



张雷,马永帅,洪斌斌,等.一种改进 OSELM 算法在片烟复烤过程水分在线检测中的应用[J].轻工学报,2025,40(3):95-103.  
ZHANG L,MA Y S,HONG B B,et al. Application of an improved OSELM algorithm in online detection of moisture content in the tobacco strip redrying process[J]. Journal of Light Industry,2025,40(3):95-103.  
DOI:10.12187/2025.03.011

# 一种改进 OSELM 算法在片烟复烤过程水分在线检测中的应用

张雷<sup>1,2</sup>,马永帅<sup>1</sup>,洪斌斌<sup>1</sup>,熊开胜<sup>3</sup>,徐大勇<sup>2</sup>,堵劲松<sup>2</sup>,李银华<sup>1</sup>,邹泉<sup>3</sup>

1. 郑州轻工业大学 电气信息工程学院,河南 郑州 450001;
2. 中国烟草总公司 郑州烟草研究院,河南 郑州 450001;
3. 云南中烟工业有限责任公司 技术中心,云南 昆明 650231

**摘要:**针对片烟复烤过程中关键质量指标出口烟叶含水率难以直接在线检测,且离线化验滞后严重的问题,提出一种改进在线序列极限学习机(Online Sequential Extreme Learning Machine, OSELM)的复烤干燥过程自适应建模方法,实时在线检测干燥区出口烟叶的含水率。首先,采用专家知识与互信息方法选择与烟叶含水率相关性最强的辅助变量,增强模型的泛化能力并降低复杂度。然后,针对复烤过程的强非线性和显著时变特性,提出一种基于自适应遗忘因子的 OSELM 建模方法,设计的自适应遗忘因子策略能够根据复烤工况的变化动态迭代更新,以此增强软测量模型对复杂工况的在线跟踪能力。最后,基于某复烤厂的实际生产数据进行实验,结果表明,相较于传统软测量建模方法,本文方法具有较高的在线检测精度和响应速度,证明了该算法的有效性和优越性。

**关键词:**片烟;烟叶含水率;复烤机;互信息;软测量;在线序列极限学习机;在线检测

**中图分类号:**TS452 **文献标识码:**A **文章编号:**2096-1553(2025)03-0095-09

## 0 引言

复烤机是一类结构复杂的大型热工设备,广泛应用于片烟加工生产中<sup>[1]</sup>。复烤干燥过程的主要目标是调整片烟中的含水率,并去除片烟中的杂气、害虫和病菌等。其中,出口烟叶含水率是复烤过程中的关键质量评价指标,由于复烤生产工况复杂多变,片烟含水率无法直接实时在线测量,导致

生产工况波动大、产品品质不稳定及能耗和物耗的浪费,因此,亟需建立一种准确的复烤过程烟叶含水率软测量模型,以实现片烟含水率的实时、准确在线检测,对于提升复烤过程的精准控制水平具有重要意义<sup>[2-3]</sup>。

目前,烟叶含水率的检测主要采用 3 种方法:烘箱法、近红外水分检测和软测量技术。烘箱法利用人工采样,虽准确度高,但劳动强度大、效率低且存

收稿日期:2024-01-22;修回日期:2024-05-07;出版日期:2025-06-15

基金项目:河南省科技攻关计划项目(222102220122,222102210118);国家局烟草科研大数据重大专项(110202101083(SJ-07));烟草行业烟草工艺重点实验室引领计划专项(202022AWHZ01,202022AWCX04)

作者简介:张雷(1988—),男,河南省洛阳市人,郑州轻工业大学讲师,博士,主要研究方向为复杂工业智能建模。E-mail:lyzl@zzuli.edu.cn

通信作者:邹泉(1971—),男,云南省玉溪市人,云南中烟工业有限责任公司高级工程师,主要研究方向为烟草工艺及装备。E-mail:qxh@hongta.com

在滞后性。近红外水分仪可实现在线检测,但测量精度易受烟叶颜色和形态的影响,且设备成本高,需要频繁维护。软测量技术通过易于获取的辅助变量构建模型,能够估计难以直接测量的参数<sup>[4]</sup>。但复烤过程中的理化反应十分复杂,建立一个准确的机理模型是极其困难的。随着人工智能技术的不断进步,基于数据驱动的软测量建模方法受到越来越多的关注,尤其在流程工业领域中应用日益广泛<sup>[5-6]</sup>。常用方法包括人工神经网络(Artificial Neural Network, ANN)、支持向量回归(Support Vector Regression, SVR)、极限学习机(Extreme Learning Machine, ELM)等,它们均具有强大的非线性拟合能力<sup>[7-8]</sup>。例如,张雷等<sup>[9]</sup>提出基于深度门控循环单元(Deep Gated Recurrent Unit, DGRU)网络的烘丝机干燥过程动态建模方法。这些研究虽取得了积极成果,但多属于离线建模方法,其应用范围仍是受限的。

