

DOI: 10.11949/j.issn.0438-1157.20181373

基于交叉迭代BLSTM网络的乙烯裂解炉建模

顾恒昌¹, 牟鹏^{2,3}, 李建伟¹

(¹ 北京化工大学化工资源有效利用国家重点实验室, 北京 100029; ² 北京化工大学信息科学与技术学院, 北京 100029;
³ 智能过程系统工程教育部工程研究中心, 北京 100029)

摘要: 数据驱动的乙烯裂解炉模型通常忽视了裂解炉结构和反应机理, 存在预测误差偏大的缺点, 为此提出基于知识和数据融合驱动的乙烯裂解炉乙烯收率等关键参数的双向长短期记忆网络(BLSTM)预测模型。为了解决BLSTM建模缺少可用数据的问题, 提出了一种采用交叉迭代的BLSTM(CIBLSTM)模型。所提CIBLSTM模型采用了正反向交叉迭代方法, 逐步逼近所缺数据的真实值, 进而建立乙烯裂解炉的预测模型。为了验证所提CIBLSTM模型的有效性, 选取9种工业实际原料与分析数据进行仿真测试, 仿真结果验证了所提的CIBLSTM模型的有效性与实用性, 所提方法也可应用于其他复杂化工过程建模。

关键词: 深度学习; 神经网络; 裂解炉; 模型; 训练; 预测

中图分类号: TQ 021.8

文献标志码: A

文章编号: 0438-1157 (2019) 02-0548-08

Modeling and application of ethylene cracking furnace based on cross-iterative BLSTM network

GU Hengchang¹, MU Peng^{2,3}, LI Jianwei¹

(¹ State Key Laboratory of Chemical Resources Engineering, Beijing University of Chemical Technology, Beijing 100029, China;

² College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China;

³ Engineering Research Center of Intelligent PSE, Ministry of Education of China, Beijing 100029, China)

Abstract: The ethylene cracking furnace model based on BP and RBF ignores the reaction mechanism of cracking furnace and has the disadvantage of large prediction error. Therefore, a two-way long-term time-memory network (BLSTM) model based on the reaction mechanism of ethylene cracking furnace to forecast key parameters such as ethylene yield is proposed. To solve the problem that BLSTM modeling lacks available data, a BLSTM model using cross iteration (CIBLSTM) is provided. The CIBLSTM model uses a forward-reverse cross-iteration method to gradually approximate the true value of the lacks available data, and then a prediction model is established for the ethylene cracking furnace. To verify the validity of the proposed CIBLSTM model, nine industrial actual raw materials and analytical data were selected for simulation test. The simulation results verify the validity and practicability of the proposed CIBLSTM model. The proposed method can also be applied to other complex chemical processes modeling.

Key words: deep learning; neural network; cracking furnace; model; training; prediction

收稿日期: 2018-11-19 修回日期: 2018-12-11

通信作者: 李建伟(1964—), 男, 博士, 教授, lijw@mail.buct.edu.cn

第一作者: 顾恒昌(1992—), 男, 博士研究生, guhengchang@126.com

基金项目: 国家自然科学基金重点项目(61533003)

引用本文: 顾恒昌, 牟鹏, 李建伟. 基于交叉迭代BLSTM网络的乙烯裂解炉建模[J]. 化工学报, 2019, 70(2): 548–555

Citation: GU Hengchang, MU Peng, LI Jianwei. Modeling and application of ethylene cracking furnace based on cross-iterative BLSTM network[J]. CIESC Journal, 2019, 70(2): 548–555

引言

随着乙烯装置的规模大型化,乙烯裂解炉的单体生产能力规模越来越大,工业应用对于乙烯裂解模型的精度与适应能力的要求越来越高,与此同时,乙烯裂解过程的反应网络非常复杂且与传热、传质、传能过程高度耦合,基于Kumar模型反应动力学的乙烯裂解炉过程建模方法需要针对每种原料重新建模或整定参数^[1-2],一定程度限制了机理模型在乙烯裂解炉中的实际应用。近年来采用神经网络的乙烯裂解炉建模方法克服了这一缺点并得到广泛的应用。

