 个子模型, 按照上面描述的方法, 一共可以得到 c 个证据概率分配函数, 分别记为 $m(C_1|\mathbf{X}^t), \dots, m(C_c|\mathbf{X}^t)$, 将其作为各子模型的权值因子, 用于对子模型的输出进行融合.

最后, 计算出各测试样本 \mathbf{x}_i^t 对应于各子模型LS-SVM1, \dots , LS-SVM c 的子输出 $\hat{y}_{i1}, \hat{y}_{i2}, \dots, \hat{y}_{ic}$, 利用上面得到的 c 个子模型的权值因子, 对子模型输出进行加权融合, 则 \mathbf{x}_i^t 的多模型输出为

$$\hat{y}_i = m(C_1|\mathbf{X}^t)\hat{y}_{i1} + \dots + m(C_c|\mathbf{X}^t)\hat{y}_{ic}. \quad (9)$$

按照上式, 可求出 \mathbf{X}^t 中所有测试样本的多模型输出 $\hat{y}_1, \dots, \hat{y}_n$, 输出集合记为 $\hat{y} = \{\hat{y}_1, \dots, \hat{y}_n\}$.

相比于传统的多模型方法, 本文方法首先通过定义测试样本相对于训练样本集中各聚类中心的隶属度, 然后考虑到D-S合成规则良好的聚焦特性和对不确定信息的融合能力, 利用D-S合成规则对各类隶属度信息进行整合优化, 构造多个概率分配函数, 将其作为权值因子融合子模型输出, 而不是简单直接地用某个子模型的输出表征样本最终的预测输出, 这样, 不但可有效处理测试样本被错误划分对最终输出的影响, 而且过渡平缓, 极大避免了使用切换方式获得输出而引起的震荡性.

4 基于证据合成规则的多模型软测量建模 (Multi-model dynamic soft sensing modeling based on D-S rule)

基于证据合成规则的多模型软测量建模系统结构如图2所示. 算法的具体实现步骤如下:

1) 数据预处理. 选择训练样本数据集 $\mathbf{X}_{m \times n}$, m 为样本维数, n 为样本个数, 剔除异常数据并对数据进行归一化处理;

2) AP聚类分析. 采用AP聚类方法将数据集 \mathbf{X} 聚为 c 类, 得到最优聚类中心集合 \mathbf{V} 以及各样本的归属情况;

3) 建立子模型. 对上面得到的 c 个子训练样本集, 采用LS-SVM对其进行训练学习并确定模型参数. 选择高斯核函数作为LS-SVM的核函数, 通过交叉验证法确定各子模型的参数 C 和 σ ;

4) 基于D-S规则的模型预测输出. 对新的测试样本数据集 \mathbf{X}^t , 按照式(5)–(8)的方法求得 \mathbf{X}^t 相对于各子模型的证据概率分配函数值, 将其作为各子模型的权值因子; 然后算出 \mathbf{x}_i^t 相对于每个子模型的子输出 $\hat{y}_{i1}, \hat{y}_{i2}, \dots, \hat{y}_{ic}$, 再用式(9)对子模型的输出进行加权融合, 得到 \mathbf{x}_i^t 的最终输出 \hat{y}_i ; 按照这样的方法, 求得 \mathbf{X}^t 中所有样本的输出 \hat{y} .

当要预测的是新增的单个样本 \mathbf{x}_1^{t*} ($\mathbf{x}_1^{t*} \notin \mathbf{X}^t$)时, 变更一下原测试样本集 \mathbf{X}^t , 将样本 \mathbf{x}_1^{t*} 加入到 \mathbf{X}^t , 则

