

DOI:10.19651/j.cnki.emt.2210823

多重注意机制及权重校正 LSTM 的 PVC 含水率预测^{*}

张帅杰¹ 郭小萍¹ 咸春华¹ 苏宝玉²

(1. 沈阳化工大学信息工程学院 沈阳 110142; 2. 沈阳华控科技发展有限公司 沈阳 110179)

摘要: 针对 PVC 干燥工段中, PVC 含水率存在非线性、大滞后、与其他变量关联性复杂难以预测的问题, 提出一种多重注意机制及权重校正型长短期记忆网络(LSTM)模型用于 PVC 含水率的预测。在编码器部分, 利用与含水率相关的输入序列之间的相关性对空间注意机制训练的可变权重进行校正, 避免由于单纯数据训练导致相关性强的输入变量之间权重差异较大, 进而实际干燥工艺不符; 同时, 由于含水率预测的滞后特性, 为减弱长子时间窗口内 LSTM 单元细胞状态信息丢失, 提出信息补偿机制补偿之前时刻细胞状态信息。在解码器部分, 利用时间注意机制对编码器的隐藏层状态进行权重更新, 解除固定长度向量对模型性能的限制。最后, 选取某化工公司干燥工段 DCS 数据进行验证, 相对于 RNN、VA-LSTM、STA-LSTM 相关系数(R^2)分别提高了 571%、122.6%、82.6%, 结果表明本文模型具有一定优越性。

关键词: PVC 含水率; 时空注意机制; 权重校正; 信息补偿机制; LSTM

中图分类号: TP273 文献标识码: A 国家标准学科分类代码: 510.8010

Prediction of PVC moisture content by multiple attention mechanism and weight correction LSTM

Zhang Shuaijie¹ Guo Xiaoping¹ Zang Chunhua¹ Su Baoyu²

(1. College of Information Engineering, Shenyang University of Chemical Technology, Shenyang 110142, China;

2. Shenyang HuaKong Technology Development Co., Ltd., Shenyang 110179, China)

Abstract: In view of the problems of PVC moisture content in the PVC drying section, such as nonlinearity, large lag, complex correlation with other variables and difficult to predict, a multiple attention mechanism and weight correction long-term and short-term memory network (LSTM) model are proposed for the prediction of PVC moisture content. In the encoder part: use the correlation between the input sequences related to water content to correct the variable weight of spatial attention mechanism training, so as to avoid the large weight difference between the input variables with strong correlation due to simple data training, and then the actual drying process is inconsistent. At the same time, due to the hysteresis of water content prediction, in order to reduce the loss of cell state information of LSTM unit in the eldest son time window, an information compensation mechanism is proposed to compensate the cell state information at the previous time. In the decoder part, we use the time attention mechanism to update the weight of the hidden layer state of the encoder, and remove the limitation of the fixed length vector on the performance of the model. Finally, the DCS data of the drying section of a chemical company were selected for verification. Compared with RNN, VA-LSTM and STA-LSTM, the correlation coefficient (R^2) were increased by 571%, 122.6% and 82.6% respectively. The results showed that the model in this paper had certain advantages.

Keywords: PVC moisture content; spatiotemporal attention mechanism; weight correction; information compensation mechanism; LSTM

0 引言

工业生产中, 工艺指标通常需要对其进行实时监测及

控制, 这依赖于检测变送机构的在线测量, 但检测机构往往具有高成本的特点, 还可能由于恶劣的工况环境无法长期使用, 同时可能由于现有检测技术不足, 部分重要的待检测

收稿日期: 2022-07-26

*基金项目: 辽宁省教育厅基础研究项目(LJ2020021)资助

变量无法在线检测,只能利用中控室离线采样分析^[1-5]。

在 PVC 生产过程中,PVC 干燥工段主要负责将汽提塔来的浆料进行烘干,达到产品质量要求。其中,PVC 含水率是产品质量的重要指标,PVC 含水率低于 0.5% 为合格品,低于 0.4% 为一等品,提前掌握 PVC 含水率变化趋势并对于干燥工段被控变量实施相应优化控制是提升产品质量及生产效益的关键。中控室离线采样分析普遍具有提前取样的特点,取样时刻与实际时刻对应的工艺参数可能具有较大的时间偏差,这对控制及分析具有较大的时间滞后性,无法保证实时性;由于水分检测仪器本身测量精度有限引起的系统误差、环境因素引发的偶然误差、人为因素引起的过失误差等误差因素使得中控室分析数据可能不具有数据完全真实性;离线分析的数据量较少,建立模型的周期较长,无法在短时间内反应对象的动力学特性,加长了项目实施周期。在线水分检测仪受检测环境限制,可安装在下料器处且成本较高,不易维护。因此,利用与含水率相关性较强且测量成本较低的变量建立预测模型具有重要作用。

机理建模存在诸多困难且模型甚至无法实施,数据驱动的学习框架因无需考虑复杂的工艺特性且可以逼近任意非线性对象具有广泛研究和应用^[6-8]。常用的方法有主成分分析(principal component analysis, PCA)^[9]、偏最小二乘(partial least squares, PLS)^[10]、支持向量回归(support vector regression, SVR)^[11]、高斯过程回归(Gaussian process regression, GPR)^[12]、人工神经网络(artificial neural network, ANN)^[13-14]、循环神经网络(recurrent neural network, RNN)^[15],但以上方法无法有效处理长序列数据建模问题,长短期记忆网络(long short-term memory, LSTM)利用门控制及细胞状态实现长时间记忆适合对长序列建模^[16-18]。