在实际的片烟复烤生产中,受原料品质差异、机械设备老化、外界环境干扰等因素影响,复烤工业过程实质上是一个非稳态过程。工业数据具有典型的时间变化特性,而传统离线全局模型一旦投入实际生产运行中,由于缺乏自适应和自学习能力,无法及时跟踪生产工况的最新变化,导致软测量模型性能下降<sup>[10-11]</sup>,因此,探索一种能够适应复烤过程动态变化的自适应建模方法显得尤为必要<sup>[12]</sup>。针对该问题,最直接的方法是采用滑动窗口策略,通过将新样本数据纳入模型并同时移除旧样本来重新建立并更新模型参数,这种方法能有效追踪生产过程的状态变化,但需要重复建模,计算复杂度较高<sup>[13-14]</sup>。在线序列极限学习机(Online Sequential Extreme Learning Machine, OSELM)是 ELM 的在线学习算法,能够在线学习数据流并实现模型参数的增量式更新<sup>[15]</sup>,具有快速学习、低计算复杂度和强泛化能力等优点。OSELM 已在系统建模、故障诊断、时间序列分析等方面得到广泛应用,并在处理非稳态和时变数据方面展现出优异性能,因此,在复烤过程自适应建模方面具有应用潜力<sup>[16-17]</sup>。然而,由于片烟复烤的生产工况复杂且多变,导致传统的 OSELM 模型在实际应用中存在一

定的局限性。

鉴于此,本文拟提出一种改进的 OSELM 方法,用于实现复烤过程中片烟含水率实时精准在线检测。首先,采用互信息法分析过程变量与质量指标之间的相关性,进行最优特征选择;其次,鉴于复烤过程的强非线性和时变特性,建立基于 OSELM 的软测量模型;再次,提出一种自适应遗忘因子机制,可以根据过程变化在线迭代调整模型,进一步增强其对复杂动态系统的跟踪和自适应能力;最后,在实际生产数据上进行实验验证,证明所提方法的可行性与有效性。

## 1 复烤数据描述及特征选择

### 1.1 复烤数据描述

本研究实验数据来源于西南地区某复烤厂,以 KG235C 型号复烤机为研究对象,设备尺寸为 55.6 m×5.5 m×4.8 m,包括 6 个干燥区、2 个冷却区和 4 个回潮区,采用双侧进风方式。该厂目前已搭建了 MES 生产执行系统及 DCS 底层采集系统,现场服务器中积累了大量工业数据。本研究采集了 2021 年 4 月 12 至 17 日同一配方的生产数据,共 90 个批次,每一批次生产时间大约 62 min,数据采样间隔为 15 s,每个批次大约 200 个样本,将完整样本数据划分为训练集和测试集,前者 16 000 组数据主要用于模型的训练,后者 3595 组数据用于测试模型的检测性能。结合现场的传感器分布和生产工艺需求,本文研究的重点聚焦在干燥区。共采集该区的 37 个辅助变量,作为模型的初始变量集合,以回潮区采集的物料厚度参数和冷却区近红外水分仪检测的烟叶含水率作为模型输出变量。实验平台采用 Matlab2018 版本。

### 1.2 复烤特征筛选

在复烤工业现场,数据采集监控(Supervisory Control and Data Acquisition, SCADA)系统采集了大量过程变量,作为软测量建模的辅助变量。然而,高维数据容易产生维数灾难问题,增加模型的复杂度和过拟合风险。针对该问题,互信息<sup>[18]</sup>是一种基于信息论的特征选择方法,相较于传统主成分分析方法,互信息不受数据分布和尺度的影响,能够度量数据之

间的线性和非线性关系,提高关键变量筛选的准确性。互信息定义如下:

$$I(X;Y) = \iint p(x,y) \log \frac{p(x,y)}{p(x)p(y)} dx dy$$

其中,  $p(x,y)$  为  $x$  和  $y$  联合概率的分布函数,  $p(x)$  和  $p(y)$  分别为  $x$  和  $y$  的边缘概率密度函数。互信息值越大,则代表两者相关性越强。本文采用经典的最小冗余最大相关性 (Minimum Redundancy Maximum Relevance, mRMR) 算法对复烤过程进行特征选择,其基本理念是从原始的特征集中选择一组既能最大程度表示目标变量信息,相互之间冗余度又最小的特征组合。因此, mRMR 算法能够平衡特征与目标变量之间的相关性和特征之间的冗余性。