可得到新的测试样本集 \mathbf{X}^{t*} , 然后按照步骤4)来预测 \mathbf{x}_1^{t*} 的输出, 具体为: 按照式(5)–(7)求出新的测试样本集 \mathbf{X}^{t*} 中所有样本对应于各聚类中心的隶属度; 然后, 按照式(8)求出 c 个子模型对应的概率分配函数 $m(C_1|\mathbf{X}^{t*}), \dots, m(C_c|\mathbf{X}^{t*})$, 将其作为子模型的权值因子; 接着, 求出该样本对应于每个子模型的子输出 $\hat{y}_{11}^{t*}, \dots, \hat{y}_{1c}^{t*}$; 那么, 测试样本 \mathbf{x}_1^{t*} 的多模型输出为 $\hat{y}_1^{t*} = m(C_1|\mathbf{X}^{t*})\hat{y}_{11}^{t*} + \dots + m(C_c|\mathbf{X}^{t*})\hat{y}_{1c}^{t*}$. 得到样本 \mathbf{x}_1^{t*} 的输出后, 将其从测试集 \mathbf{X}^{t*} 中删除. 对于下一个新的测试样本 \mathbf{x}_2^{t*} , 将其加入到原测试集里, 得到新的测试集 \mathbf{X}^{t*} 后, 按照上面同样的方法预测其输出后, 将其从 \mathbf{X}^{t*} 中删去. 按照这样的方法, 不但可以有效预测出单个测试样本的输出, 而且不会增加测试集的规模, 也有效提高了运算效率.

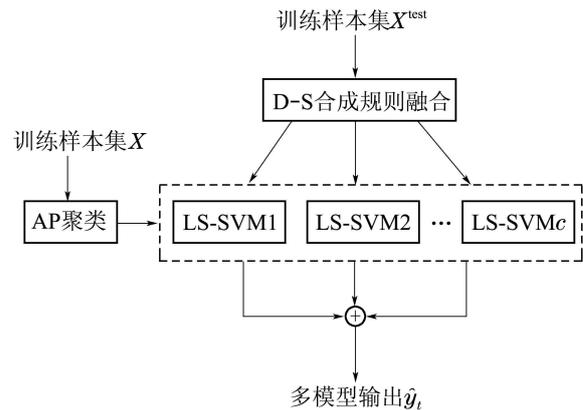


图2 基于证据合成规则的多模型软测量结构框图
Fig. 2 The structure of multi-model soft sensing model based on D-S rule

5 仿真研究(Simulation research)

为了验证本文算法, 应用文献[14]中的非线性系统进行仿真研究, 该系统可用如下非线性方程表示:

$$y(t) = \frac{x_1(t)}{1 + 0.5 \sin(x_2(t))} + \frac{x_2(t)}{1 + 0.5 \sin(x_1(t))} + \varepsilon(t),$$

$$\begin{cases} x_1(t+1) = \left(\frac{x_1(t)}{1 + x_1^2(t)} + 1 \right) + \sin(x_2(t)) \\ x_2(t+1) = \\ x_2(t) \cos(x_2(t)) + \exp\left(-\frac{x_1^2(t) + x_2^2(t)}{8}\right)x_1(t) + \\ \frac{u^3(t)}{1 + u^2(t) + 0.5 \cos(x_1(t) + x_2(t))}, \end{cases} \quad (10)$$

式中: $x_1(t)$ 与 $x_2(t)$ 为该系统的状态, $u(t)$, $y(t)$ 与 $\varepsilon(t)$ 分别为系统的输入、输出和白噪声.

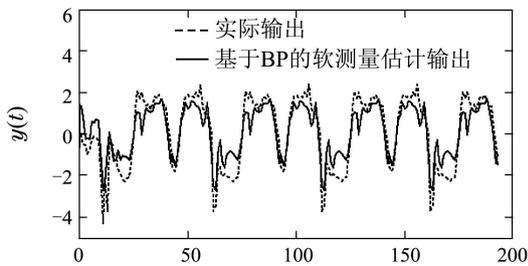
假定系统状态不可测, 通过已知的输入输出信息来预测系统的输出 $y(t)$. 选择软测量建模的输入为 $\phi(t-1) = (y(t-1), y(t-2), y(t-3), u(t-1), u(t-2),$

$u(t-3))^T$. 以 $u(t) \in [-2.5, 2.5]$ 的随机信号与 $\varepsilon(t) \in N(0, 0.1)$ 的白噪声作用于系统, 得到 5000 组时间序列训练样本. 以测试信号

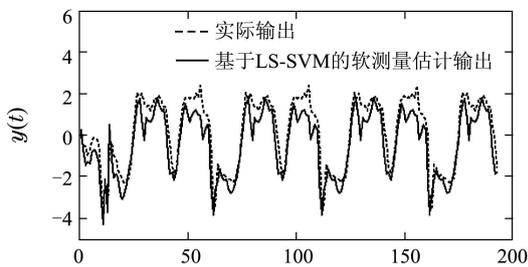
$$u(t) = \sin(0.5\pi t) + \sin(0.08\pi t) \quad (11)$$

作用于该系统, 产生 200 组测试样本用来检验前馈神经网络(BP)、最小二乘支持向量机(LS-SVM)、基于自适应模糊核聚类的最小二乘支持向量机(AFKCM-LS-SVM)、基于放射传播聚类的最小二乘支持向量机(AP-LS-SVM)和本文方法的性能.