但标准 LSTM 没有考虑关联变量之间的相关性和时序性、关联变量与目标质量变量间的相关性,模型精度较低。专家们对 LSTM 进行改进且与其他智能算法结合可应用于各类对象的分析预测,如文献[19]开发了 STA-LSTM 结构增强网络对质量变量与输入变量相关性学习并应用于加氢裂化过程重质石脑油初始沸点及航空煤油初始沸点的预测,文献[20]开发了双重注意的 LSTM 实现对多个质量变量时序性分析并应用于卷烟过程及多相流过程的质量变量预测,文献[21]开发了有监督混合 CNN-LSTM 网络,青霉素发酵过程和脱丁烷塔验证了方法的有效性,文献[22]利用 CNN-LSTM 用于 NO_x 预测,文献[23]将 CNN-LSTM 应用于滑坡位移动态预测,文献[24]将 LSTM 用于数控机床热误差预测,文献[25]利用 SDS-SSA-LSTM 预测变压器油中溶解气体浓度,文献[26]利用 EMD-LSTM 对受热面积灰预测。

鉴于 LSTM 对工业长时间序列建模的优越性,本文提出使用 LSTM 作为基础结构并引入多种注意机制及校正环节对 PVC 含水率进行分析预测,以提高预测精度。

1 PVC 干燥工艺分析

PVC 干燥工段简化的流程如图 1 所示,汽提工段的物料由汽提塔处理后进入干燥工段的离心槽内,离心槽内的物料由离心机通过离心机供料泵打入干燥床内进行干燥,干燥的物料由下料器进入包装工段。其中离心槽起到缓冲及存储物料的作用且装有搅拌器保证浆料的均匀性;干燥床内分布有多组蒸汽列管维持床体温度;物料在热风拖动下,呈现“沸腾”状由一床向二床移动,热风风量配比由床体参数及工艺规定。水分检测取样设在下料器处,因此,含水率检测与关联变量具有较大的滞后性且与含水率相关的变量个数较多且变量之间互相耦合。

干燥工段变量时序性及耦合性分析:进床总蒸汽阀门开度为维持床温的主要能量体系,总蒸汽阀门开度增大一床、二床温度提高,一床床温及二床床温滞后于总蒸汽阀门开度,同时,二床床温滞后于一床床温,滞后来源包括总蒸汽阀门开度加大及由一床流入的已升温物料;物料由离心机进入干燥床内向下料器移动过程需要时间大致为 1 h,因此,离心机电流增大时、对床压的滞后时间较长,下料器安装在二床出口处,下料器变频减小对床压影响的滞后时间较小;进床风量一定时,增加热风温度将潜在的影响床内环境,时间滞后长达数个小时。因此,影响含水率增加的主要因素为:床压升高:离心机总电流升高、下料器变频降低;进床能量降低:进床总蒸汽压力降低、进一床及二床蒸汽量降低、进一床及二床热风温度降低;热交换速率降低:进一床、二床风量降低。其中,受生产安全限制,风量取固定设定值。与工艺专家沟通及对干燥工段工艺分析,选取进床总蒸汽阀门开度、一床二室下部温度、二床下部温度、进一床热风温度、进二床热风温度、干燥床压力差、离心机总电流作为对含水率预测的 7 个关联变量。

2 PVC 含水率多重注意机制及权重校正 LSTM

2.1 LSTM 相关描述

1) LSTM

LSTM 是 RNN 的改进方式,LSTM 具有 1 个长时间记忆状态、3 个非线性门控制器实现信息处理:通过细胞状态实现长时间记忆,通过遗忘门决定忘记的信息,输入门决定更新的信息,输出门决定输出信息,LSTM 结构如图 2 所示,每个 LSTM 单元具有 3 个输入、2 个输出。

对 LSTM 单元,在 t 时刻,3 个输入为:前一时刻细胞状态 c_{t-1} 、前一时刻隐藏层状态 h_{t-1} 、当前输入 x_t ,2 个输出为:当前时刻更新的细胞状态 c_t 、当前时刻更新的隐藏层状态 h_t ,门控制、中间状态、细胞状态分别满足:

$$\text{遗忘门: } f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$$

$$\text{输入门: } u_t = \sigma(W_u[h_{t-1}, x_t] + b_u)$$

$$\text{输出门: } o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

$$\text{中间状态: } \bar{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c)$$

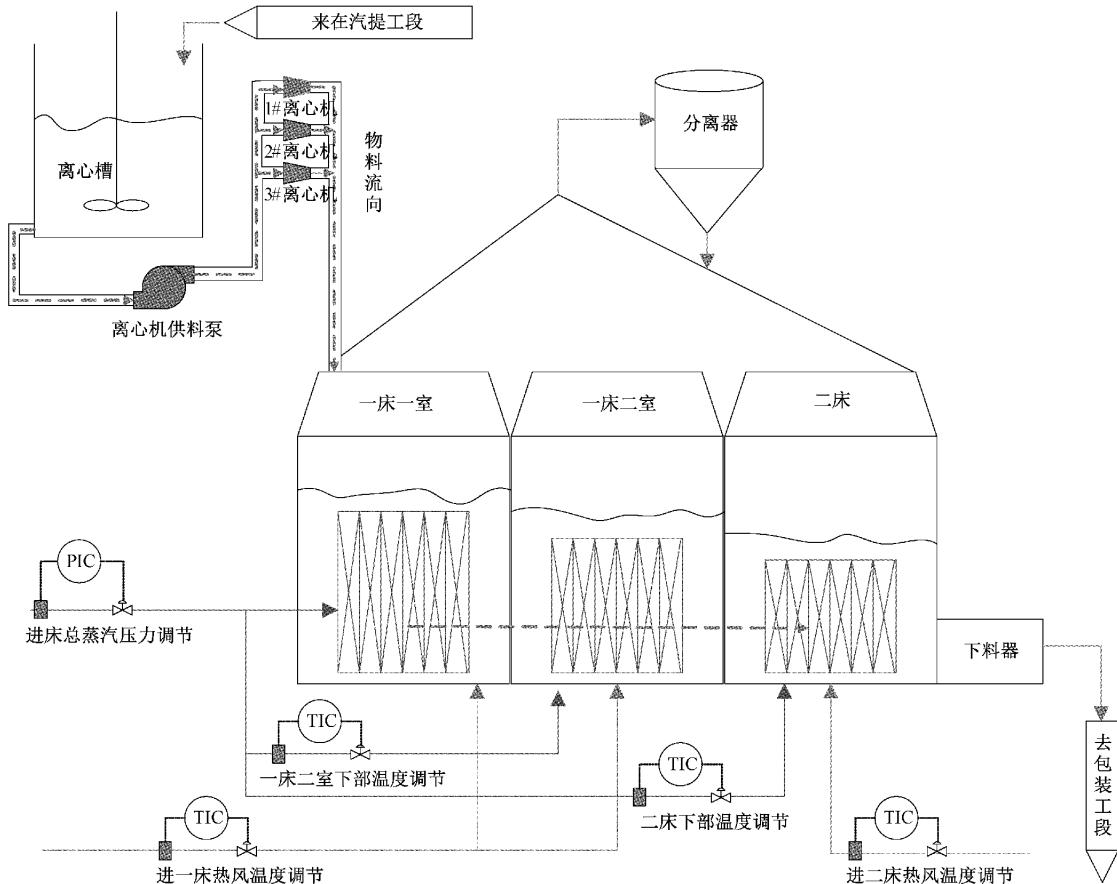


图 1 PVC 干燥工段简化流程

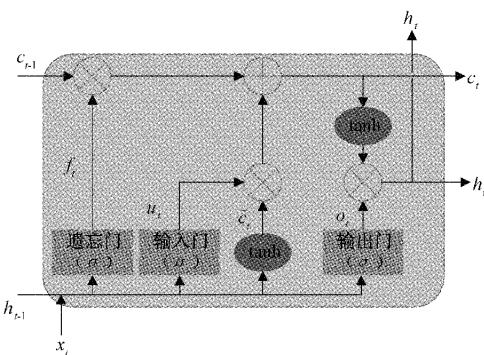


图 2 LSTM 标准结构

$$\text{隐藏状态: } h_t = o_t \tanh(c_t)$$

$$\text{细胞状态: } c_t = f_t c_{t-1} + u_t \bar{c}_t$$

其中, $W_f, W_u, W_o, W_c, b_f, b_u, b_o, b_c$ 为待学习参数,

$$\tanh(\cdot), \sigma(\cdot) \text{ 为激活函数: } \sigma(x) = \frac{1}{1 + e^{-x}}, \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

2) 解码器编码器架构

解码器编码器架构是处理序列数据之间建模的深度学习结构, 架构如图 3 所示。编码器将输入数据转化为隐

藏状态序列用于捕获动态特性, 隐藏状态序列转化为固定长度的上下文向量用于对隐藏层信息进行非单调特征处理及高度的特性信息提取, 但输入序列数据变长时, 将限制模型性能, 解码器使用该向量作为输入预测输出。

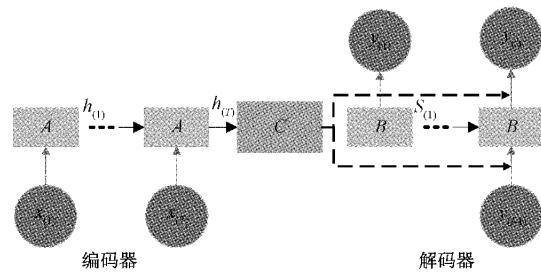


图 3 解码器编码器结构

图 3 中, A 为编码器单元, B 为解码器单元, A 和 B 可以属于不同的单元结构, C 为固定长度上下文向量。

3) 注意机制

注意机制通过对每个输入序列与质量变量进行相似度计算(similarity), 利用相似度区分输入变量的重要性并分配注意权重, 即多个输入变量对输出影响性大小的分配, 标准结构如图 4 所示。