## 2 基于改进 OSELM 的复烤过程动态建模

### 2.1 OSELM 理论概述

ELM 是一种单隐层前馈神经网络 (Single-hidden Layer Feedforward Neural Networks, SLFNs), 它通过随机初始化隐层权重和偏置, 利用最小二乘法 (Least Squares Method) 来求解输出层的权重, 以大幅减少计算量和训练时间。ELM 基本原理详见文献 [13]。OSELM 是 ELM 的增量学习版, 适合处理在线学习场景, 在接收到新数据后能够以增量学习方式迭代更新模型, 而不需要重新训练整个网络, 可以实时适应新的数据分布, 因此非常适合处理复烤过程的动态变化。OSELM 的学习过程分为两个阶段: 初始化阶段和在线序列学习阶段。

在初始化阶段, 初始样本集  $D_0 = \{(x_i, t_i)\}_{i=1}^{N_0}$ , 当隐含层节点数小于训练样本个数, 即  $L < N$  时, 则初始权重  $\beta_0$  为:

$$\beta_0 = H_0^+ T_0 = (H_0^T H_0)^{-1} H_0^T T_0$$

其中,  $H_0$  为初始隐含层的输出矩阵,  $T_0$  为  $D_0$  的输出。

在线序列学习阶段, 当新样本加入样本集时, 新权值在初始权值  $\beta_{(0)} = K_0^{-1} H_0^T T_0$  基础上递推而得, 其中  $K_0 = H_0^T H_0$ 。对于新增  $N_1$  个样本  $\{(X_i, T_i)\}_{i=N_0+1}^{N_0+N_1}$ , 可得

$$K_1 = \begin{bmatrix} H_0 \\ H_1 \end{bmatrix}^T \begin{bmatrix} H_0 \\ H_1 \end{bmatrix} = \begin{bmatrix} H_0^T & H_1^T \end{bmatrix} \begin{bmatrix} H_0 \\ H_1 \end{bmatrix} = K_0 + H_1^T H_1$$

当新样本数据加入模型时, 结合原有数据更新网络参数, 则模型参数更新为:

$$\beta_{(1)} = K_1^{-1} \begin{bmatrix} H_0 \\ H_1 \end{bmatrix}^T \begin{bmatrix} H_0 \\ H_1 \end{bmatrix} = K_1^{-1} (K_1 \beta_{(0)} - H_1^T H_1 \beta_{(0)} + H_1^T T_1) = \beta_{(0)} + K_1^{-1} H_1^T (T_1 - H_1 \beta_{(0)})$$

$\beta_{(1)}$  通过  $\beta_{(0)}$  增量修改, 令  $P_{k+1} = K_{k+1}^{-1}$ , 在  $k+1$  次迭代后, 则模型参数如下所示:

$$P_{k+1} = P_k - P_k H_{k+1}^T (I + H_{k+1}^T P_k H_{k+1}^T)^{-1} H_{k+1} H_{k+1}^T \quad (1)$$

$$\beta^{(k+1)} = \beta^{(k)} + P_{k+1} H_{k+1}^T (T_{k+1} + H_{k+1} \beta^{(k)})$$

由上可知, 在初始模型的基础上, 通过增量更新策略可实现模型的迭代更新, 提高在线计算效率。

### 2.2 OSELM 算法改进

根据式①可知, 传统 OSELM 算法在更新时赋予了新旧样本相同的权重, 这可能导致模型无法有效捕捉最新的生产状态。为了解决这一问题, 引入了遗忘因子来加权处理新旧样本, 以增强模型对新数据的敏感性并减少旧数据的影响。然而, 固定遗忘因子可能限制模型在非稳态系统中的适应性。因此, 本文提出了一种自适应调整遗忘因子的方法, 使模型能够根据当前情况动态调整对旧数据的依赖程度, 从而提高模型的自适应性和预测性能, 更好地适应工艺过程的复杂变化。

根据文献 [19] 的理论, 在新数据在线学习阶段, 公式①修改为:

$$\beta_{k+1} = \beta_k + \frac{P_k h_{k+1}}{1 + \xi_{k+1}} \hat{e}_{k+1}$$

其中,  $\hat{e}_{k+1} = y_t - h_{k+1}^T \beta_k$ , 为在  $\beta_k$  下的新样本预测误差;  $\xi_{k+1} = h_{k+1}^T P_k h_{k+1}$ , 为辅助变量;  $h_{k+1} = [g(a_1, b_1, x_t), \dots, g(a_L, b_L, x_t)]$ , 为隐含层输出。若  $\xi_{k+1} = 0$ , 则令  $P_{k+1} = P_k$ ; 若  $\xi_{k+1} > 0$ , 则  $P_{k+1}$  定义为:

$$P_{k+1} = P_k - \frac{P_k h_{k+1} h_{k+1}^T P_k}{\varepsilon_{k+1}^{-1} + \xi_{k+1}}$$

