

基于学习型人工蜂群算法优化双向GRU的乙烯产率预测

温在鑫¹, 钱斌^{1,2†}, 胡蓉^{1,2}, 金怀平¹, 杨媛媛¹

(1. 昆明理工大学 信息工程与自动化学院, 云南 昆明 650500; 2. 昆明理工大学 云南省人工智能重点实验室, 云南 昆明 650500)

摘要: 本文针对以乙烯产率为生产指标的预测问题, 基于双向门控循环单元网络(BGRU)建立乙烯产率预测模型, 以最小化模型误差为优化目标并提出一种学习型人工蜂群算法(LABC)对预测模型进行优化和设计. 在构建BGRU预测模型时, 先对乙烯裂解炉实际生产过程进行分析, 确定影响产率的关键因素并将其作为模型的输入; 再采用LABC对BGRU网络模型的结构、初始权值和阈值、训练比和动量因子进行全面的优化和设计. 在LABC中, 首先根据人工蜂群算法(ABC)特点构建强化学习(RL)框架下的状态集、动作集、奖励函数和最优混合搜索策略, 在此基础上, 提出一种深度双Q网络(DDQN)来实现最优混合搜索策略, 通过该策略可智能选择合适的搜索动作来执行针对不同状态的局部搜索. 本文通过在标准数据集和实际生产数据上的测试及算法对比, 验证了所提学习型人工蜂群算法优化的双向GRU网络(LABC_BGRU)模型具有预测精度高、适用性强的特性.

关键词: 深度强化学习; 双向GRU; 人工蜂群算法; 乙烯裂解炉; 生产能力预测

引用格式: 温在鑫, 钱斌, 胡蓉, 等. 基于学习型人工蜂群算法优化双向GRU的乙烯产率预测. 控制理论与应用, 2023, 40(10): 1746 – 1756

DOI: 10.7641/CTA.2022.20211

Ethylene yield prediction based on bi-directional GRU optimized by learning-based artificial bee colony algorithm

WEN Zai-xin¹, QIAN Bin^{1,2†}, HU Rong^{1,2}, JIN Huai-ping¹, YANG Yuan-yuan¹

(1. Faculty of Information Engineering and Automation,

Kunming University of Science and Technology, Kunming Yunnan 650500, China;

2. Yunnan Key Laboratory of Artificial Intelligence, Kunming University of Science and Technology, Kunming Yunnan 650500, China)

Abstract: Aiming at prediction problem that takes ethylene yield as production index, this paper establishes the ethylene yield prediction model based on the bi-directional gated recurrent neural network (BGRU), a learning based artificial bee colony algorithm (LABC) is proposed to optimize and design the prediction model with the goal of minimizing model error. When constructing the BGRU prediction model, the actual production process of ethylene cracking furnace is analyzed to determine the key factors that affect the yield and take them as the input of the model. In addition, LABC is designed to comprehensively evolve and design the structure, initial weight and threshold, training ratio and momentum factor of the BGRU model. In LABC, the state set, action set, reward function and optimal hybrid search strategy in reinforcement learning framework are constructed according to the characteristics of artificial bee colony algorithm (ABC), on this basis, a new deep double Q network (DDQN) is proposed to realize the optimal hybrid search strategy. Through this strategy, appropriate search actions can be intelligently selected to perform local search for different states. Results of experiments and comparisons on actual production data and standard data set demonstrate that LABC_BGRU model has the characteristics of high prediction accuracy and strong applicability.

Key words: deep reinforcement learning; bi-directional GRU; ABC; ethylene cracking furnace; production capacity prediction

Citation: WEN Zaixin, QIAN Bin, HU Rong, et al. Ethylene yield prediction based on bi-directional GRU optimized by learning-based artificial bee colony algorithm. *Control Theory & Applications*, 2023, 40(10): 1746 – 1756

收稿日期: 2022-03-24; 录用日期: 2022-11-10.

†通信作者. E-mail: bin.qian@vip.163.com; Tel.: +86 13312529481.

本文责任编辑: 谭永红.

国家自然科学基金项目(62173169, 61963022), 云南省基础研究重点项目(202201AS070030)资助.

Supported by the National Natural Science Foundation of China (62173169, 61963022) and the Basic Research Key Project of Yunnan Province (202201AS070030).

1 引言

乙烯是有机化工基本原料, 在石油化工产业占据核心地位. 到2020年底, 乙烯加工装置的产能约占中国乙烯总产能的71.82%, 约占世界乙烯总产能的12.64%. 在乙烯实际生产过程中, 上游工艺供应和下游工艺以及外部市场需求的改变会使乙烯裂解炉的原料集变化, 这大大增加乙烯生产过程建模的难度和成本. 在当前智能制造的背景下, 研发响应快、精度高、性能稳定的乙烯裂解炉模型是实现乙烯装置智能化建设的重要任务.

流程工业生产过程的建模方法主要分为机理建模法^[1]和数据驱动建模法^[2]. 机理建模法所建立的模型具有可解释性强的优点, 但建模时需要对反应过程的内在物化机理基本完全掌握. 由于乙烯生产过程伴随着非常复杂的物化反应, 目前尚难以建立较准确的基于机理的乙烯产率预测模型. 数据驱动建模法主要包括有偏最小二乘回归、支持向量机、人工神经网络等. 该类建模方法采用一定的代数几何结构来隐式地拟合生产过程数据内部的非线性关系, 无需掌握生产过程的物化机理. 这使其在复杂反应过程的建模中得到较多应用. 譬如, 神经网络建模已成为乙烯产率预测建模的主要方法. 耿志强等^[3]针对径向基函数(radial basis function, RBF)神经网络隐藏层节点的不确定和初始中心敏感性、收敛速度过慢等问题, 提出一种基于模糊C均值的RBF神经网络模型, 并将其用于乙烯产率预测中, 得到较高的预测精度. Yu等^[4]通过历史数据对CoilSim1D进行校正, 然后用于生成样本, 并使用ANN工具箱建立产品收率模型, 获得较高的双烯收率预测精度. 然而基于数据驱动的乙烯裂解炉建模也存在缺点, 如: 神经网络的输入状态总是从前往后输出, 但在乙烯裂解过程中, 当前时刻状态受上一时刻和下一时刻状态的共同影响, 具有很强的时序相关性. 针对此类问题, Lefebvre等^[5]提出的双向长短时间记忆网络(bi-directional long short term memory, BLS-TM)一方面能分别利用“长时记忆”和“短时记忆”表示建模过程中的全局特征信息和局部特征信息, 另一方面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, 从而提高建模精度.