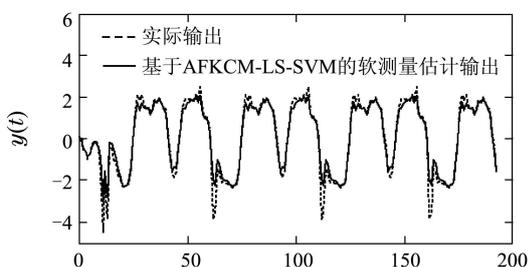
仿真结果如图 3 所示, BP 方法是一种局部搜索方法, 在求解复杂非线性函数的全局极值时易陷入局部最优, 导致训练失败, 因而它局部拟合效果好而整体拟合效果差; LS-SVM 方法由于模型过于单一而使得整体精度不高, 而 AFKCM-LS-SVM 和 AP-LS-SVM 这两种方法虽然拟合能力较好, 但是它们在最高点与最低点附近的拟合能力还有待改善. 相比于上述几种方法, 本文方法同时兼顾了局部拟合效果和最高点与最低点附近的拟合效果. 采用相对均方误差(RMSE)和最大相对误差(MAXE)来评估模型的预测能力, 这几种方法的比较结果如表 1 所示, 从中也可看出本文方法能较好地逼近系统的实际输出.



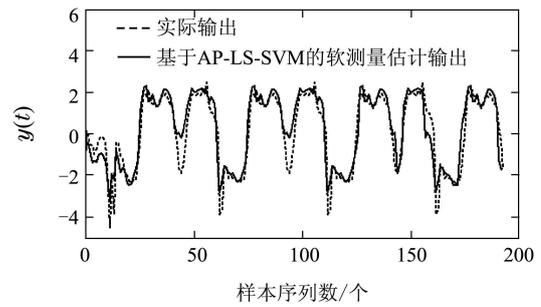
(a)



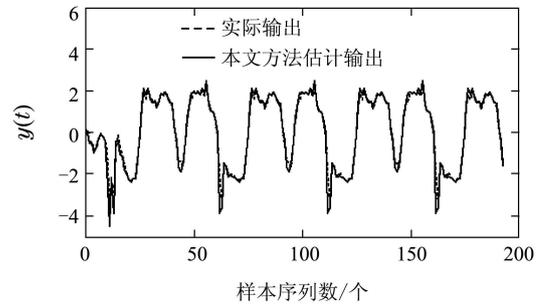
(b)



(c)



(d)



(e)

图 3 5 种方法对该系统的估计输出与实际输出对比
Fig. 3 The actual output and the estimation output of the system based on five methods

表 1 不同方法的性能比较

Table 1 Comparison of different methods

方法	RMSE($\times 10^{-1}$)	MASE($\times 10^{-1}$)
BP	0.3948	1.3839
LS-SVM	0.3492	1.3159
AFKCM-LS-SVM	0.3628	1.3462
AP-LS-SVM	0.3634	1.3481
本文方法	0.3311	1.2859

6 工业应用(Application to industrial process)

酯化反应作为整个聚酯生产工艺的关键环节, 在稳定聚酯生产中起决定性作用. 而酯化率的大小, 作为衡量第一酯化釜反应效果的关键指标, 对后续反应的进行和聚酯产品的结晶性能有直接影响, 因此常通过调节酯化率来控制整个生产过程. 图 4 为酯化反应的过程示意图. 将对苯二甲酸(PTA)和乙二醇(EG)配比成浓度合适的浆料后, 送入第一酯化反应器进行酯化反应, 反应过程中产生的乙二醇蒸汽被送入精馏塔作回收处理, 回收后的乙二醇送回浆料釜间接回酯化釜参与反应, 酯化釜主产物BHET被送到预缩聚反应器进行下一步反应, 水蒸汽则直接排出系统.

酯化反应的目标是达到满足缩聚工艺要求的酯化率, 而不同的缩聚工艺对酯化率有不同的要求, 所以必须通过调整反应压力和原料量比等操作条件来达到所需的酯化率. 但是操作条件的突然改变会引起酯化率的质量波动, 不利于整个生产过程的实时控制.