其中,  $\varepsilon_{k+1} = \lambda_k - \frac{1-\lambda_k}{\xi_{k+1}}$ , 为辅助变量;  $\lambda_k$  为第  $k$  次的遗忘因子, 并且满足  $0 < \lambda_k \leq 1$ ,  $\lambda_k$  越小, 对旧数据影响越小, 则第  $k+1$  次的遗忘因子公式为:

$$\lambda_{k+1} = \left\{ \begin{array}{l} 1 + (1 + \rho) \\ \left[ \ln(1 + \xi_{k+1}) + \left( \frac{(v_{k+1} + 1)\eta_{k+1}}{1 + \xi_{k+1} + \eta_{k+1}} - 1 \right) \right] \\ \frac{\xi_{k+1}}{1 + \xi_{k+1}} \end{array} \right\}^{-1}$$

其中,  $\rho$  是固定常数,  $\eta_{k+1} = \hat{e}_{k+1}^2/\gamma_{k+1}$ ,  $\gamma_{k+1} = \lambda_k \left( \gamma_k + \frac{\hat{e}_{k+1}^2}{1 + \xi_{k+1}} \right)$ ,  $v_{k+1} = \lambda_k(v_k + 1)$ , 均为辅助参数, 初始值在 0~1 之间。该算法利用复烤数据分布统计特性来动态调整遗忘因子的大小, 具体来说, 当复烤工况变化剧烈时, 模型会赋予较小的遗忘因子, 更多地关注新数据; 相反地, 当复烤工况较稳定时, 模型会赋予较大的遗忘因子, 以利用更多旧数据。自适应调整机制使模型能够根据复烤生产工况的变化程度调整参数更新, 从而更准确地捕捉复烤过程的动态特性。

2.3 模型局部更新

在处理复烤过程中的数据时, 由于不同过程变量的量纲和范围差异较大, 对模型性能有显著影响, 传统批次归一化方法通常假设数据分布固定, 忽视了数据动态变化。为了适应复烤过程的时变特性, 本文提出了局部归一化方法。这种方法在每个时间步或固定窗口内计算数据的均值和方差, 并使用这些统计量对新样本进行归一化。这使得模型能够动态适应数据分布的变化, 从而提高对生产过程变化的捕捉能力。具体来说, 对于  $t+1$  时刻固定窗口内的样本, 均值和方差可以分别通过以下公式进行更新:

$$\bar{x}_{t+1} = \frac{n-1}{n} \bar{x}_t + \frac{1}{n} x_{t+1}$$

$$\sigma_{t+1}^2 = \frac{n-2}{n-1} \sigma_t^2 + \frac{1}{n-1} (x_{t+1} - \bar{x}_{t+1})^2$$

其中  $\bar{x}_{t+1}$  和  $\sigma_{t+1}$  分别是  $t$  时刻的均值和方差,  $n$  为固定窗口大小。同理, 对输出变量也需进行上述更新。通过局部归一化, 有助于模型更好地捕捉到生产过程中的局部变化。

3 复烤工业实验及结果分析

3.1 数据预处理结果

复烤工业生产的现场环境相对恶劣, 采集数据往

往存在少量离群样本, 为保证数据的合理有效, 需及时剔除显著离群点, 本研究采用  $3\sigma$  准则进行离群值检测。为消除数据随机噪声干扰, 采用小波变换方法, 将非平稳热工数据分解为一系列不同尺度信号, 消除随机噪声影响。图 1 为入口含水率预处理结果对比图。由图 1a) 可知, 原始入口含水率曲线平滑度较为粗糙, 经过预处理后见图 1b), 建模样本质量显著提高。

首先, 为降低特征筛选的难度, 删除一些变化不大的辅助变量以减少干扰; 然后, 采用 mRMR 方法结合交叉验证来确定最佳特征数目; 再根据大量实验结果, 确定选择 8 个辅助变量 ( $X_{24}$ 、 $X_{17}$ 、 $X_{28}$ 、 $X_{37}$ 、 $X_{20}$ 、 $X_{31}$ 、 $X_8$ ) 时, 模型的预测效果最佳。复烤过程变量的互信息见表 1。由表 1 可知, 干燥五区上部温度的互信息最大, 为 0.233 4, 其次是干燥四区下部温度和干燥三区下部温度, 其互信息分别为 0.149 5 和 0.128 4。分析其原因可能是复烤多采用低温缓慢上升的加工方式, 干燥五区和四区温度较高, 对出口水分的影响较大, 这与实际工艺相一致, 证明特征筛选结果的有效性。值得注意的是, 虽然烟叶原料流量、