然而,这类神经网络黑箱模型^[3]在训练时往往会忽略对象的反应机理,通常需要大量的训练数据,且经常在测试数据超出训练数据集范围时误差很大^[3]。

Hua等^[4-8]从反应动力学入手,以反应动力学拓扑结构指导设计神经网络结构,提出了一种基于卷积神经网络(CNN)的乙烯裂解炉建模方法,取得了很好的效果。不难看出,神经网络结构越接近待建模过程,其适应性与有效性越好。裂解炉的非稳态过程通常采用微分方程描述,其机理模型采用一系列微分方程的迭代^[9-11]模拟传热、传质、传能与反应网络的耦合过程,最终通过数值求解得到模型,但需要针对每种原料建模,模型的适应性较差。BP与RBF神经网络模型结构简单,已经广泛应用于过程建模,但是数据处理以及特征映射能力有限。深度神经网络具有强大的数据处理与特征映射的能力,成为近几年的研究热点之一。

近年来有大量关于深度学习神经网络的研究报道,深度学习神经网络尤其是递归神经网络(RNN)^[12-13]在解决神经网络本身隐含层增多后带来训练问题的同时,也提供了有利的分析和挖掘时序数据与数据间关系的方法。特别是LSTM网络以其分别利用“长时记忆”(全流程信息)和“短时记忆”(局部特征信息)的学习能力^[14-15],广泛应用于语义识别领域^[16]与工业过程建模^[17-18]。

文献[19-23]提出的双向长短时间记忆网络(BLSTM)进一步改进了传统的LSTM算法,一方面其输出同时考虑了前后因素的影响,以后续结果约束先前过程的取值范围,从而提高建模的精度;另一方面正向网络和反向网络构成了信息闭环,能够更好地验证和修正过程误差信息^[24],具有更强的鲁

棒性。

建立LSTM及BLSTM模型时需要较多的过程输入输出数据。然而,大多数工业过程受到工况以及可用检测措施的限制,存在可用的数据量少的情況,这限制了BLSTM在工业过程中的应用。据此,本文提出采用迭代双向交叉LSTM网络(ICBLSTM)构建乙烯裂解炉的预测模型。首先研究裂解原料的相似性,界定适应ICBLSTM建模方法的原料集;其次提出采用LSTM网络模拟裂解反应过程的双向交叉LSTM建模方法及解决所需建模数据可用性的迭代双向交叉LSTM建模方法;最后采用工业实际应用的案例验证提出的乙烯裂解炉深度学习迭代双向交叉LSTM建模方法的有效性与实用性。

1 原料相似性分析

裂解所用原料是一类性质复杂的混合物,不同类别原料间由于所含成分不一样,裂解反应也不尽相同,例如,原料中芳香烃含量较高会严重影响裂解炉的运行及乙烯和丙烯产物的收率。因此,应依据原料建立乙烯裂解炉的模型,有必要在建模前筛选用于ICBLSTM建模的原料集。

为了便于说明,下面以石脑油为例讨论筛选ICBLSTM建模原料集的方法。乙烯裂解炉建模实践中通常用石脑油的以下参数作为其性质的表征^[25]:(1)密度;(2)蒸馏曲线10%沸程(℃);(3)蒸馏曲线30%沸程(℃);(4)蒸馏曲线50%沸程(℃);(5)蒸馏曲线70%沸程(℃);(6)蒸馏曲线90%沸程(℃);(7)族组成(PNA:原料烃分子中所含各族烃的质量分数P—烷族烃,N—环烷族烃,A—芳香族烃)。

实际工业应用中可用于机理建模的原料数据有限,限制了应用聚类等数据挖掘方法的原料筛选方法,为此考虑采用基于Euler距离的相似度^[26]分析方法分析原料的相似性,原料的相似度越高其Euler距离越小,裂解性质也相对较为一致;Euler距离越大,则其原料相似度越低,裂解性质差别越大。