另一方面,反应过程通常采用两个酯化反应器来达到工艺要求的酯化率,而反应系统的高度非线性,时变性和不确定性也加大了酯化率在线测量的难度.因此本文提出基于证据合成规则的多模型动态软测量方法,用来对酯化率进行软测量.

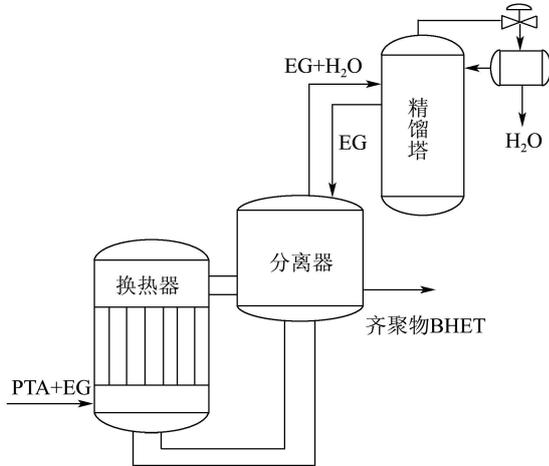


图4 酯化反应过程示意图

Fig. 4 The esterification reaction process schematic diagram

分析酯化反应过程的工艺机理,选择停留时间(τ),酯化反应温度(T),压力(P),EG/PTA摩尔配比作为辅助变量,建立基于证据合成规则的多模型动态软测量模型,用来对酯化率进行预测.

下面以某化工厂聚酯生产过程为例,具体的建模步骤如下:

1) 对现场采集的数据进行处理,得到1000组标准数据.将其中的900组数据作为训练数据集,用于模型的建立;剩下的100组作为测试数据集,用于模型的验证.

2) 利用AP聚类方法对训练数据进行聚类,得到最优聚类个数为 $c = 4$,对应的各聚类中心 \mathbf{v}_j .

3) LS-SVM子模型建立:对4个子样本集,利用LS-SVM方法建立4个子模型并训练学习,经交叉验证法确定LS-SVM的参数,如表2所示.

表2 LS-SVM模型的参数

Table 2 LS-SVM model parameters

方法	model1	model2	model3	model4
C	151.69	150.00	140.36	145.001
σ	9.509	11.006	10.008	9.838

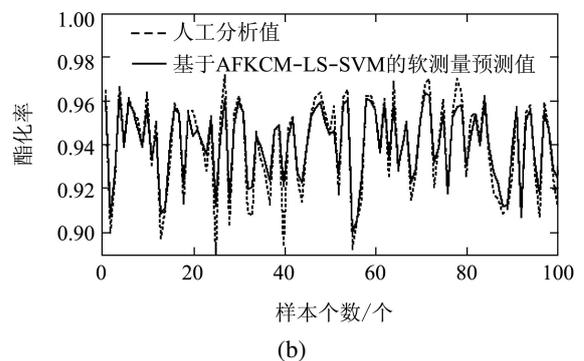
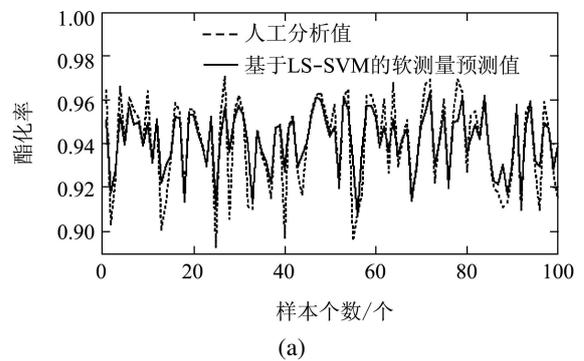
4) 基于D-S合成规则的模型预测输出:按照式(5)–(8)计算得出测试样本集对各子模型的权值因子,然后利用式(9)对各子模型的输出进行融合,得到测试样本的静态多模型输出 \hat{y} .