此外, 神经网络的权值、阈值是随机设定的, 隐藏层节点数难以确定, 且现有传统的基于梯度的神经网络训练算法很容易陷入局部最优和鞍点, 这是由于基于梯度信息的优化方法具有贪婪特性^[6], 从而导致缺乏足够的探索能力. 生物启发式智能算法相比于传统神经网络训练算法, 具有结构简单、易于实现等优点, 不仅可短时间内搜索较广的解空间, 且其内在的寻优机制可推动算法到达较优区域搜索, 从而获得问题的满意解. 生物启发式智能算法这种通过对高维解空间极小

区域的搜索来实现对较优区域的搜索, 是其有效的本质原因, 也是现有基于梯度下降的网络训练算法难以做到的. 因此, 在网络训练过程中采用生物启发式智能算法对神经网络的初始参数进行优化和设计是合理且必要的.

2005年, Karaboga等^[7]提出一种人工蜂群算法(artificial bee colony algorithm, ABC). ABC模拟蜂群的个体分工、信息共享和采蜜行为. 该优化算法具有控制参数少、搜索精度较高和鲁棒性较强的特点, 在求解高维连续问题时表现出良好的性能. 目前已有一些学者针对ABC优化神经网络进行研究, Huang等^[8]将BP神经网络用于红酒品质评价时, 采用ABC对其进行优化, 用适应度最好的网络参数代替网络初始参数, 以解决网络收敛速度慢的问题. Yu等^[9]为提高交通流量预测的精度, 提出一种基于RBF神经网络的短时预测方法, 并采用ABC训练高斯函数的中心、宽度以及RBF神经网络隐层和外层之间的权值. 上述文献较好地将ABC应用于网络优化, 但大多是基于初始权重和阈值的优化, 忽略了训练比、动量因子和网络结构. 实际上, 神经网络结构、初始权值和阈值、训练比和动量因子直接影响神经网络的训练速度和处理能力^[10]. 只有对它们进行全面优化, 才能提高网络的整体性能. 此外, ABC算法存在局部搜索机制及其调整方法难以合理确定的问题, 通常以某种人为经验公式固定或自适应更新, 这一定程度上限制了算法的性能. 有学者提出通过强化学习实现ABC智能调整搜索策略, 如Kruekaew和Kimpan^[11]使用ABC算法结合Q-learning来解决云计算环境中的调度问题, 使ABC实现智能决策. 但是Q-learning算法需要在复杂环境下建立庞大的Q值表, 这种方法不仅耗时且收敛速度慢, 易产生维度爆炸, 导致ABC在状态较复杂的情况下难以得到较好的局部搜索策略, 进而陷入局部最优.

为进一步提高乙烯产率预测精度, 本文提出一种学习型人工蜂群算法优化的双向门控循环单元(gate recurrent unit, GRU)网络(bi-directional gated recurrent neural network optimized by learning-based ABC, LABC_BGRU)乙烯产率预测模型. 首先为解决传统神经网络对复杂工业过程特征映射能力不足的问题, 本文采用BGRU作为乙烯产率预测网络, BGRU作为BLSTM的改进算法, 其参数量更少且学习能力更优^[12]; 其次, 根据网络优化问题的高维复杂连续特性, 采用参数较少且能高效求解连续问题的人工蜂群算法作为网络训练优化算法, 并基于深度强化学习智能调整ABC的搜索机制, 执行具有全局优化视野的局部搜索, 进而高效探索更深层次的解空间; 再次, 采用LABC对神经网络的结构、初始权值和阈值、训练比和动量因子进行优化设计, 然后利用训练样本对改进后的神经网络权值和阈值进行优化; 最后, 采用标准

数据集和工业实际应用案例验证LABC_BGRU模型的有效性与其实用性。

2 问题描述

2.1 乙烯裂解炉工艺流程

在乙烯实际生产中, 乙烯裂解炉为核心装置, 实现其模型化、优化具有重要意义。乙烯裂解炉用于将烃类原料在高温下转换成小分子化合物及其他产物, 主要生成乙烯和丙烯。裂解炉分为对流段和辐射段两个部分, 其具体生产过程如图1所示。

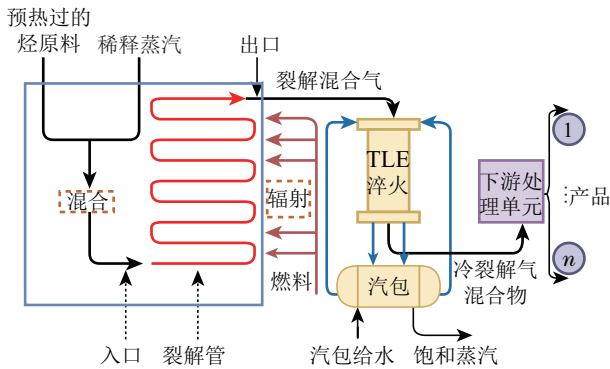


图1 石脑油裂解烯烃装置的常规流程图

Fig. 1 The conventional block flow diagram of naphtha cracking olefin plants

烃原料在对流段预热后与稀释蒸汽混合, 汽烃混合物被加热至汽化随即进入辐射段的高温裂解管, 继续升温后发生热解反应, 高温由外部燃料维持。得到的裂解混合气进入线性急冷换热器和汽包构成的急冷锅炉进行快速冷却, 抑制二次反应发生, 保证关键产物产率并减少结焦。最后, 对冷混合气进行压缩, 并在下游处理单元回收各种产品。综上可知, 乙烯裂解过程是一个非常复杂且各反应过程高度耦合的动态非线性过程, 传统机理建模方法很难对热裂解反应的最后结果做出很好的估计。