图 1 入口含水率预处理结果对比图  
Fig. 1 Comparison of pretreatment inlet moisture content results

表 1 复烤过程变量的互信息  
Table 1 Mutual information analysis of redrying process parameters

| 序号 | 变量                                            | 互信息     | 序号 | 变量                                            | 互信息     |
|----|-----------------------------------------------|---------|----|-----------------------------------------------|---------|
| 1  | 336+354 电子秤累计值和/kg                            | 0.065 4 | 20 | 干燥四区下部温度/℃                                    | 0.149 5 |
| 2  | 336+354 电子秤瞬时流量和/(kg·h <sup>-1</sup> )        | 0.004 0 | 21 | 干燥五区风门 1 实际开度/%                               | 0.000 5 |
| 3  | A354 电子秤(非叶基)流量/(kg·h <sup>-1</sup> )         | 0.002 0 | 22 | 干燥五区风门 2 实际开度/%                               | 0.000 5 |
| 4  | A354 电子秤(非叶基)累计量/kg                           | 0.071 0 | 23 | 干燥五区排潮风机风速/(m <sup>3</sup> ·h <sup>-1</sup> ) | 0.000 4 |
| 5  | 入口水分/%                                        | 0.062 9 | 24 | 干燥五区上部温度/℃                                    | 0.233 4 |
| 6  | 干燥一区风门 1 实际开度/%                               | 0.017 7 | 25 | 干燥六区排潮风机风速/(m <sup>3</sup> ·h <sup>-1</sup> ) | 0.010 5 |
| 7  | 干燥一区风门 2 实际开度/%                               | 0.018 1 | 26 | 干燥六区风门 1 实际开度/%                               | 0.022 6 |
| 8  | 干燥一区排潮风机风速/(m <sup>3</sup> ·h <sup>-1</sup> ) | 0.026 7 | 27 | 干燥六区风门 2 实际开度/%                               | 0.022 7 |
| 9  | 干燥一区下部温度/℃                                    | 0.111 1 | 28 | 干燥六区上部温度/℃                                    | 0.075 7 |
| 10 | 干燥二区风门 1 实际开度/%                               | 0.019 4 | 29 | 冷却 1 区入口风门开度/%                                | 0.117 4 |
| 11 | 干燥二区风门 2 实际开度/%                               | 0.019 2 | 30 | 冷却 1 区平衡板风门/%                                 | 0.061 6 |
| 12 | 干燥二区排潮风机风速/(m <sup>3</sup> ·h <sup>-1</sup> ) | 0.021 5 | 31 | 冷却 1 区温度(下)/℃                                 | 0.163 9 |
| 13 | 干燥二区下部温度/℃                                    | 0.090 3 | 32 | 冷却 1 区温度(上)/℃                                 | 0.001 7 |
| 14 | 干燥三区风门 1 实际开度/%                               | 0.045 1 | 33 | 冷却 2 区入口风门开度/%                                | 0.085 5 |
| 15 | 干燥三区风门 2 实际开度/%                               | 0.045 0 | 34 | 冷却 2 区平衡板风门/%                                 | 0.085 3 |
| 16 | 干燥三区排潮风机风速/(m <sup>3</sup> ·h <sup>-1</sup> ) | 0.069 6 | 35 | 冷却 2 区出口风门开度/%                                | 0.090 1 |
| 17 | 干燥三区下部温度/℃                                    | 0.128 4 | 36 | 冷却 2 区温度(上)/℃                                 | 0.004 9 |
| 18 | 干燥四区风门 1 实际开度/%                               | 0.066 2 | 37 | 冷却 2 区温度(下)/℃                                 | 0.216 5 |
| 19 | 干燥四区排潮风机风速/(m <sup>3</sup> ·h <sup>-1</sup> ) | 0.067 9 |    |                                               |         |

入口水分和物料厚度分布波动较小,但是根据实践经验,这会直接影响复烤干燥的效果。因此,在建模时,A354 电子秤(非叶基)流量 kg/h,入口水分%,左、中、右物料厚度也需要考虑。最后,本文筛选出与复烤质量相关性最高的 12 个特征变量,分别为干燥一区排潮风机风速、干燥三区和四区下部温度、干燥五区和六区上部温度,冷却 1 区和 2 区温度(下)、原料 A354 电子秤(非叶基)流量、入口水分及左、中、右物料厚度,作为软测量模型的最后输入。

复烤过程初始时刻的模型如下式所示:

$$y=f(x_1,x_2,\cdots,x_n,)$$

为了验证本文算法的有效性,选择偏最小二乘回归(Partial Least Squares,PLS)、ELM 和 OSELM 算法进行对比实验。各模型的参数设置如下:PLS 的最佳主成分数是 11,ELM、OSELM、改进 OSELM 均采用单隐含层结构,激活函数为 Sigmoid,隐含层节点数初始值为 50,滑动窗口宽度为 15。