权重计算公式为:

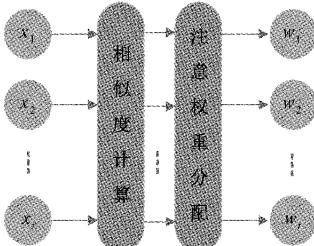


图 4 注意机制结构

$$w_i = \frac{\exp((\text{similarity})_i)}{\sum_{k=1}^n \exp((\text{similarity})_k)} \quad (1)$$

2.2 多重注意机制及权重校正 LSTM 架构

鉴于 PVC 干燥工段复杂的非线性及动力学特征,含水率预测需要较长时间步长的预测学习,在编码器及解码器架构中,开发了多重注意机制 LSTM 模型用于含水率预测,引入空间注意机制提高质量变量与输入变量相关性捕获;权重校正减小空间注意机制对强相关性输入变量之间相关性分配误差;信息补偿注意机制用于对长时间子窗口步长内细胞状态进行补充;时间注意机制打破原始固定长度向量长序列学习丢失信息的缺陷,采用时间反向传播法计算参数梯度,Adam 算法对网络参数进行更新,这使得多重注意机制 LSTM 对存在动力学复杂的 PVC 干燥系统含水率预测具有较好的预测精度,结构如图 5 所示。

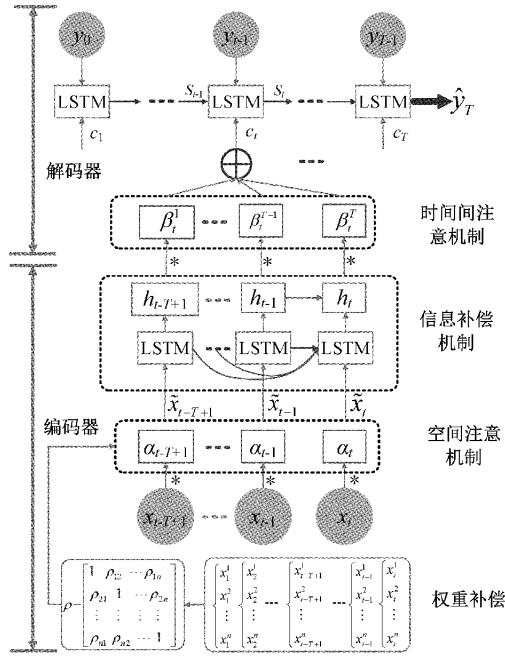


图 5 多重注意机制及权重校正 LSTM 结构

1) 空间注意机制及权重校正

空间注意机制主要目的为在每个时间步长内,编码器学习与含水率相关的关联变量,并分配权重,被加权的输入序列作为 LSTM 新的输入,隐藏层状态得到更新,使得

与含水率密切相关的关联变量具有更高的权重。对于子窗口时间步长的输入序列 $[x_1, x_2, \dots, x_T]$, 单个输入 x_i 包含 n 个输入变量,即: $x_i = (x_i^1, x_i^2, \dots, x_i^n)$, 对于干燥系统: $n = 7$ 。为了获取关联变量(进床总蒸汽阀门开度、一床二室下部温度、二床下部温度、进一床热风温度、进二床热风温度、干燥床压力差、离心机总电流)对质量变量(含水率)影响权重,可以学习之前时刻解码器隐藏层状态 S_{i-1} 对每个关联变量的关系,因此,空间注意机制结构如图 6 所示。

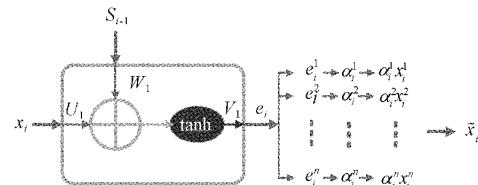


图 6 空间注意机制结构

结构机理为:

$$e_i^j = V_i^j \tanh(W_i^j S_{i-1} + U_i^j x_i^j + b_i^j) \quad (2)$$

$$\alpha_i^j = \frac{|e_i^j|}{\sum_{d=1}^n |e_i^d|}, 1 \leq j \leq n \quad (3)$$

其中, $V_i^j, W_i^j, U_i^j, b_i^j$ 为空间注意机制待学习的参数,通过 S_{i-1} 与 x_i 反向传播法学习确定, e_i^j 代表第 j 个关联变量在 i 时刻对含水率重要性的注意值, α_i^j 为空间注意权值,负责将权重分配之和为 1, 获取权重后可通过相似度计算得到含水率与 7 个关联变量的具体相关性。

对于空间注意机制,利用输出隐藏层状态包含的信息反向训练关联变量对含水率可变权重,提升了模型的精度,但实际含水率预测可能包含多种未训练数据集特征,预测精度将受到影响,因为权重值过分关注数据信息,忽略了与真实干燥系统关联性较强的关联变量之间的相关性,即:含水率对干燥系统相关性较强的关联变量分配了具有较大差异的相关性权重,例如,对具有高度相关性的进床总蒸汽阀门开度、一床二室下部温度分配的权重差值可能较大。因此,文中提出增加关联变量相关性校正环节作为空间注意机制的先验知识,对具有高度的相关性的关联变量权重进行校正,以符合干燥工段各个关联变量之间的动力学特征,校正结构为图 7。