计算Euler距离前,需要对原料各性质参数进行归一化,以解决原料性质参数的数值差异过大带来的不良影响。假设一共有 N 个原料,原料 m 与 n 都有 S 个性质参数 m_i 与 n_i , $i \in \{1, 2, \dots, S\}$,则归一化后的参数 $\tilde{m}_i$ 和 $\tilde{n}_i$ 定义为

$$\tilde{m}_i = \frac{m_i - m_{\min,i}}{m_{\max,i} - m_{\min,i}}; \tilde{n}_i = \frac{n_i - n_{\min,i}}{n_{\max,i} - n_{\min,i}} \quad (1)$$

式中,下角标 $\max, i$ 为 N 个原料中 i 性质参数的

最大值; $\min_i$ 为 N 个原料中 i 性质参数的最小值, 则物料 m 与 n 的相似度 L_{mn} 定义为


$$L_{mn} = \sqrt{\sum_{i=1}^S (\tilde{m}_i - \tilde{n}_i)^2} \quad (2)$$

原料相似度 L_{mn} 的阈值可以按照实际应用对模型准确性^[27]的要求确定。对于乙烯裂解建模过程而言, 若关键物质的模型预测收率与实际生产数据相差超过 ε , 则模型失效, 对应的相似度 L_{mn} 可以作为相似度阈值 L_0 。如果待预测的原料与训练原料之间的相似度 $L_{mn} < L_0$, 则所建模型适用于该预测原料。


2 双向 LSTM 模型

乙烯裂解炉沿炉管的裂解特性为非线性, 为了提高建模精度, 有必要依据该非线性沿炉管选择多个数据采集点。为了讨论的方便, 考虑沿炉管等距取 4 个数据采集点加上炉管入口和炉管出口一共 6 个数据采集点, 参照乙烯裂解炉建模的实践选取温度、压力、物质性质和物质组成数据用于训练正向和反向两个 LSTM 神经网络。这 6 个数据组成的矩阵定义为 $X_i (i=1, 2, 3, 4, 5, 6)$ 。每个采集点的数据矩阵 X_i 由 11 个物质百分比、9 个原料属性以及温度和压力共 22 个属性构成行, A 个训练原料 (如选用 3 个原料, 则 $A=3$), B 个训练温度数据 (如选择 $B=5$, 则包括工作点、工作点 $\pm 5^\circ\text{C}$ 、工作点 $\pm 10^\circ\text{C}$ 共 5 点温度数据), C 个训练压力数据 (如 $C=5$, 包括工作点、工作点 ± 5 kPa、工作点 ± 10 kPa 共 5 个压力数据), 则矩阵 X_i 的列为 $A \times B \times C$ (如上示例则为 75) 列。拟选用如图 1 所示的标准 LSTM 网络结构。

采用微分方程迭代建立裂解炉机理模型的迭代结构与图 1(a) 的 LSTM 整体结构具有相似性。同时, LSTM 的内部结构与裂解炉动力学反应网络结构也具有很多相似性, 从而确保采用 LSTM 网络模拟乙烯裂解炉具有极强的适应能力。如图 1(b) 所示的 LSTM 的遗忘门结构, 表示是否遗忘信息, 在乙烯裂解过程中, 遗忘信息主要指随着反应物的消耗, 部分反应的速率会逐渐减慢甚至消失。LSTM 结构包含如图 1(c) 所示的记忆门结构。记忆门主要控制是否需要更新信息, 对于乙烯裂解的反应过程, 沿着炉管方向的温度、压力等会发生变化, 需要随时更新, 以更加准确地描述裂解炉管中发生的变化。LSTM 的最后一个函数结构决定输出哪些信息, 以及将哪些信息传递到下一个模块。