为了评估模型的准确率,本研究选取 3 个评价指标,包括平均绝对误差百分比(Mean Absolute Percentage Error,MAPE)、均方根误差(Root Mean

Square Error,RMSE)和  $R^2$ 。其定义如下所示:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y_p}{y_i} \right|$$
$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_p)^2}$$
$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y_p)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

其中, $y_i$  和  $y_p$  分别为真实值和预测值, $\bar{y}$  为均值, $N$  为样本数。

3.2 实验结果分析

4 种算法预测烟叶含水率的性能评价结果见表 2。由表 2 可知,经典的 PLS 模型的 RMSE、MAPE 最大且  $R^2$  最小,主要是因为 PLS 为线性模型,无法处理复烤过程的非线性特性。相比之下,ELM 模型略有改进。但其缺乏自适应更新机制。OSELM 模型的 MAPE、RMSE 均有明显降低, $R^2$  显著提高,这表明采用在线学习方式增强了模型的自适应性。基于自适应遗忘因子的 OSELM 模型表现最优,MAPE 和 RMSE 最小, $R^2$  高达 0.989 7,这是由于自适应遗忘机制的引入,可以平衡新旧样本的权重,增强模

型对复杂时变系统的动态跟踪能力。综上可知,本文算法可以更加准确地预测关键质量指标烟叶含水率的变化。

4 种算法的烟叶含水率预测与实际含水率的对比图见图 2—图 5,相应的预测误差曲线见图 6。由图 2—图 5 可知,复烤过程工况波动剧烈,随时间不断变化,且各批次之间的一致性较差,具体而言,由图 2 可知,PLS 算法的预测值与实际含水率曲线存在较大偏差,ELM 算法仍然无法准确跟踪实际含水

率数值及变化趋势;OSELM 算法的含水率预测值基本与实际含水率曲线一致,并且预测误差基本稳定在绝对值正负 0.1 范围内;本文算法的含水率预测曲线与实际含水率曲线高度一致,且预测偏差最小,并且即使在工况波动较大的情况下,仍能够表现出明显的有效性和优越性,这进一步说明了本文算法能够适应复烤过程中的非平稳动态特性。

除了模型准确率评价指标外,算法的在线运行时间也是重要的考查指标,如果计算时间过长,则难以满足实际应用中的在线预测要求。由表 2 可知,ELM 算法的计算时间仅为 0.226 9 s,这是由于 ELM 算法的求解采用是最小二乘法,而非传统梯度下降方法,具有极高的学习速度。OSELM 算法的计算时间为 10.6 s,而本文算法为 10.82 s,这是因为自适应遗忘因子需要不断迭代计算,增加了算法的复杂度,模型性能提升是以增加算法的复杂度为代

表 2 4 种算法预测片烟含水率的性能评价结果

Table 2 Predictive performance comparison of four algorithms for cut tobacco moisture content

| 序号 | 算法    | MAPE           | RMSE           | R <sup>2</sup> | 时间/s         |
|----|-------|----------------|----------------|----------------|--------------|
| 1  | PLS   | 1.767 3        | 0.212 5        | -0.742 2       | 1.25         |
| 2  | ELM   | 1.428 5        | 0.182 9        | -0.290 9       | 0.226 9      |
| 3  | OSELM | 0.439 7        | 0.058 1        | 0.869 7        | 10.6         |
| 4  | 本文算法  | <b>0.087 7</b> | <b>0.016 4</b> | <b>0.989 7</b> | <b>10.82</b> |




图 2 PLS 算法的片烟含水率预测值与实际含水率对比图

Fig. 2 PLS algorithm; Predicted vs. actual cut tobacco moisture content comparison




图 3 ELM 算法的片烟含水率预测值与实际含水率对比图

Fig. 3 ELM algorithm; Predicted vs. actual cut tobacco moisture content comparison




图 4 OSELM 算法的片烟含水率预测值与实际含水率对比图烟叶水分预测结果

Fig. 4 OSELM algorithm; Predicted vs. actual cut tobacco moisture content comparison




图 5 本文算法的片烟含水率预测值与实际含水率对比图烟叶水分预测结果

Fig. 5 Proposed method; Predicted vs. actual cut tobacco moisture content comparison