以训练集数据长度对 n 个变量进行相关性计算获取相关性矩阵 ρ :

$$\rho = \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1n} \\ \rho_{21} & 1 & \cdots & \rho_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{n1} & \rho_{n2} & \cdots & 1 \end{bmatrix} \quad (4)$$

其中, ρ_{pq} 为相关性, $\rho_{pq} = \rho_{qp}$ 且 ρ 为正交矩阵, $|\rho_{pq}| \geq 0.6$ 认为关联变量之间具有较强相关性,对此类关联变量组可能需要进行权重校正,具体为: $|\rho_{pq}| <$

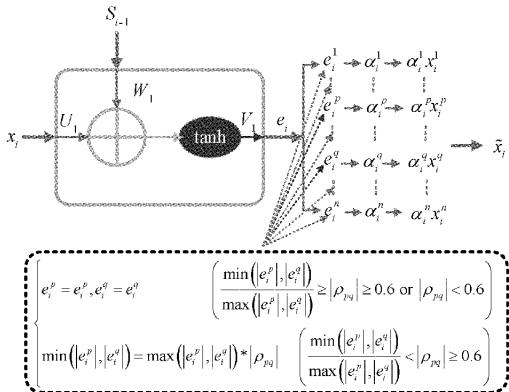


图 7 空间注意机制权重校正结构

0.6 时, 无需对权重进行校正; $\frac{\min(|e_i^p|, |e_i^q|)}{\max(|e_i^p|, |e_i^q|)} \geq |\rho_{pq}| \geq 0.6$
 0.6 时, 认为空间注意机制计算权重符合关联变量组相关性, 无需对权重进行校正; $\frac{\min(|e_i^p|, |e_i^q|)}{\max(|e_i^p|, |e_i^q|)} < |\rho_{pq}| \geq 0.6$
 0.6 时, 认为权中需要进行调整: $\min(|\alpha_i^p|, |\alpha_i^q|) = \max(|\alpha_i^p|, |\alpha_i^q|) * |\rho_{pq}|$ 。 经过权重校正的权重, 空间注意机制对关联变量之间存在强相关性的关联变量组分配的权重值误差更小, 增强了网络对关联变量之间动态关系的捕获能力, 同时兼顾含水率与关联变量的相关性, 增强了对网络干燥系统工艺特性的自主学习能力, 同时, LSTM 网络更新为:

$$\begin{cases} f_i = \sigma(W_{fi}[h_{i-1}, \tilde{x}_i] + b_{fi}) \\ u_i = \sigma(W_{ui}[h_{i-1}, \tilde{x}_i] + b_{ui}) \\ o_i = \sigma(W_{oi}[h_{i-1}, \tilde{x}_i] + b_{oi}) \\ c_i = \tanh(W_{ci}[h_{i-1}, \tilde{x}_i] + b_{ci}) \\ h_i = o_i \tanh(c_i) \\ c_t = f_i c_{i-1} + u_i \bar{c}_i \end{cases} \quad (5)$$

其中, $W_{f*}, W_{u*}, W_{o*}, W_{c*}, b_{f*}, b_{u*}, b_{o*}, b_{c*}$ 为待学习参数。

2) 信息补偿注意机制

子窗口时间步长较长时, LSTM 单元在传输细胞状态过程中将丢失一些重要信息, 造成网络性能下降, 文中提出使用信息补偿的方法将当前时刻 t 的 LSTM 单元输入细胞状态 c_{t-1} 与子窗口时间步长内之前时刻细胞状态自适应加权之和 \bar{c}_{t-1} 作为输入, 补偿丢失信息, 结构图如图 8 所示。

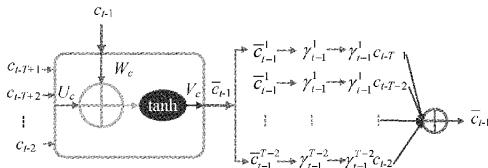


图 8 信息补偿机制结构

结构机理为:

$$\bar{c}_{t-1}^q = V_c^q \tanh(W_c^q c_{t-1} + U_c^q c_{t-T+q} + b_c^q) \quad (6)$$

$$\gamma_{t-1}^q = \frac{|\gamma_{t-1}^{q-1}|}{\sum_{x=1}^{T-2} |\gamma_{t-1}^x|}, 1 \leq q \leq T-2 \quad (7)$$

其中, $V_c^q, W_c^q, U_c^q, b_c^q$ 为信息补偿机制在子时间窗口内待学习的与第 q 个细胞相关的参数, \bar{c}_{t-1}^q 代表在子时间窗口内当前细胞状态的第 q 个细胞状态补偿值, γ_{t-1}^q 为信息补偿机制权值, 负责将权重分配之和为 1。细胞状态更新为:

$$c_{t-1} = c_{t-1} + \bar{c}_{t-1} \quad (8)$$

3) 时间注意机制

上下文向量采用固定长度提取编码器特征, 随着序列增加, 上下文向量会丢失过去时间的众多信息且解码器无法保留重要信息, 使得含水率预测精度下降, 时间注意机制中, 利用解码器前一时刻隐藏层状态包含的信息特征 S_{t-1} 对当前时刻子窗口长度内的编码器隐藏状态 $[h_{t-T+1} \dots h_{t-1} h_t]$ 进行自适应加权解除对固定长度的依赖, 结构如图 9 所示。