(a) net-structure of LSTM



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

(b) forget gate



$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C)$$

(c) memory gate

图 1 LSTM 结构

Fig.1 Structure of LSTM

为了说明的方便, 用于训练建模的 BLSTM 中的 LSTM 选用如图 1(a) 所示的 3 隐含层模型, 则构建如图 2 所示的正向神经网络 LSTM1, 用 f 表示如下

$$x_z = f(x_{z-3}, x_{z-2}, x_{z-1}) \quad (z=4, 5, 6) \quad (3)$$

反向的神经网络 LSTM2 (图 2), 用 g 表示如下

$$x_z = g(x_{z+1}, x_{z+2}, x_{z+3}) \quad (z=1, 2, 3) \quad (4)$$

采用 BPTT 算法^[28]训练和确定 LSTM1 与 LSTM2 中各模块的参数, 用于保存乙烯裂解模型的过程知识。所提模型可随工业实际应用数据采集点的增减相应增减 LSTM1 与 LSTM2 的递推关系。




图2 LSTM1与LSTM2的训练流程

Fig.2 Model structure and training process of LSTM1 and LSTM2

3 交叉迭代双向LSTM模型

双向LSTM模型需要多组输入数据以求解输出,例如需要点1、2、3来预测点4,而仅知道点1则无法预测点4。对于裂解炉的双向LSTM模型而言,并不已知裂解炉管内的过程数据。为此提出利用图2训练的LSTM1和LSTM2构建如图3所示的交叉迭代的双向LSTM即ICBLSTM结构建立裂解炉的预测模型。

利用新原料的实际性质分析测试数据集构建矩阵 $\mathbf{X}_1$, $\mathbf{X}_1$ 在整个迭代过程中保持不变,其余的5个数据采集点利用原料相似性分析的结果,利用训练原料机理模型相应数据采集点的平均值作为新原料的初始输入数据矩阵 $\widetilde{\mathbf{X}}_z^k$ (z 为数据采集点序号, $z=2,3,4,5,6$; k 为迭代次数, $k \geq 1$)并进行归一化。

设初始循环次数 $k=1$,则第 k 次迭代的迭代步骤如下。

(1)调用式(4)推出 $\mathbf{X}_4$ 的更新值 $\widetilde{\mathbf{X}}_4^{k+1}$

$$\widetilde{\mathbf{X}}_4^{k+1} = f(\widetilde{\mathbf{X}}_1^k, \widetilde{\mathbf{X}}_2^k, \widetilde{\mathbf{X}}_3^k) \quad (5)$$

(2)调用式(5)推出 $\mathbf{X}_3$ 的更新值 $\widetilde{\mathbf{X}}_3^{k+1}$

$$\widetilde{\mathbf{X}}_3^{k+1} = g(\widetilde{\mathbf{X}}_6^k, \widetilde{\mathbf{X}}_5^k, \widetilde{\mathbf{X}}_4^{k+1}) \quad (6)$$

(3)调用式(6)推出 $\mathbf{X}_5$ 的更新值 $\widetilde{\mathbf{X}}_5^{k+1}$

$$\widetilde{\mathbf{X}}_5^{k+1} = f(\widetilde{\mathbf{X}}_2^k, \widetilde{\mathbf{X}}_3^k, \widetilde{\mathbf{X}}_4^{k+1}) \quad (7)$$

(4)调用式(7)推出 $\mathbf{X}_2$ 的更新值 $\widetilde{\mathbf{X}}_2^{k+1}$

$$\widetilde{\mathbf{X}}_2^{k+1} = g(\widetilde{\mathbf{X}}_3^k, \widetilde{\mathbf{X}}_4^{k+1}, \widetilde{\mathbf{X}}_5^{k+1}) \quad (8)$$

(5)调用式(8)推出 $\mathbf{X}_6$ 的更新值 $\widetilde{\mathbf{X}}_6^{k+1}$

$$\widetilde{\mathbf{X}}_6^{k+1} = f(\widetilde{\mathbf{X}}_3^k, \widetilde{\mathbf{X}}_4^k, \widetilde{\mathbf{X}}_5^{k+1}) \quad (9)$$