2.2 影响乙烯产率的因素

在原料确定的裂解反应中, 影响乙烯产率的因素主要有裂解温度、烃分压、停留时间和进料流量等。根据裂解炉生产过程的内在机理并结合相关文献介绍^[4], 选取乙烯收率预测模型的输入变量为进料流量 (feed flow rate, FFR)、炉管出口温度 (coil outlet temperature, COT)、蒸汽烃比 (steam hydrocarbon ratio, SHR) 和停留时间 (residence time, RT), 输出变量为乙烯产率 (ethylene yield, EY)。故BGRU乙烯产率神经网络模型的定义如下所示:

$$\text{Yields}_{(i,j,p)} = \text{BGRU}_{\text{yield}(i,j,p)},$$

$$\text{avol, FFR, COT, SHR, RT,} \quad (1)$$

其中: avol为模型可调参数, FFR为进料流量, COT为炉管出口温度, SHR为蒸汽烃比, RT为停留时间。BG-

RU_{yield(i,j,p)}表示j炉处理i原料时p产品的收率神经网络模型。优化目标为最小化模型的平均相对误差, 即

$$\text{minimize} \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{Yields}_{(i,j,p)} - y_{(i,j,p)})^2}, \quad (2)$$

其中: Yields_(i,j,p)由BGRU_{yield(i,j,p)}模型获得, 大小取决于模型参数avol, y_(i,j,p)为训练样本真实值, n为训练样本个数。

3 LABC_BGRU模型

LABC_BGRU模型由BGRU网络和LABC算法构成, 本文采用BGRU网络对乙烯产率进行预测, 并为进一步优化BGRU网络, 采用LABC对BGRU网络的结构、初始权值和阈值、训练比和动量因子进行全面的优化和设计。ABC和强化学习(reinforcement, RL)结合时必须充分考虑价值函数、状态集、动作集、奖励函数和策略关键RL要素。因此, 在上述前提下, 设计以下方案。如图2所示, ABC和RL的组合模型分为环境模块、学习模块。ABC被视为环境模块, 每次迭代会从 S_t 变为 S_{t+1} 的状态。学习模块由智能体、双Q网络和回放记忆单元组成, 智能体是RL算法的虚拟对象, 双Q网络用于拟合动作价值函数, 回放记忆单元用于训练双Q网络。学习模块和环境模块不断交互, 实现LABC的自学习, 自学习训练后的智能体通过最优混合搜索策略执行全局最优局部搜索, 进而提高算法收敛速度和求解精度。

3.1 双向门控循环神经网络

GRU的内部结构与裂解炉动力学反应网络结构十分相似, 例如, GRU的更新门用于决定丢弃和添加信息。对于乙烯裂解的反应过程, 沿着炉管方向的压力、温度等会发生改变, 需实时更新, 以准确描述裂解炉管中发生的变化。GRU的重置门可决定先前信息遗忘的程度。在裂解过程中, 遗忘信息指随着反应物的消耗, 部分反应的速率减慢甚至停止反应。故采用GRU网络可对裂解炉裂解过程更好的进行模拟。

然而, 对于单向网络而言, 状态总是从前往后输出, 在乙烯裂解过程中, 当前时刻状态可能受上一时刻和下一时刻状态的共同影响, 因此本文采用由两个单向的、方向相反的GRU构成的BGRU作为乙烯产率网络预测模型, 这更有利于提取深层次特征。由第2.2节可知影响乙烯收率的关键因素有4个, 输出变量为乙烯收率。因此, 设置输入层节点的数量为4, 输出层节点数为1, 以及隐藏层的节点数量由学习型人工蜂群算法优化为8。

3.2 学习型人工蜂群算法

3.2.1 LABC的自学习过程

环境模块与学习模块的不断交互实现LABC的自学习。首先设置LABC的终止条件, 并将初始网络关键参数传入环境模块生成初始环境, 而后在迭代中, 智

能体获得时间步长 t 时的状态 S_t , 根据基于深度双Q网络的最优混合搜索策略得到最优搜索动作 a_t , 并将状态转换为 S_{t+1} , 获得反馈 r_t , 其次将学习记录 (S_t, a_t, S_{t+1}, r_t) 存入回放记忆单元, 深度双Q网络在一定迭

代步长后进行随机经验回放, 对网络参数进行更新. 这种不断获取状态、执行动作、获得反馈和调整策略的过程就是自学习过程, 可以很好地适应人工蜂群算法的迭代过程.

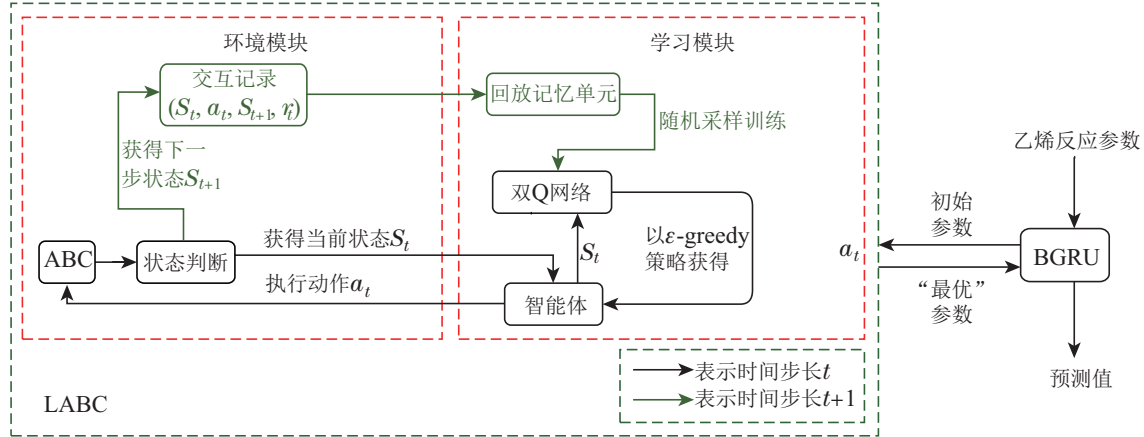


图 2 LABC_BGRU模型结构图

Fig. 2 Structure diagram of LABC_BGRU

3.2.2 环境模块

ABC的编码方案: 对BGRU网络进行训练时, 一般会使用附加动量法来避免网络在训练过程中出现震荡和陷入局部最小值, 权重和阈值的附加动量法调节公式定义为

$$\Delta w_{jt}(k+1) = (1 - mc) \cdot \alpha \cdot d_t^k \cdot b_j + mc \cdot \Delta w_{jt}(k), \quad (3)$$

$$\Delta \theta_t(k+1) = (1 - mc) \cdot \alpha \cdot d_t^k + mc \cdot \Delta \theta_t(k), \quad (4)$$

式中: k 表示训练次数, α 为训练比, mc 表示动量因子, $0 < \alpha < 1, 0 < mc < 1$. 由式(3)–(4)可知神经网络的结构、权值和阈值、训练比和动量因子均间接或直接影响网络性能. 故本文将以上5个关键参数看作一个蜜源, 并使用实数编码.