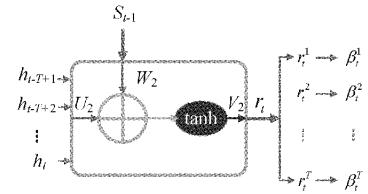


图 9 时间注意机制结构

结构机理为:

$$r_t^m = V_2^m \tanh(W_2^m S_{t-1} + U_2^m h_{t-T+m} + b_2^m) \quad (9)$$

$$\beta_t^m = \frac{|r_t^m|}{\sum_{g=1}^T |r_t^g|}, 1 \leq m \leq T \quad (10)$$

其中, $V_2^m, W_2^m, U_2^m, b_2^m$ 为空间注意机制待学习的与第 m 个样本相关的参数, r_t^m 代表当前时刻第 m 个编码器的时间注意值, β_t^m 为时间注意权值, 负责将权重分配之和为 1, T 为子窗口步长。在 t 时刻上下文向量 C 表达式为:

$$C_t = \sum_{m=1}^T h_{t-T+m} \beta_t^m \quad (11)$$

进而 t 时刻新的解码器状态更新为:

$$S_t = f_t(C_t, S_{t-1}) \quad (12)$$

其中, $S_{t-1} = W_3 y_{t-1} + V_3 S_{t-1} + b_3$, W_3, V_3 为权重矩阵, b_3 为偏置项, $f_t(\cdot)$ 为 LSTM 单元。含水率预测结果为:

$$\hat{y}_T = V(f_t(S_{T-1}; C_T)) + b_v \quad (13)$$

其中, V 为权重矩阵, b_v 为偏置项。

3 PVC 干燥工段含水率预测实例

选取某化工公司干燥工段正常工况下 DCS 采集的 16 000 组数据为样本数据, 利用 Pauta 准则^[27-28]对样本数据进行异常值剔除、一阶惯性法对样本数据滤波。RMSE、 R^2 用于比较文中所提模型与 RNN、可变注意力 LSTM

(VA-LSTM)、时空注意机制 LSTM(STA-LSTM)的预测精度。

$$RMSE = \sqrt{\sum_{t=1}^{T_{testing}} (y_{(t)} - \hat{y}_{(t)})^2 / (T_{testing} - 1)} \quad (14)$$

$$R^2 = 1 - \sum_{t=1}^{T_{testing}} (y_{(t)} - \hat{y}_{(t)})^2 / \sum_{t=1}^{T_{testing}} (y_{(t)} - \bar{y})^2 \quad (15)$$

其中, $T_{testing}$ 为测试集样本长度取 1 000, \bar{y} 为测试集含水率均值, $\hat{y}_{(t)}$ 为模型预测值, $y_{(t)}$ 为测试集真实值。

前 15 000 组用于训练集数据, 对相关变量进行相关性分析, 热力图如图 10 所示, 参考 RMSE 性能对模型参数设置: 子窗口时间为 20; 神经元数量(解码器及编码器)为 100; 小批量大小为 200; 学习率为 0.001; 迭代次数为 60。不同模型对含水率预测效果如图 11 所示, 模型残差如图 12 所示, 性能对比如表 1 所示。

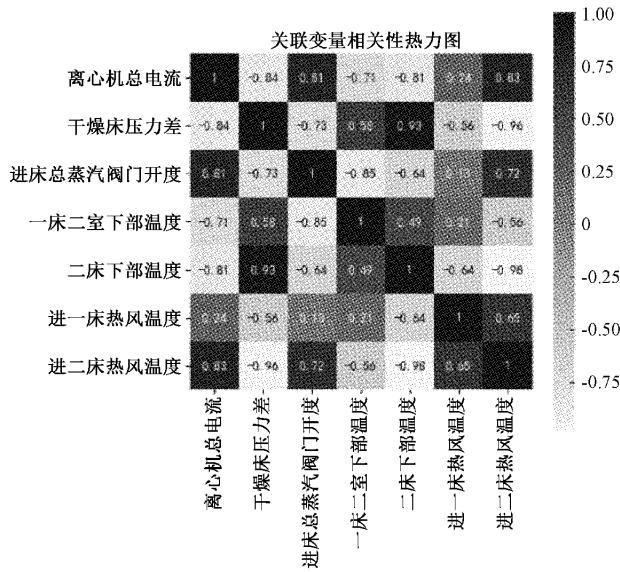


图 10 含水率关联变量相关性

表 1 模型性能

方法	RMSE	R^2
RNN	0.002 11	0.128 33
VA-LSTM	0.000 87	0.386 78
STA-LSTM	0.000 89	0.471 61
文中方法	0.000 27	0.861 07

分析可知, 图 11 对比了几种常用于处理时间序列模型对含水率预测的趋势, 图 12 对比了各个模型的残差, 其中 RNN 由于无法解决长时间序列存在的梯度消失及梯度爆炸问题, 预测精度最低且存在较大的模型残差; VA-LSTM 引入了可变权重注意机制提高了含水率与关联变量的相关性, 预测精度有所提高; STA-LSTM 还引入了时间注意机制改善固定长度的上下文向量对网络的约束, 预测精度较好; 本文模型在时空注意机制基础上增加了空间