若迭代后的结果不满足式(9)的收敛条件或者式(10)的迭代次数要求,则继续迭代,否则终止迭代,输出乙烯裂解炉的ICBLSTM模型。

$$\Delta \mathbf{X}_6^k = \sum_j^u \left(\frac{\widetilde{\mathbf{X}}_6^k(j) - \widetilde{\mathbf{X}}_6^{k+1}(j)}{\widetilde{\mathbf{X}}_6^k(j)} \right)^2 \leq 0.01 \quad (10)$$

$$k \geq 3000 \quad (11)$$




图3 交叉迭代双向LSTM的结构

Fig.3 Structure of ICBLSTM

式中, u 为裂解反应动力方程所涉及的组分总数, j 是裂解反应动力方程的组分编号, Δx_6^k 是裂解炉管出口物资组成的迭代误差。按照以下步骤确定模型适应的原料: ① 计算测试原料与训练建模原料的相似度; ② 按照相似度 Euler 距离由小到大逐步测试, 根据测试结果满足应用需求(如精度)的程度, 设置相似度 Euler 距离的阈值 L_0 ; ③ 与训练建模的原料相似度小于 L_0 的原料可以适用所建的 ICBLSTM 模型, 否则需新建模型。

4 实例分析

选用结构参数和操作参数如表 1 所示的 SL-1

型裂解炉作为验证实例。

表 1 裂解炉结构参数及操作参数

Table 1 Structure parameters and operation parameters of cracking furnace

Structure parameters	Value	Operation parameters	Value
furnace tube group	6	feedstock flow/(kg/h)	890.625
tube pass	2	steam/hydrocarbon ratio	0.60
arrangement	16/8	coil inlet temperature/K	875
inner diameter/m	0.051/0.073	coil outlet temperature/K	1122
outer diameter/m	0.063/0.086	coil outlet pressure/kPa	178
length/m	13.681/14.921		
tube pitch/m	0.112/0.154		

表2 物料性质及相似度结果

Table 2 Material properties and similarity results

No.	Density, 20°C/(g/cm ³)	10% boiling range/°C	30% boiling range/°C	50% boiling range/°C	70% boiling range/°C	90% boiling range/°C	<i>P</i>	<i>N</i>	<i>A</i>	<i>L_{mn}</i>
1	0.6927	54.5	73	90	107	127	0.7223	0.2234	0.0529	0
2	0.7255	86.9	105.4	121.3	137.3	156.5	0.663	0.2605	0.0762	1.382
3	0.7488	85.2	114.8	131.8	147.5	162.4	0.4631	0.4856	0.0483	1.7751
4	0.7022	60	75	88.5	103	124	0.7069	0.2248	0.0566	2.1174
5	0.7103	64	81	98	117	143	0.6669	0.2605	0.068	2.5121
6	0.7389	77	106	135	163	190	0.6898	0.1916	0.116	2.9868
7	0.7093	69	88	103	119	149	0.6409	0.3172	0.0419	0.0023
8	0.7375	85.2	105	120.3	136.2	156.1	0.5609	0.3493	0.0893	0.0092
9	0.6894	36.2	46.9	65	104.7	137.6	0.7379	0.1742	0.0864	0.0133

选用9种石脑油作为实例的原料,以原料1作为基准,其他原料与原料1的相似度 L_{mn} 如表2所示。从表2不难看出第7、8、9类原料与原料1相近度较高应归为一类,选取该类原料作为建模样本集,并按照3:1的比例随机选取训练样本集和泛化样本第1、7、8作为训练样本集。表2中的 P 、 N 、 A 为石脑油中的原料的族组成: P 为烷烃含量占比, N 为环烷烃含量占比, A 为芳香烃含量占比。

采用建立的石脑油裂解 Kumar 机理模型辅助 ICBLSTM 建模,训练正向及反向 LSTM 并采用石脑油9测试 ICBLSTM 框架的预测能力,其中10个关键组分的结果如表3所示。