ABC的适应度函数: 乙烯裂解炉产率建模的目标是提高模型的预测精度, 故本文将BGRU神经网络均方误差的倒数作为适应度函数, 其定义如下式所示:

$$f = \frac{1}{K+1}, \quad (5)$$

式中: $K = \frac{1}{n} \sum_{i=1}^n e^2(i)$, $e(i) = y(i) - y_m(i)$, n 为训练样本数, $y(i)$ 为网络实际输出, $y_m(i)$ 为网络期望输出, $e(i)$ 为网络的实际输出和期望输出之间的误差.

3.2.3 学习模块

深度双Q网络: 在深度双Q网络(double deep Q network, DDQN)中, 通过主网络选择动作, 根据目标

网络评估其价值. DDQN的目标值更新可以写为

$$Y_t^{\text{DDQN}} = r_t + \gamma Q(S_{t+1}, \arg \max_a Q(S_{t+1}, a; \theta_t); \theta'_t), \quad (6)$$

其中: r_t 为立即收益, 表示 S_t 状态下选择动作 a_t 的当前收益; γ 为折扣率, 值越大则越侧重长远收益, 越小越侧重当前收益; θ_t 为主网络权重; θ'_t 为目标网络权重, 主网络通过随机经验回放进行参数更新, 并在一定步数后将参数复制给目标网络.

采用随机梯度下降以最小化误差, 损失函数表示为目标值和评估值之间的均方误差, 如下所示:

$$L^{\text{DDQN}} = (Y_t^{\text{DDQN}} - Q(S_{t+1}, a_t; \theta_t))^2, \quad (7)$$

式中 $Q(S_{t+1}, a_t; \theta_t)$ 表示用主网络得到状态 S_t 下选取动作 a_t 所对应的 Q 值.

状态集: 从种群适应度值出发考虑以下3个状态:

1) 种群的平均适合度值.

$$f_{\text{avg}}^t = \frac{\sum_{i=1}^{\text{SN}} f_i^t}{\text{SN}}, \quad (8)$$

其中: f_{avg}^t 为种群 t 时刻的平均适应度, f_i^t 为 X_i 在 t 时刻的适应度, SN为种群大小.

2) 种群多样性.

$$d^t = f_{\text{best}}^t + f_{\text{worst}}^t, \quad (9)$$

其中: d^t 为 t 时刻种群的多样性, $f_{\text{best}}^t, f_{\text{worst}}^t$ 分别为 t 时刻种群最优、最劣适应度值.

3) 历史最优个体适合度值: f_{best} .

使用 $t = 1$ 时刻的3个状态对上述状态进行归一化并分为100份, $t = 1$ 时刻的状态为 $S_1 = [99, 99, 99]$.

动作集: 智能体根据算法当前状态得到雇佣蜂阶段和侦察蜂阶段最优搜索动作. 本文提出10个基本搜索动作组成动作集, 以下为各搜索动作的详细描述:

1) 最优值交叉: 当前种群个体与历史最优个体交叉得到2个新个体

$$V_{i,j} = \frac{1}{2}((1 + \beta)X_{i,j} + (1 - \beta)X_{\text{best},j}), \quad (10)$$

$$V'_{i,j} = \frac{1}{2}((1 - \beta)X_{i,j} + (1 + \beta)X_{\text{best},j}), \quad (11)$$

其中: $i \in \{1, 2, \dots, \text{SN}\}$, $j \in \{1, 2, \dots, D\}$, SN为种群规模, D 为变量的维数. V_i 和 V'_i 为两个候选解, 若 V_i 和 V'_i 中的较优个体的适应度值优于 X_i , 则用该较优个体替换 X_i . 参数 β 的定义如下所示:

$$\beta = \begin{cases} (2\text{rand})^{\frac{1}{1+\text{sr}}}, & \text{rand} \leq 0.5, \\ \left(\frac{1}{2-2\text{rand}}\right)^{\frac{1}{1+\text{sr}}}, & \text{rand} > 0.5, \end{cases} \quad (12)$$

参数sr越大表示子代越接近父代, 本文取为10, rand是(0, 1)之间的随机数.

2) 高斯变异: 由当前种群个体 X_i 和 $X_{k,j}$ 高斯分布产生的随机数加权的随机个体组合产生新个体

$$V_{i,j} = (1 - N(0, 1))X_{i,j} + N(0, 1)(X_{\text{best},j} - X_{k,j}), \quad (13)$$

其中: $k \in \{1, 2, \dots, \text{SN}\}$, $k \neq i$, $N(0, 1)$ 为服从值为0且方差为1的高斯分布.

3) 集成最优引导: 种群根据适应度值排序, 由所有优于当前种群个体 X_i 的其他个体加权组合产生的新个体对当前种群个体进行引导更新, 即

$$V_{i,j} = \begin{cases} X_{i,j} + \theta_{i,j}(X_{\text{ebest},j}^k - X_{i,j}), & k > 1, \\ X_{i,j} + \theta_{i,j}(X_{\text{best},j} - X_{i,j}), & k = 1, \end{cases} \quad (14)$$

其中: $X_{\text{ebest},j}^k = \sum_{i=1}^{k-1} W_i X_{i,j}$; k 为当前个体的排名序号; W_i 为适应度排名为 i 的个体对应的权重, 计算公式为

$$W_i = \frac{WF_i}{\sum_{i=1}^k WF_i}, \quad (15)$$

其中: F_i 为 X_i 的适应度; WF_i 为 X_i 的平衡适应度, 其定义公式为

$$WF_i = \frac{e^{1+\log_{10}(k-1)}}{i^4 F_i}, \quad (16)$$

使用平衡适应度计算权重可防止 k 太大时, 排名略优于 X_i 的个体的权重趋于0, 在集成时被稀释. 由式(16)可知, 个体适应度 F_i 和平衡适应度 WF_i 为负相关, 式 $e^{1+\log_{10}(k-1)}/i^4$ 为大量实验仿真结果得出, 用于调节 $1/F_i$ 的值至一个合理范围.