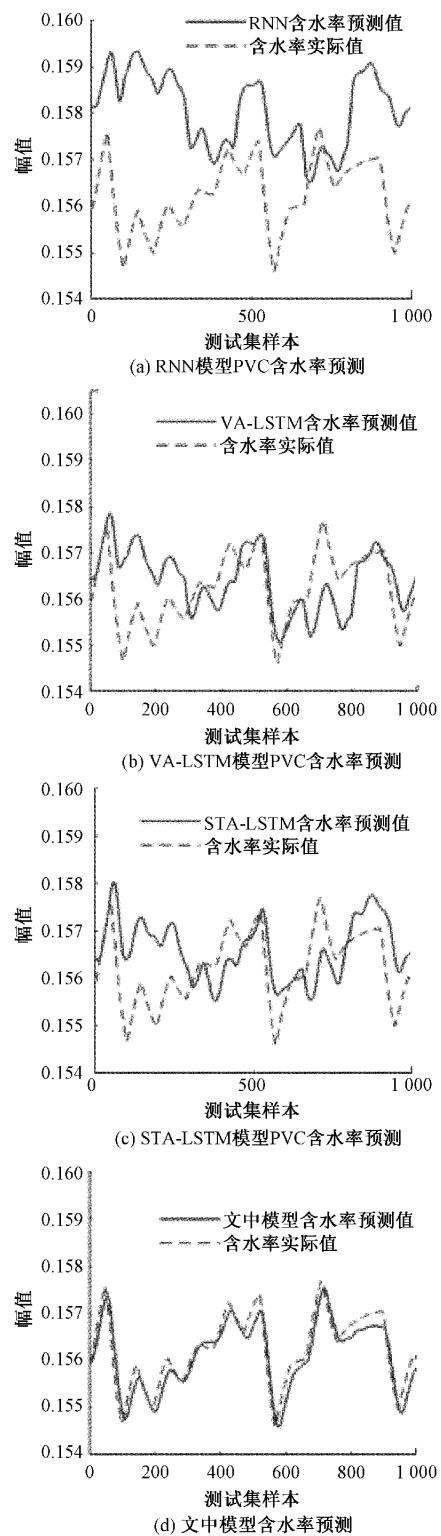


图 11 模型含水率预测效果对比

注意机制对权重的校正及子窗口内细胞状态信息补偿, 提高了网络自主学习能力, 含水率预测精度优于其他 3 种模型, 同时, 表 1 数据表明文中模型 RMSE 数值最小、 R^2 数值最大。

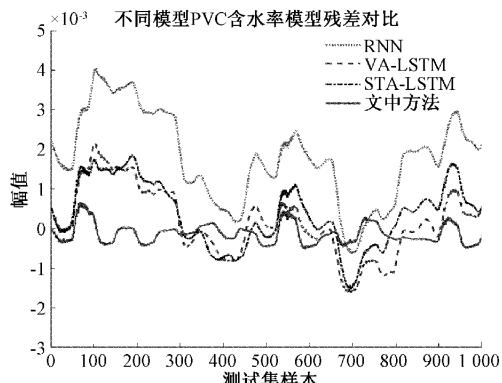


图 12 模型残差对比

4 结 论

文中提出一种适用于 PVC 干燥系统含水率预测的 LSTM 模型, 为适配与干燥工段变量之间的动态特征, 在时空注意机制网络结构下, 增加了时空注意机制权重校正规则及信息补偿机制, 可提升模型对干燥对象的学习能力及含水率预测精度, 依据预测的含水率变化趋势可对干燥系统控制变量做出指导, 提升系统平稳性及 PVC 产品品质。此模型也可推广于存在较大时序延迟特性及输入变量与质量变量之间存在强关联特性的对象。最后, 由于网络结构较为复杂、超参数利用 RMSE 指标在约定集合遍历确定不具有精确性, 后需研究可致力于网络的超参数整定及模型训练速度优化。