由表3可知,裂解炉关键物质收率的相对误差小于1%,远远好于一般BP^[29]、RBF^[30]等神经网络的建模结果。非关键物质的收率误差较大(C_3H_8 为10.51%, C_4H_6 为7.24%)。但由于这两种物质的实际收率较低(小于5%),因此在实际工业应用中这类误差影响不大。不难看出深度学习与机理混合建模的方法更适用于乙烯裂解炉的建模。

表3的结果也表明,所提出模型在不需重新整定建模参数的条件下,结果精度依然较高,说明 ICBLSTM 模型对于原料具有较好的适应能力。

表3 石脑油9预测的测试结果

Table 3 Test results of naphtha 9

物质	目标产量/(%) (质量)	预测收率/(%) (质量)	误差/%
H ₂	12.36	12.10	2.19
CH ₄	22.48	22.27	0.93
C ₂ H ₄	22.54	22.35	0.81
C ₂ H ₆	4.67	4.60	1.38
C ₃ H ₆	9.86	9.86	0.00
C ₃ H ₈	4.42	4.00	10.51
C ₄ H ₁₀	5.32	5.14	3.58
C ₄ H ₈	6.45	6.14	4.94
C ₄ H ₆	3.03	2.82	7.24
C ₄ '	5.25	5.13	2.36

逐步对相似度较差的原料进行预测测试,测试结果如表4所示。参照工业实际应用经验以模型关键物质收率最大误差 $\varepsilon=5\%$ 作为判据,选择预测原料相似度的阈值 L_0 。

由表4已知,对于最偏离训练原料属性的原料6,关键物质乙烯的误差为34.19%,丙烯误差为3.96%,关键物质乙烷的收率误差 $>\varepsilon$,因此模型已经不能正常工作,原料6与建模原料的裂解性质差异较大,所建模型不适用于原料6,并依据 ε 确定实例建立 ICBLSTM 乙烯裂解炉模型的原料相似度阈值

表4 其他石脑油预测的测试结果

Table 4 Test results of other naphtha

石脑油编号	C ₂ H ₄ 产量/(%) (质量)	C ₂ H ₄ 预测收率/(%) (质量)	C ₂ H ₄ 误差/%	C ₃ H ₆ 产量/(%) (质量)	C ₃ H ₆ 预测收率/(%) (质量)	C ₃ H ₆ 误差/%
2	31.78	30.66	3.51	9.87	9.95	0.90
3	31.56	30.54	3.22	10.53	10.7	1.66
4	30.22	29.23	3.27	13.61	13.9	2.16
5	30.63	29.18	4.76	9.95	9.94	0.05
6	29.08	19.14	34.19	9.44	9.07	3.96

$L_c=2.5$, 相似度大于 2.5 的原料需要采用提出的方法重新建模。

5 结 论

乙烯裂解过程具有高度相关性和多非稳态过程的特点, 基于 LSTM 的深度学习建模方法可以用相应的网络结构有效地描述该类过程。对于工业实际应用中经常出现缺少可用的建模所需数据的情况, 提出了 ICBLSTM 模型, 该模型采用迭代方法填补空缺的所需数据。所建立的 ICBLSTM 模型原料相似度阈值 L_c 可达到 2.5, 对原料具有较强的适应性, 同时比传统神经网络模型精度更高。所提出方法为乙烯裂解炉的建模研究提供了新思路, 拓宽了深度学习在流程工业的应用范围。