表3列出了这4种方法的性能参数.图5为4种不同的软测量方法的预测性能曲线.从上述仿真结果可以看出,本文方法相比于单一模型及传统的多模型方法,预测性能有了较大改善.这是因为酯化反应具有较高非线性及多工况的特点,而单模型建模时一个模型需要考虑到全部训练样本,这限制了模型的精度;而传统多模型方法在建模时尽管对训练数据集进行了聚类划分,分别建立了不同的子模型,但是在预测测试样本输出阶段没有深入考虑测试样本与训练样本的差异和划分情况及过程的动态变化对多模型输出结果的影响,因此预测性能没有显著改善.本文方法先利用AP聚类方法将工况相同和特性相似的样本聚类划分,然后充分考虑在预测测试样本的输出阶段,各子模型输出对样本最终输出结果的影响,利用D-S合成规则构造权值因子对子模型的输出进行多模型融合,得到测试样本的最终输出,避免了切换方式引起的震荡和样本误分引起的预测偏差,改善了系统的响应特性,因而具有更好的适应性,在对酯化率的软测量建模中取得了较好的拟合效果.

表3 不同方法的性能比较

Table 3 Comparison of different methods

方法	RMSE($\times 10^{-1}$)	MASE($\times 10^{-1}$)
LS-SVM	0.4101	1.4235
AFKCM-LS-SVM	0.4092	1.4167
AP-LS-SVM	0.3656	1.2167
本文方法	0.3419	1.1937



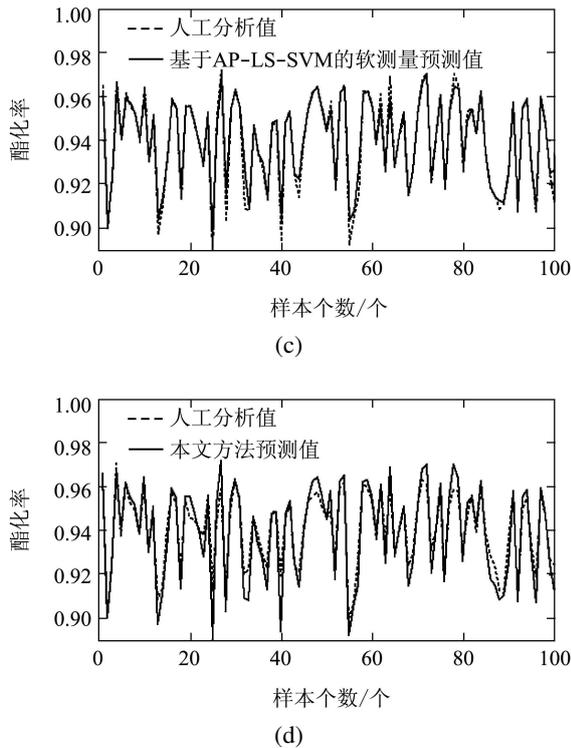


图5 4种不同的软测量方法对酯化率测试样本的预测值与人工值对比结果

Fig. 5 The estimated output and actual output of the ester rate test samples based on four different methods

7 结束语(Conclusions)

本文针对实际工业生产过程中关键变量的软测量,设计了一种基于证据合成规则的多模型软测量方法。该方法考虑了D-S合成规则的聚焦特性,针对AP聚类得到的各子模型成功建立了多个证据概率分配函数,将其作为子模型的权值因子,然后对子模型的输出进行加权融合得到测试样本的输出,改善了多模型输出的预测性能和融合能力;通过对酯化率的软测量建模应用,表明本文提出的方法有较好的预测性能和精度,是一种有效的多模型建模方法。

参考文献(References):