价,但对于复烤测试集 3595 个测试样本及每 15 s 一次的采样间隔,本文算法的时效性仍然能够满足工业实际在线应用的预测要求。

表 3 为不同窗口宽度下本文算法泛化能力评价结果。由表 3 可知,窗口宽度对模型检测性能有重要影响,如果窗口宽度设置较小,则模型泛化能力不足,且稳定性差;相反,窗口宽度设置过大,则包含了更多旧信息,使模型自适应更新能力受限。因此,当窗口宽度为 15 时,本文模型性能最佳。

图 7 为在线预测过程中遗忘因子权重变化趋势。由图 7 可知,随着生产工况不断变化,本文设计的改进 OSELM 算法能够不断迭代更新遗忘因子权重参数。相对于传统固定遗忘因子方法,该算法能够根据工况的变化动态调整遗忘因子大小,例如,当工况发生大幅变化时,遗忘因子会增大,降低旧样本的权重,同时增加新样本的权重,这样能更好地获取最新的工况变化,进而增强复烤测量模型的动态跟踪能力。




图 6 4 种算法的烟叶水分预测误差曲线  
Fig. 6 Prediction error curves of four algorithms (PLS, ELM, OSELM and proposed method) for cut tobacco moisture content

表 3 不同窗口宽度下本文算法泛化能力评价结果  
Table 3 Generalization performance of proposed method under varying window sizes

| 窗口宽度 | $R^2$   | RMSE    | MAPE    |
|------|---------|---------|---------|
| 10   | 0.984 3 | 0.020 2 | 0.093 2 |
| 15   | 0.989 7 | 0.016 4 | 0.087 7 |
| 20   | 0.985 6 | 0.019 3 | 0.103 7 |
| 25   | 0.985 3 | 0.019 5 | 0.103 1 |
| 30   | 0.979 4 | 0.023 1 | 0.107 5 |
| 35   | 0.986 4 | 0.018 8 | 0.087 4 |
| 40   | 0.981 1 | 0.022 1 | 0.098 5 |

为了评估软测量模型的在线更新能力,本文设计了 7 种不同更新比例,分别为 0%、5%、10%、25%、50%、75%、100%。不同更新比例下本文算法的实验结果见表 4。由表 4 可知,当模型更新比例为 0%、5%、10%时,本文算法的预测性能显著下降,事实上,更新 0%时,模型退化为离线的全局 ELM 算法,其性能最差。相反,随着模型更新比例不断增加,本文算法性能发生了显著改善,100%更新时,其  $R^2$  达到了 0.991,这表明了在线更新对于解决复烤过程时变特性的重要性。




图 7 在线预测过程中遗忘因子权重变化趋势  
Fig. 7 Dynamic adaptation of forgetting factor weights during real-time prediction

表 4 不同更新比例下本文算法性能  
Table 4 Proposed method performance under different update ratios

| 更新比例/% | RMSE  | $R^2$  |
|--------|-------|--------|
| 0      | 0.201 | -0.564 |
| 5      | 0.080 | 0.753  |
| 10     | 0.046 | 0.919  |
| 25     | 0.051 | 0.901  |
| 50     | 0.030 | 0.965  |
| 75     | 0.033 | 0.958  |
| 100    | 0.016 | 0.990  |

## 4 结论

针对复烤过程干燥区烟叶水分在线检测的难题,本文提出了基于改进 OSELM 软测量方法。该方法结合了序列学习和遗忘机制,能够实现模

型的动态更新与调整,从而适应复烤工业复杂的生产环境,能够快速、准确地检测烟叶含水率,具有良好的泛化能力和自适应更新能力,基于某复烤厂实际生产数据测试结果,本文方法具有较高的检测精度和时效性,其  $R^2$  高达 0.989 7,充分证明了该算法的有效性和优越性,对于提高复烤生产过程的控制稳定和实时优化具有重要意义。未来工作中,将重点研究集成学习方法,以进一步提升针对复烤多品种、多牌号烟叶的在线检测精度。