参考文献

- [1] Kumar P, Kunzru D. Modeling of naphtha pyrolysis[J]. Industrial & Engineering Chemistry Process Design & Development, 1985, **24**: 774-782.
- [2] Sadrameli S M. Thermal/catalytic cracking of hydrocarbons for the production of olefins: a state-of-the-art review (I): Thermal cracking review[J]. Fuel, 2015, **140**: 102-115.
- [3] Keyvanloo K, Sedighi M, Towfighi J. Genetic algorithm model development for prediction of main products in thermal cracking of naphtha: comparison with kinetic modeling[J]. Chemical Engineering Journal, 2012, **209**: 255-262.
- [4] Hua F, Zhou F, Tong Q. Modeling ethylene cracking process by learning convolutional neural networks[J]. Computer Aided Chemical Engineering, 2018, **44**: 841-846.
- [5] Yuan B, Li J, Du W, et al. Study on co-cracking performance of different hydrocarbon mixture in a steam pyrolysis furnace[J]. Chinese Journal of Chemical Engineering, 2016, **24**: 1252-1262.
- [6] Zhou F, Qiu T, Chen B Z. Analyzing and modeling ethylene cracking process with complex networks approach[J]. Computer Aided Chemical Engineering, 2015, **37**: 407-412.
- [7] Zhou F, Qiu T, Chen B Z. Improvement of ethylene cracking reaction network with network flow analysis algorithm[J]. Computers & Chemical Engineering, 2016, **91**: 182-194.
- [8] Hu G H. Coupled simulation of convection section with dual stage steam feed mixing of an industrial ethylene cracking furnace[J]. Chemical Engineering Journal, 2016, **286**: 436-446.
- [9] 高荣华.《化工原理》课程中的微分方程问题[J]. 扬州职业大学学报, 1999, **3**(3): 45-47.
Gao R H. Differential equation in the course of chemical engineering theory[J]. Journal of Yangzhou Polytechnic College, 1999, **3**(3): 45-47.
- [10] 沙利, 张红梅, 高金森, 等. 乙烯裂解炉管内流动反应历程的数值模拟(I): 二维流动反应数学模型的建立[J]. 化工学报, 2003, **54**(3): 392-397.
Sha L, Zhang H M, Gao J S, et al. Numerical simulation on flow-reaction progress in tubular reactor of steam crackers(I): Development of two-dimensional flow-reaction model[J]. Journal of Chemical Industry and Engineering(China), 2003, **54**(3): 392-397.
- [11] 华丰, 方舟, 邱彤. 乙烯裂解炉反应与传热耦合的智能混合建模与模拟[J]. 化工学报, 2018, **69**(3): 923-930.
Hua F, Fang Z, Qiu T. Recirculation and reaction hybrid intelligent modeling and simulation for industrial ethylene cracking furnace[J]. CIESC Journal, 2018, **69**(3): 923-930.
- [12] Williams G, Baxter R, He H X, et al. A comparative study of RNN for outlier detection in data mining[C]//IEEE International Conference on Data Mining, 2002. Proceedings, Maebashi, Japan: IEEE, 2002: 709-712.
- [13] Sak H, Senior A, Beaufays F. Long short-term memory recurrent neural network architectures for large scale acoustic modeling[C]//Fifteenth Annual Conference of the International Speech Communication Association. Singapore: Interspeech, 2014.
- [14] Greff K, Srivastava R K, Koutnik J, et al. LSTM: a search space odyssey[J]. IEEE Transactions on Neural Networks & Learning Systems, 2015, **28**: 2222-2232.
- [15] Sainath T N, Vinyals O, Senior A, et al. Convolutional, long short-term memory, fully connected deep neural networks[C]//Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference on. IEEE, Brisbane, QLD, Australia: IEEE, 2015: 4580-4584.
- [16] 彭敏, 杨绍雄, 朱佳晖. 基于双向 LSTM 语义强化的主题建模[J]. 中文信息学报, 2018, **32**(4): 40-49.
Peng M, Yang S X, Zhu J H. Semantic enhanced topic modeling by bi-directional LSTM[J]. Journal of Chinese Information Processing, 2018, **32**(4): 40-49.
- [17] 李泽龙, 杨春节, 刘文辉, 等. 基于 LSTM-RNN 模型的铁水硅含量预测[J]. 化工学报, 2018, **69**(3): 992-997.
Li Z L, Yang C J, Liu W H, et al. Research on hot metal Si-content prediction based on LSTM-RNN[J]. CIESC Journal, 2018, **69**(3): 992-997.
- [18] Zhang X, Zou Y, Li S, et al. Product yields forecasting for fccu via deep bi-directional LSTM network[C]//2018 37th Chinese Control Conference (CCC). IEEE, 2018: 8013-8018.
- [19] Lefebvre G, Berlemont S, Mamalet F, et al. BLSTM-RNN based 3D gesture classification[C]//International Conference on Artificial Neural Networks. Heidelberg, Berlin: Springer, 2013: 381-388.
- [20] Hakkani-Tür D, Tür G, Celikyilmaz A, et al. Multi-domain joint semantic frame parsing using bi-directional RNN-LSTM[C]//Proceedings of the 17th Annual Meeting of the International Speech Communication Association (INTERSPEECH 2016). Baixas, France: ISCA2016: 715-719.
- [21] Yao Y, Huang Z. Bi-directional LSTM recurrent neural network for Chinese word segmentation[C]//International Conference on Neural Information Processing. Cham: Springer, 2016: 345-353.