参考文献

- [1] KONG X, GE Z. Deep learning of latent variable models for industrial process monitoring [J]. IEEE Transactions on Industrial Informatics, 2021, DOI: 10.1109/TII.2021.3134251.
- [2] SUN Q, GE Z. Deep learning for industrial KPI prediction: When ensemble learning meets semi-supervised data [J]. IEEE Transactions on Industrial Informatics, 2020, 17(1): 260-269.
- [3] KHDHIR R, BELGHITH A. Innovative solutions for design and fabrication of deep learning based soft sensor [J]. IJCSNS, 2022, 22(2): 131.
- [4] REN L, WANG T, LAILI Y, et al. A data-driven self-supervised lstm-deepfm model for industrial soft sensor [J]. IEEE Transactions on Industrial Informatics, 2021, 18(9): 5859-5869.
- [5] ZHOU J, WANG X, YANG C, et al. A novel soft sensor modeling approach based on difference-LSTM for complex industrial process [J]. IEEE Transactions on Industrial Informatics, 2021, 18(5): 2955-2964.
- [6] YUAN X, ZHOU J, HUANG B, et al. Hierarchical quality-relevant feature representation for soft sensor modeling: A novel deep learning strategy [J]. IEEE Transactions on Industrial Informatics, 2019, 16(6): 3721-3730.
- [7] SUN Q, GE Z. A survey on deep learning for data-driven soft sensors [J]. IEEE Transactions on Industrial Informatics, 2021, 17(9): 5853-5866.
- [8] CURRERI F, PATANE L, XIBILIA M G. RNN and LSTM based soft sensors transferability for an industrial process [J]. Sensors, 2021, 21(3): 823.
- [9] YUAN X, GE Z, HUANG B, et al. Semisupervised JITL framework for nonlinear industrial soft sensing based on locally semisupervised weighted PCR [J]. IEEE Transactions on Industrial Informatics, 2016, 13(2): 532-541.
- [10] YUAN X, ZHOU J, WANG Y. A spatial-temporal LWPLS for adaptive soft sensor modeling and its application for an industrial hydrocracking process [J]. Chemometrics and Intelligent Laboratory Systems, 2020, 197: 103921.
- [11] YU J. A Bayesian inference based two-stage support vector regression framework for soft sensor development in batch bioprocesses [J]. Computers & Chemical Engineering, 2012, 41: 134-144.
- [12] 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.
- [13] WANG Y, WU D, YUAN X. A two-layer ensemble learning framework for data-driven soft sensor of the diesel attributes in an industrial hydrocracking process [J]. Journal of Chemometrics, 2019, 33(12): e3185.
- [14] YUAN X, QI S, WANG Y. Stacked enhanced auto-encoder for data-driven soft sensing of quality variable [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(10): 7953-7961.
- [15] KATARIA G, SINGH K. Recurrent neural network based soft sensor for monitoring and controlling a reactive distillation column [J]. Chemical Product and Process Modeling, 2017, 13(3): 20170044.
- [16] BALLESTEROS M, DYER C, SMITH N A. Improved transition-based parsing by modeling characters instead of words with LSTMs [J]. ArXiv Preprint, 2015, arXiv:1508.00657.
- [17] YUAN X, LI L, WANG Y. Nonlinear dynamic soft sensor modeling with supervised long short-term memory network [J]. IEEE Transactions on Industrial Informatics, 2019, 16(5): 3168-3176.

- [18] YUAN X, LI L, WANG Y, et al. Deep learning for quality prediction of nonlinear dynamic processes with variable attention-based long short-term memory network [J]. *The Canadian Journal of Chemical Engineering*, 2020, 98(6): 1377-1389.
- [19] YUAN X, LI L, SHARDT Y A W, et al. Deep learning with spatiotemporal attention-based LSTM for industrial soft sensor model development[J]. *IEEE Transactions on Industrial Electronics*, 2020, 68(5): 4404-4414.
- [20] FENG L, ZHAO C, SUN Y. Dual attention-based encoder-decoder: A customized sequence-to-sequence learning for soft sensor development [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(8): 3306-3317.
- [21] ZHENG J, MA L, WU Y, et al. Nonlinear dynamic soft sensor development with a supervised hybrid CNN-LSTM network for industrial processes[J]. *ACS Omega*, 2022, 7(19): 16653-16664.
- [22] 邢红涛, 郭江龙, 刘书安, 等. 基于 CNN-LSTM 混合神经网络模型的 NO_x 排放预测[J]. *电子测量技术*, 2022, 45(2): 98-103.
- [23] 王朝阳, 李丽敏, 温宗周, 等. 基于时间序列和 CNN-LSTM 的滑坡位移动态预测[J]. *国外电子测量技术*, 2022, 41(3): 1-8.
- [24] 谭峰, 李成南, 萧红, 等. 基于 LSTM 循环神经网络的数控机床热误差预测方法[J]. *仪器仪表学报*, 2020, 41(9): 79-87.
- [25] 陈铁, 陈一夫, 李咸善, 等. 基于 SDS-SSA-LSTM 的变压器油中溶解气体浓度预测[J]. *电子测量技术*, 2022, 45(12): 6-11.
- [26] 李孟威, 史元浩, 杨彦茹, 等. 融合 EMD 和 LSTM 的受热面积灰预测研究[J]. *电子测量与仪器学报*, 2020, 34(11): 166-172.
- [27] 张敏, 袁辉. 拉依达(PauTa)准则与异常值剔除[J]. *郑州工业大学学报*, 1997(1): 87-91.
- [28] 李丽敏, 温宗周, 王真, 等. 基于自学习 Pauta 和 Smooth 的地下水位异常值检测和平滑处理方法[J]. *西安工程大学学报*, 2018, 32(5): 604-608.

作者简介

张帅杰(通信作者),硕士研究生,主要研究方向为模型辨识、工业模型预测控制及软测量、PID 控制。

E-mail:2764778748@qq.com

郭小萍,博士,教授,硕士研究生导师,主要研究方向为复杂系统建模与控制、过程监测与故障诊断、间歇过程质量预测与控制。

E-mail:1362331028@qq.com

臧春华,教授,硕士研究生导师,主要研究方向为复杂系统建模与控制、智能测控技术。

E-mail:zch1884246@126.com