4) 最优值引导: 由最优个体 X_{best} 引导当前种群个

体 X_i 更新, 即

$$V_{i,j} = X_{i,j} + \theta_{i,j}(X_{\text{best},j} - X_{i,j}), \quad (17)$$

其中 $\theta_{i,j}$ 为服从均匀分布(0, 0.05)的随机数.

5) 反向学习: 为利用种群搜索信息, 根据重心计算反向点. 重心和基于重心的反向点定义如下所示.

定义1 设 (X_1, X_2, \dots, X_N) 是 D 维搜索空间中带有单位质量的 N 个个体, 则种群的重心定义为

$$G_j = \frac{1}{N} \sum_{i=1}^N x_{ij}, \quad j = 1, 2, \dots, D. \quad (18)$$

定义2 若种群的重心为 G , 则该种群中某一个体 X_i 的反向点定义为

$$\tilde{X}_i = 2G - X_i, \quad i = 1, 2, \dots, n. \quad (19)$$

6) 最优精英交叉: 历史最优个体 X_{best} 和当前种群精英个体 X_e 交叉, 即

$$V_{i,j} = \frac{1}{2}((1 + \beta)X_{e,j} + (1 - \beta)X_{\text{best},j}), \quad (20)$$

$$V'_{i,j} = \frac{1}{2}((1 - \beta)X_{e,j} + (1 + \beta)X_{\text{best},j}), \quad (21)$$

其中 β 如式(12)定义.

7) 最优个体变异: 由历史最优个体和高斯分布产生的随机数加权的随机个体组合产生新个体

$$V_{i,j} = (1 - \sigma(0, 1))X_{\text{best},j} + \sigma(0, 1)(X_{\text{best},j} - X_{k,j}), \quad (22)$$

其中 $\sigma(0, 1)$ 为(0, 1)范围内随机数.

8) 集成个体无偏扰动: 集成个体 $X_{\text{integrate}}$ 根据扰动项产生新个体

$$V_{i,j} = X_{\text{integrate},j} + \theta'_{i,j}\sigma, \quad (23)$$

其中 $\theta'_{i,j}$ 为服从均匀分布(-1, 1)的随机数. 扰动项和集成个体的定义如下所示.

定义3 扰动项 σ 为历史最优个体 X_{best} 、当前种群精英个体 X_e 和普通种群个体 X_i 之间差异的均值, 其定义公式如下:

$$\sigma = \frac{1}{3}(|X_{k,j} - X_{e,j}| + |X_{k,j} - X_{\text{best},j}| + |X_{e,j} - X_{\text{best},j}|). \quad (24)$$

定义4 集成个体 $X_{\text{integrate}}$ 的定义为

$$X_{\text{integrate}} = \frac{1}{3}(X_k + X_{\text{best}} + X_e). \quad (25)$$

9) 最优个体扰动: 对最优个体 X_{best} 进行小范围扰动

$$V_{i,j} = X_{\text{best},j} + \theta''_{i,j}X_{n,j}, \quad (26)$$

其中: X_n 为 X_{best} 邻域内的个体, $n \neq e$, $\theta''_{i,j}$ 为服从均匀分布的(-0.05, 0.05)的随机数.

10) 最优个体logistic混沌映射: 最优个体 X_{best} 根

据式(27)产生映射个体 X_1 , 参数 $\mu \in (0, 4]$, 本文取4, $\mu = 4$ 时实现满映射^[13], 映射空间均匀分布.

$$X_1 = \mu X_{\text{best}}(1 - X_{\text{best}}). \quad (27)$$

为分析以上10种搜索动作的有效性, 采用补充材料中表1的14组测试函数¹进行测试, 可得如图3的结果, 其中U为单峰函数, M为多峰函数, S为可微分函数, N为不可微分函数. 由图3可知, 不同搜索动作求解不同类型测试函数的动作有效率差异很大, 例如动作4, 6求解单峰函数时有效率较低, 但在求解多峰函数时有效率明显提升; 动作7求解多峰不可分函数的有效率相对于求解多峰可分函数的有效率有明显提升; 动作9求解可分函数的有效率明显高于求解不可分函数的有效率.

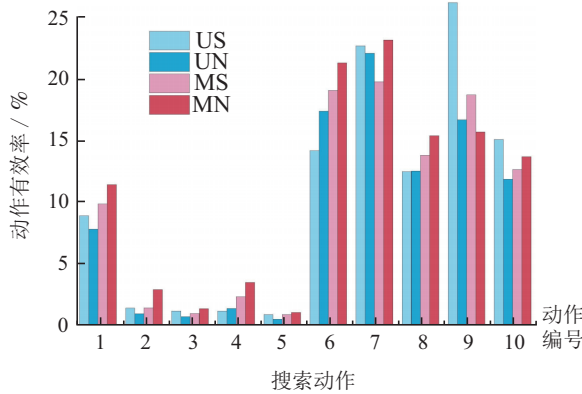


图 3 不同解空间下各动作的有效率

Fig. 3 Efficiency of actions in different solution spaces

动作1-5为探索操作, 即对目标值区域广泛搜索, 将其作为雇佣蜂阶段探索动作集; 动作6-10为局部寻优操作, 即对目标值较低的一小块区域细致搜索, 将其作为侦察蜂阶段局部寻优动作集.

综上所述, 不同动作针对不同解空间的动作有效率有较大差异, 为高效求解网络模型参数优化问题对应的复杂高维解空间, 需对搜索动作进行智能调整. 此外, 智能体在做出动作决策时把两个搜索阶段的动作合为一个动作对, 将动作对的状态动作价值函数值作为动作评估值, 无需对两个搜索阶段的动作分别评估学习, 从而加快学习模块收敛速度.

奖励函数: 奖励函数的设计是为了估计动作和优化策略. 本文采用最优适应度值变化率与种群平均适应度值变化率作为奖励指标, 如下所示:

$$r_t = w_1 \frac{F_{t-1} - F_t}{F_{t-1}} \alpha + w_2 \frac{\text{AVGF}_{t-1} - \text{AVGF}_t}{\text{AVGF}_{t-1}} \beta - \phi(F_t), \quad (28)$$

其中: $(F_{t-1} - F_t)/F_{t-1}$ 是最优适应度值变化率, $(\text{AVGF}_{t-1} - \text{AVGF}_t)/\text{AVGF}_{t-1}$ 是平均适应度值变化率; w_1 和 w_2 分别为其权重; α 和 β 为变化率调节因

子, 因不同适应度种群寻优难易程度不同, 不能直接将适应度变化率作为动作的奖励指标, 故需对其调节; ϕ 为惩罚项, 与适应度大小成正比, 为防止强化学习模型一直选择过小正向奖励的动作, 使模型训练停滞.