## 参考文献:

- [1] 戴永生,申玉军,夏飞,等. 片烟复烤机回潮段加温加湿系统的改进设计[J]. 烟草科技, 2019, 52(9): 115-120.
- [2] 徐大勇,李新锋,范明登,等. 复烤温度对片烟收缩率及大小分布的影响[J]. 烟草科技, 2013, 46(3): 12-16.
- [3] 徐波,姜焕元,范明登,等. 基于“翠碧 1 号”品种烟叶典型力学特性的打叶复烤加工技术及应用[J]. 烟草科技, 2020, 53(7): 80-86, 106.
- [4] KADLEC P, GABRYS B, STRANDT S. Data-driven soft sensors in the process industry [J]. Computers & Chemical Engineering, 2009, 33(4): 795-814.
- [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] ZHANG L, REN G F, DU J S, et al. A novel spatio-temporal attention-based bidirectional LSTM model for moisture content prediction in drying process [J]. Drying Technology, 2024, 42(14): 2122-2136.
- [7] ZHANG L, ZHANG X G, CHEN H, et al. A robust temperature prediction model of shuttle kiln based on ensemble random vector functional link network [J]. Applied Thermal Engineering, 2019, 150: 99-110.
- [8] ZHANG X G, ZHANG L, CHEN H, et al. Prediction of coal feeding during sintering in a rotary kiln based on statistical learning in the phase space [J]. ISA Transactions, 2018, 83: 248-260.
- [9] 张雷,李金学,堵劲松,等. 基于 DGRU 网络的烘丝机筒壁温度动态预测 [J]. 轻工学报, 2022, 37(6): 85-91.
- [10] ZHANG L, REN G F, LI S L, et al. A novel soft sensor approach for industrial quality prediction based TCN with spatial and temporal attention [J]. Chemometrics and Intelligent Laboratory Systems, 2025, 257: 105272.
- [11] ZHANG L, MA C F, ZOU Y J, et al. A multi-scale spatiotemporal deep learning model with variational mode decomposition for multistep prediction of moisture content in the leaf moistening process [J]. Drying Technology, 2025: 1-15.
- [12] BAKIROV R, GABRYS B, FAY D. Multiple adaptive mechanisms for data-driven soft sensors [J]. Computers & Chemical Engineering, 2017, 96: 42-54.
- [13] URHAN A, ALAKENT B. Integrating adaptive moving window and just-in-time learning paradigms for soft-sensor design [J]. Neurocomputing, 2020, 392: 23-37.
- [14] HU J, WU M, CAO W H, et al. Soft-sensing of burn-through point based on weighted kernel just-in-time learning and fuzzy broad-learning system in sintering process [J]. IEEE Transactions on Industrial Informatics, 2024, 20(5): 7316-7324.
- [15] ZHANG X F, MA H B, ZHANG H Q. Data-driven control based on information concentration estimator and regularized online sequential extreme learning machine [J]. Symmetry, 2024, 16(1): 88.
- [16] XUE J Q, CHEN X C, CHI Q Y, et al. Online learning-based adaptive device-free localization in time-varying indoor environment [J]. Applied Sciences, 2024, 14(2): 643.
- [17] BELETE B A, GELMECHA D J, SINGH R S. Online sequential extreme learning machine (OSELM) based denoising of encrypted image [J]. Expert Systems with Applications, 2025, 274: 126999.
- [18] PENG H C, LONG F H, DING C. Feature selection based on mutual information: Criteria of max-dependency, max-relevance, and min-redundancy [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1226-1238.
- [19] SOARES S G, ARAÚJO R. An adaptive ensemble of on-line extreme learning machines with variable forgetting factor for dynamic system prediction [J]. Neurocomputing, 2016, 171: 693-70.

# Application of an improved OSELM algorithm in online detection of moisture content in the tobacco strip redrying process

ZHANG Lei<sup>1,2</sup>, MA Yongshuai<sup>1</sup>, HONG Binbin<sup>1</sup>, XIONG Kaisheng<sup>3</sup>, XU Dayong<sup>2</sup>,  
DU Jinsong<sup>2</sup>, LI Yinhua<sup>1</sup>, ZOU Quan<sup>3</sup>

1. College of Electrical and Information Engineering, Zhengzhou University of Light Industry, Zhengzhou 450001, China;
2. Zhengzhou Tobacco Research Institute of CNTC, Zhengzhou 450001, China;
3. Technology Center, China Tobacco Yunnan Industrial Co., Ltd., Kunming 650231, China

**Abstract:** To address the challenges in directly detecting the moisture content of tobacco strips (a key quality indicator) and the significant delays in offline moisture measurements during the redrying process, this study proposes an adaptive modeling method using an improved Online Sequential Extreme Learning Machine (OSELM) for real-time online monitoring of moisture content at the drying zone exit. First, domain-specific expert knowledge and mutual information analysis were combined to select auxiliary variables most relevant to moisture content, thereby improving model generalization while maintaining predictive accuracy and reducing computational complexity. Subsequently, an OSELM-based modeling approach with adaptive forgetting factors (AFFs) was developed to address the strong nonlinearity and time-varying dynamics. The AFF strategy dynamically adjusted according to process variations, significantly enhancing the soft sensor's online tracking performance under complex operational conditions. Finally, validation using real-world production data from an industrial redrying facility showed that the proposed method outperforms traditional soft sensing approached in both detection accuracy and response time, thereby confirming its superior effectiveness.

**Key words:** tobacco strip redrying machine; moisture content of tobacco strip; mutual information; soft sensor; online sequential extreme learning machine; online detection

[责任编辑:王晓波 贾学伟]