- [22] Wang P, Qian Y, Zhao H, et al. Learning distributed word representations for bidirectional LSTM recurrent neural network [C]//Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. 2016: 527-533.
- [23] 马涛. 组合预测方法及其应用研究[D]. 兰州: 兰州大学, 2017.
Ma T. A research on combining forecasting methods and its applications[D]. Lanzhou: Lanzhou University, 2017.
- [24] 韩昭蓉, 黄廷磊, 任文娟, 等. 基于Bi-LSTM模型的轨迹异常点检测算法[J]. 雷达学报, 2018, (5):1-8.
Han Z R, Huang T L, Ren W J, et al. Trajectory outlier detection algorithm based on bi-LSTM Model[J]. Journal of Radars, 2018, (5): 1-8.
- [25] 张利军, 张永刚, 王国清, 等. 石脑油的组成预测方法[J]. 化工进展, 2011, 30(2): 278-283.
Zhang L J, Zhang Y G, Wang G Q, et al. Research on prediction of naphtha composition based on commercial indices[J]. Chemical Industry and Engineering Progress, 2011, 30(2): 278-283.
- [26] 张杰, 黄翔, 李泮泉, 等. 基于T-scan测量的薄壁钣金件孔特征重构[J]. 工程科学学报, 2017, 39(6): 917-923.
Zhang J, Huang X, Li S G. Hole feature reconstruction of thin-walled sheet metal parts based on T-scan measurement[J]. Chinese Journal of Engineering, 2017, 39(6): 917-923.
- [27] 王飞. 乙烯装置中碳二加氢反应器的稳态、动态建模与优化 [D]. 上海: 华东理工大学, 2012.
Wang F. Steady-state, dynamic simulation and optimization of acetylene hydrogenation reactor in ethylene plant[D]. Shanghai: East China University of Science and Technology, 2012.
- [28] Prokhorov D V, Si J, Barto A, et al. Handbook of Learning and Approximate Dynamic Programming: Chapter 15 BPTT and DAC -A Common Framework for Comparison[M]. USA: John Wiley & Sons, Inc., Online library, 2012.
- [29] 邵研硕. 乙烯生产过程能效监测系统预测评估模块实现[D]. 大连: 大连理工大学, 2017.
Zhao Y S. The implementation of forecast evaluation module in the ethylene production process inspection system of energy efficiency[D]. Dalian: Dalian University of Technology, 2017.
- [30] 耿志强, 陈杰, 韩永明. 基于模糊RBF神经网络的乙烯装置生产能力预测[J]. 化工学报, 2016, 67(3): 812-819.
Geng Z Q, Chen J, Han Y M. Ethylenen plants production capacity forecast based on fuzzy RBF neural network[J]. CIESC Journal, 2016, 67(3): 812-819.