最优混合搜索策略: 本文动作集由多个搜索动作构成, 为实现ABC在不同状态下选择合适搜索动作, 提出如下所示的最优搜索策略:

$$\pi(S_t, a_t) = \begin{cases} \max_a Q(S_t, a), & \varepsilon \geq r, \\ a(\text{随机算法选择}), & \varepsilon < r, \end{cases} \quad (29)$$

其中: ε 被称为贪婪率或剥削率, r 是0到1之间的随机值. 当 $\varepsilon \geq r$ 时, 选择使期望 Q 值最大化的动作 a ; 当 $\varepsilon < r$ 时, 选择一个随机动作 a .

3.3 LABC_BGRU流程

基于以上工作, LABC算法描述如算法1所示, 整个LABC_BGRU的执行流程如图4所示.

表 1 算法1: LABC算法

Table 1 Algorithm 1: LABC algorithm

初始化ABC: 将BGRU的 N 个初始化关键参数作为种群, 最大迭代数(Iterations).

初始化DDQN: 主 Q 网络参数(θ), 目标 Q 网络参数($\theta' = \theta$), 动作集(A), 状态集(S), 最优混合搜索策略(ε -greedy), 回放记忆池(D).

-设置当前迭代数 $t = 0$. 计算所有个体适应度.

-计算ABC的状态 S_t .

while $t \leq \text{Iterations}$ **do**

 根据 ε -greedy策略选择动作 a_t .

 根据 a_t 执行蜂群搜索操作并计算 r_t 和 S_{t+1} .

 将 S_t, a_t, r_t, S_{t+1} 存入 D .

 从 D 中随机采样.

 根据式(6)计算 Y_t^{DDQN} .

 根据式(7)计算损失函数 L^{DDQN} .

 通过随机梯度下降更新主 Q 网络参数.

 每隔 c 步设置 $\theta' = \theta$.

$t = t + 1$.

end

输出: 最优BGRU网络参数.

4 实验设计与分析

4.1 LABC关键环节有效性验证

4.1.1 LABC搜索策略有效性分析

为验证LABC搜索策略智能调整的有效性, 采用补充材料中的14组测试函数¹对全局最优个体引导的人工蜂群(gbest-guided ABC, GABC)算法^[4]、LABC(R)(R-random)算法(贪婪率 $\varepsilon = 1$, 即完全随机选取动作)与LABC算法(学习率 $\alpha = 0.75$, 折扣率 $\gamma = 0.2$, 贪婪率 $\varepsilon = 0.1$)进行比较. 设 $\text{SN} = 50$, $\text{limit} = \text{SN} \times D$, $G = 100$. 3种算法在 $D = 30$ 时独立实验20次的结果如表2所示.

¹补充材料: <https://maifile.cn/est/d2286979826989/pdf>.