- [1] 徐海霞, 刘国海, 周大为, 等. 基于改进核模糊聚类算法的软测量建模研究 [J]. 仪器仪表学报, 2009, 30(10): 2226 – 2231.
(XU Haixia, LIU Guohai, ZHOU Dawei, et al. Soft sensor modeling based on modified kernel fuzzy clustering algorithm [J]. *Chinese Journal of Scientific Instrument*, 2009, 30(10): 2226 – 2231.)
- [2] 李卫, 杨煜普, 王娜. 基于核模糊聚类的多模型LSSVM回归建模 [J]. 控制与决策, 2008, 23(5): 560 – 564.
(LI Wei, YANG Yupu, WANG Na. Multi-model LSSVM regression modeling based on kernel fuzzy clustering [J]. *Control and Decision*, 2008, 23(5): 560 – 564.)
- [3] 李修亮, 苏宏业, 褚健. 基于在线聚类的多模型软测量建模方法 [J]. 化工学报, 2007, 58(11): 2834 – 2839.
(LI Xiuliang, SU Hongye, ZHU Jian. Multiple models soft-sensing technique based on online clustering arithmetic [J]. *Journal of Chemical Industry and Engineering*, 2007, 58(11): 2834 – 2839.)
- [4] 陈定三, 杨慧中. 基于局部重构融合流形聚类的多模型软测量建模 [J]. 化工学报, 2011, 62(8): 2281 – 2285.
(CHEN Dingsan, YANG Huizhong. Multiple model soft sensor based on local reconstruction and fusion manifold clustering [J]. *Journal of Chemical Industry and Engineering*, 2011, 62(8): 2281 – 2285.)
- [5] 李丽娟, 宋坤, 赵英凯. 基于仿射传播聚类的ARA发酵过程建模 [J]. 化工学报, 2011, 62(8): 2116 – 2122.
(LI Lijuan, SONG Kun, ZHAO Yingkai. Modeling of ARA fermentation based on affinity propagation clustering [J]. *Journal of Chemical Industry and Engineering*, 2011, 62(8): 2116 – 2122.)
- [6] 李丽娟, 刘君. 芳烃异构化过程的多模型建模 [J]. 化工学报, 2011, 62(8): 2350 – 2354.
(LI Lijuan, LIU Jun. Multi-modeling of aromatics isomerization process [J]. *Journal of Chemical Industry and Engineering*, 2011, 62(8): 2350 – 2354.)
- [7] 李丽娟, 潘磊, 张提. 基于AP聚类算法的跳汰机床层松散度软测量建模 [J]. 化工学报, 2012, 63(9): 2675 – 2680.
(LI Lijuan, PAN Lei, ZHANG Shi. Soft sensor modeling for mobility of jig bed based on AP-clustering algorithm [J]. *Journal of Chemical Industry and Engineering*, 2012, 63(9): 2675 – 2680.)
- [8] 张文清, 傅雨佳, 杨慧中. 基于改进聚类和加权bagging的多模型软测量建模 [J]. 化工学报, 2012, 63(9): 2697 – 2702.
(ZHANG Wenqing, FU Yujia, YANG Huizhong. Multi-model soft-sensor modeling based on improved clustering and weighted bagging [J]. *Journal of Chemical Industry and Engineering*, 2012, 63(9): 2697 – 2702.)
- [9] 张盛刚, 李巍华, 丁康. 基于证据可信度的证据合成新方法 [J]. 控制理论与应用, 2009, 26(7): 812 – 814.
(ZHANG Shenggang, LI Weihua, DING Kang. A novel approach to evidence combination based on the evidence credibility [J]. *Control Theory & Applications*, 2009, 26(7): 812 – 814.)
- [10] LI X, JEAN D, FLORENTIN S, et al. Evidence supporting measure of similarity for reducing the complexity in information fusion [J]. *Information Sciences*, 2011, 10(181): 1818 – 1835.
- [11] SU Z, WANG P, YU X, et al. Maximal confidence intervals of the interval-valued belief structure and applications [J]. *Information Sciences*, 2011, 9(181): 1700 – 1721.
- [12] 刘准钊, 程咏梅, 潘泉, 等. 基于证据距离和矛盾因子的加权证据合成法 [J]. 控制理论与应用, 2009, 26(12): 1439 – 1442.
(LIU Zhuniao, CHENG Yongmei, PAN Quan, et al. Combination of weighted belief functions based on evidence distance and conflicting belief [J]. *Control Theory & Applications*, 2009, 26(12): 1439 – 1442.)
- [13] SU Z, WANG P, SHEN J, et al. Multi-model strategy based evidential soft sensor model for predicting evaluation of variables with uncertainty [J]. *Applied Soft Computing*, 2011, 2(11): 2595 – 2610.
- [14] ZENG J, WNG J, GUO J. Local multi-model method based on similarity of vector [J]. *Application Research of Computers*, 2012, 29(5): 1631 – 1634.

作者简介:

唐 苦 (1989–), 女, 硕士研究生, 研究方向为软测量, E-mail: tang_ok@126.com;

王 昕 (1972–), 男, 副教授, 硕士生导师, 研究方向为智能电网、可再生能源的分布式生产、传输、存储和接入技术, E-mail: wangxin26@sju.edu.cn;

王振雷 (1975–), 男, 教授, 博士生导师, 研究方向为化工过程智能建模、控制与优化、故障诊断和控制系统性能评估, E-mail: wangzhen.l@ecust.edu.cn.