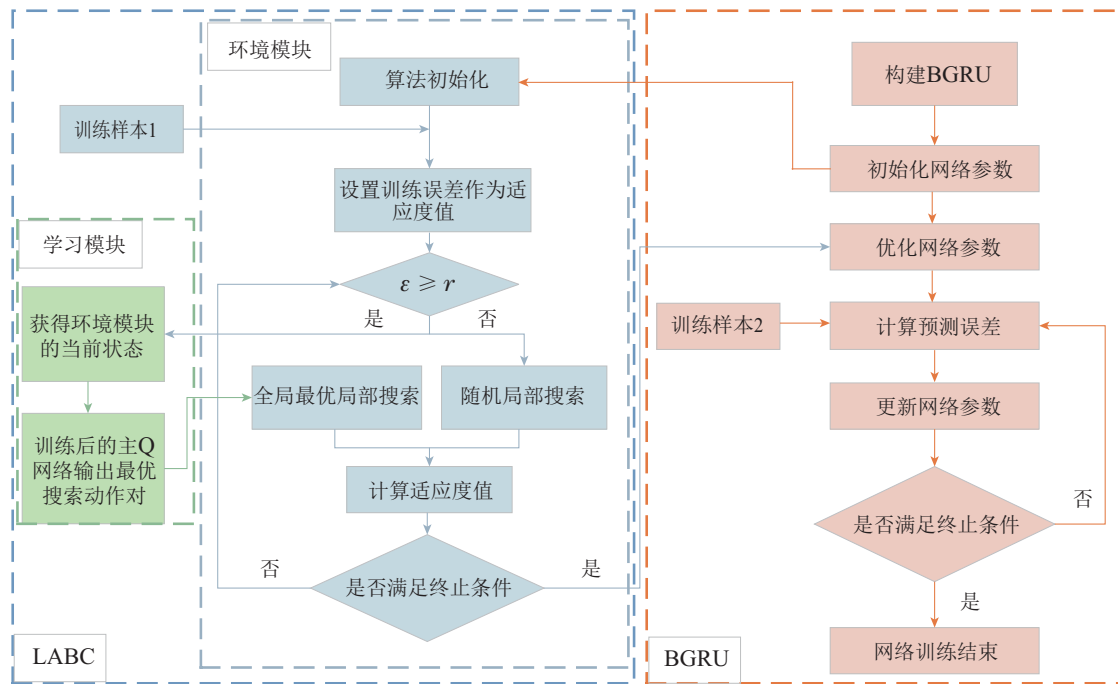


图4 LABC_BGRU流程图

Fig. 4 Flow chart of LABC_BGRU

表2 GABC, LABC(R)与LABC的优化性能比较

Table 2 Optimization performance comparison of GABC, LABC(R) and LABC

函数	GABC				LABC(R)				LABC			
	最优值	最差值	平均值	标准差	最优值	最差值	平均值	标准差	最优值	最差值	平均值	标准差
F1	4.5e-232	3.1e-177	2.5e-178	0	0	0	0	0	0	0	0	0
F2	2.5e-223	1.9e-167	1.0e-168	0	5.6e-303	7.9e-235	4.6e-236	0	0	0	0	0
F3	4.2e-200	1.6e-158	1.3e-159	4.2e-159	8.8e-308	7.9e-234	4.1e-235	0	0	0	0	0
F4	4.9e-106	3.4e-77	1.8e-78	7.7e-78	3.7e-159	2.5e-115	1.4e-116	5.8e-116	1.4e-224	1.2e-181	6.9e-183	0
F5	6.0e-112	3.5e-81	2.9e-82	9.1e-82	5.4e-156	1.3e-120	7.4e-122	3.0e-121	2.0e-284	2.3e-154	1.3e-155	5.3e-155
F6	2.4e-106	6.3e-78	3.5e-79	1.5e-78	6.6e-151	2.6e-82	1.4e-83	6.1e-83	3.3e-252	5.3e-148	3.5e-149	1.3e-148
F7	0	0	0	0	0	0	0	0	0	0	0	0
F8	6.2e+01	1.4e+02	1.0e+02	2.3e+01	9.2e+01	1.7e+02	1.3e+02	1.0e+01	0	0	0	0
F9	1.2e-04	8.7e-04	4.2e-04	2.5e-04	1.0e-04	1.3e-04	4.1e-04	4.2e-04	3.0e-06	9.9e-05	5.2e-05	3.1e-05
F10	1.7e+05	3.6e+05	2.8e+05	4.8e+04	9.8e+01	9.9e+01	9.9e+01	2.4e-01	2.2e-02	2.2	4.5e-01	6.6e-01
F11	0	0	0	0	0	0	0	0	0	0	0	0
F12	2.1e+01	8.3e+01	4.4e+01	2.4e+01	1.0	1.3	1.2	9.6e-02	5.9e-04	8.2e-01	6.5e-02	1.8e-01
F13	0	0	0	0	1.9e-13	2.3e-1	6.0e-2	8.0e-2	0	0	0	0
F14	4.4e-16	4.4e-16	4.4e-16	0	4.4e-16	4.4e-16	4.4e-16	0	1.4e-16	4.4e-16	1.6e-16	4.2e-08

由表2可知,对于F1, F2, F3, F8, GABC算法、LABC(R)算法都未求得其最优值,而LABC算法求得最优值.由于F7其最优解在一个区间, F11存在密集的最优解,所以3种算法在F7和F11上都取得了最优值.而对于其他测试函数,3种算法都未能求得最优值.综上所述,LABC算法具有更高的求解精度、算法稳定性.

4.1.2 LABC的学习过程、学习结果分析

为对LABC的学习过程、学习结果进一步分析,本

文基于LABC学习迭代1000轮生成的交互数据绘制了如图5所示的LABC的学习奖励曲线.

由图5可知,在前330次学习迭代,学习奖励曲线的提升速度较快,但震荡较大,说明智能体在训练初期进行大量探索,寻求效果好的动作,随着训练次数的增加,智能体通过积累经验逐渐改进策略,从而在训练600次后逐渐收敛到最优决策.综上所述,本文的奖励设置有利于智能体在迭代训练中习得有效经验,从而使LABC效果得到提升.




图 5 LABC学习奖励曲线图

Fig. 5 Learning reward curves of LABC

4.1.3 BGRU的优化设计有效性分析

为验证采用LABC对BGRU网络的结构、初始权值和阈值、训练比和动量因子进行优化设计的有效性, 本文对各参数对网络训练的影响进行深入分析.


1) 设计神经网络应有限考虑3层网络(即有一个隐层), 隐层节点数过少会使网络拟合能力减弱, 但节点数过多会导致网络向着某些相似样本的更新方向靠拢, 从而陷入局部最优.

2) 网络训练过程实质是根据输出值与期望值之间的误差不断调整网络权值和阈值的过程, 大量结果表明改进初始化方法能有效提高网络的精度.


3) 训练比(训练集样本数/测试集样数)过大易导致网络过拟合, 过小则会导致网络欠拟合.

4) 动量因子通过调整网络参数的更新方向, 使参数在梯度平滑方向的更新力度变大, 在梯度陡峭方向更新力度变小.

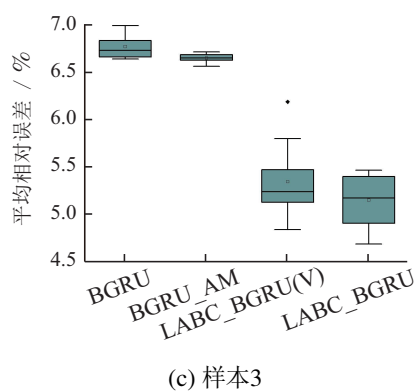
为进一步说明以上关键因素的改进对网络训练的影响, 本文将BGRU, 附加动量法(BGRU_additional momentum method, BGRU_AM), LABC_BGRU(V)(V-Variation)(仅对初始权值和阈值优化)和LABC_BGRU进行比较. 在UCI数据库中的CCPP标准数据集²随机抽取3组样本数据, 迭代训练1000次, 平均相对误差结果如图6所示, 可以看出LABC_BGRU(V)和LABC_BGRU明显优于BGRU和BGRU_AM, 验证了网络初始权值和阈值对网络效果的影响, LABC_BGRU的整体分布较LABC_BGRU(V)更优, 说明网络结构、训练比和动量因子对网络预测精度的优化作用. 此外, 根据3个样本空间下每种模型的占比进行方差分析(analysis of variance, ANOVA), 来进一步验证各模型组内差异. 图7显示了4种模型在不同训练样本空间下的均值变化及95%置信度下的Tukey's HSD检验的置信区间, 可以看出, LABC_BGRU的占比在均值水平上与BGRU, BGRU_AM有显著差异, 且优于LABC_BGRU(V).



(a) 样本1



(b) 样本2



(c) 样本3

图 6 不同模型结果对比箱线图

Fig. 6 Box plot for comparisons of different model result

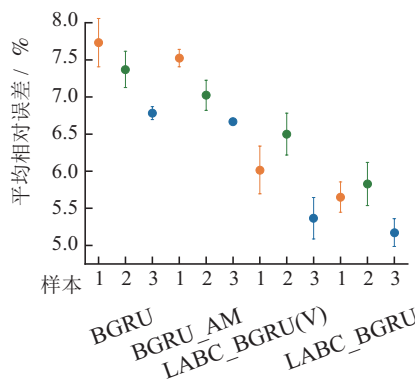


图 7 LABC_BGRU与对比模型的方差分析区间图
Fig. 7 Interval diagram of variance analysis between LABC_BGRU and comparison model

²UCI数据库中的CCPP标准数据集: <http://archive.ics.uci.edu/dataset/294/combined+cycle+power+plant>.

4.2 标准数据集测试

为初步验证LABC_BGRU模型有效性,采用UCI数据库中CCPP标准数据集²用于测试. CCPP数据集有4个输入属性和1个输出属性. 设置LABC_BGRU网络学习率为0.01, 迭代次数为600, 正反向GRU节点数均为8, 激励函数为Sigmoid函数; 采用150组训练样本用于模型训练, 用30组测试样本用于模型测试, 模型收敛对比结果如图8所示, 模型精度对比结果如表3所示.

由表3可知, 隐藏层节点数相同时, LABC_BGRU

的平均相对误差低于其他网络. 从图8可看出LABC_BGRU网络模型在25次训练后迅速收敛, 均方误差(mean-square error, MSE)为 $MSE = 0.0036$. BGRU网络模型在训练550代后收敛, $MSE = 0.0065$. GRU和LSTM在训练600代后仍未收敛, 且训练损失仍较高. 显然, 在迭代次数相同的情况下, 无论是从收敛速度还是从精度来看, LABC_BGRU网络模型都优于上述其他网络预测模型. 由此初步验证LABC_BGRU模型的有效性.

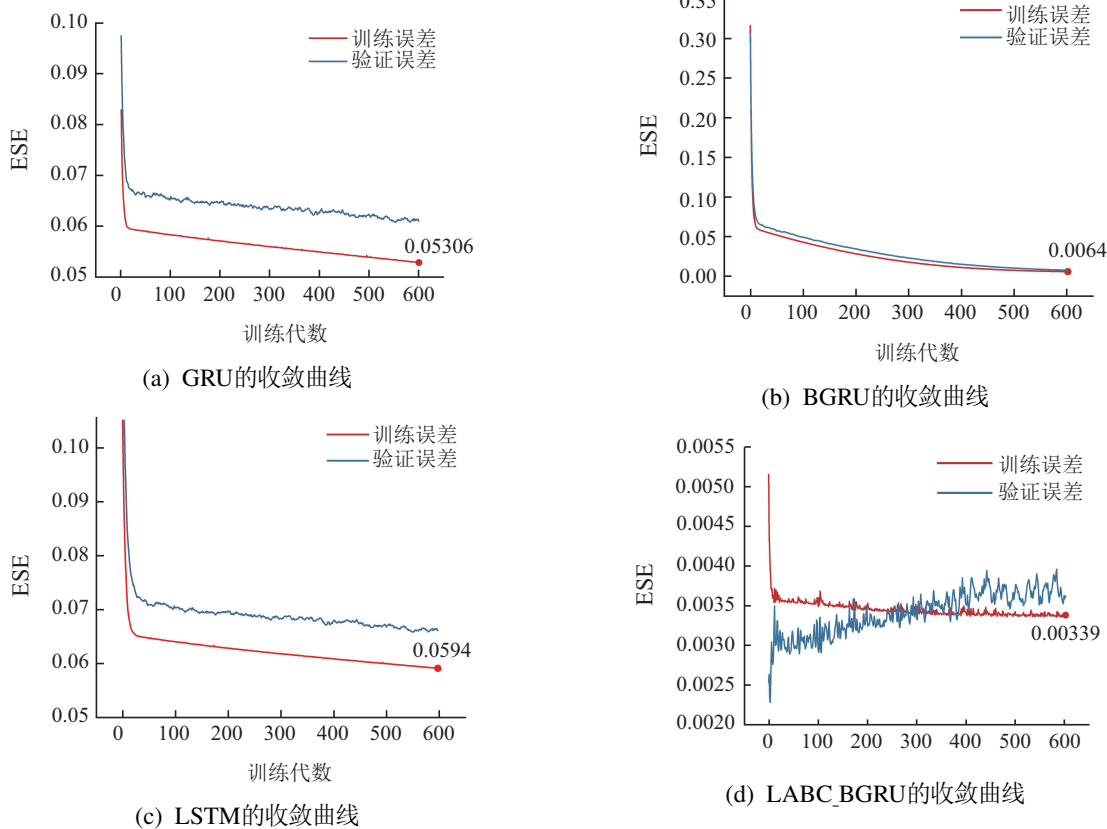


图8 不同模型的收敛曲线

Fig. 8 Convergence curves of different model

表3 CCPP标准数据集测试结果

Table 3 Testing results of CCPP standard data set

网络预测模型	隐藏层节点数	平均相对误差/%
RBF	8	17.91
LSTM	8	18.32
GRU	8	17.71
BGRU	8	9.59
LABC_BGRU	8	7.88

4.3 基于LABC_BGRU的乙烯产率预测

为进一步验证LABC_BGRU的有效性,采用浙江某石化企业乙烯裂解装置的生产数据进行测试. 该装置由艾默生DeltaV系统控制, 并由现场智能仪表(传感器)实时采集流量、压力、蒸汽焓比等关键生产过程

数据, 然后经Hart总线将所采集的数据传送至DeltaV组态数据库. 本文将正常工况下一个完整操作周期的生产数据从数据库中导出, 然后以该批次数据作为样本数据来离线训练LABC_BGRU模型. 为确保模型精度, 需对样本数据做如下预处理:

1) 数据误差处理: 由于数据中存在过失误差和随机误差. 首先根据 3σ 法剔除数据中存在过失误差的数据. 然后采用小波滤波法处理随机噪声.

2) 归一化处理: 由于输入数据的量纲不同, 需对筛选后的数据进行归一化处理. 通过线性函数归一化方法把输入数据特征缩放到 $[0, 1]$.

本文选用处理后的250组数据建立模型, 选取FFR, COT, SHR和RT作为网络输入, 将乙烯产率作为网络输出. LABC_BGRU隐藏层的节点数量由学习

型人工蜂群算法优化为 8, 训练比和动量因子优化为 5:1, 0.92, 初始权重和阈值设置为LABC优化得到的最优权重和阈值. BGRU_AM隐藏层节点数由人为经验公式 $2^{\text{input-size}}$ (input_size 为网络输入节点数, 本文为 4) 定义为 16, 训练比和动量因子根据经验设置为 4:1 和 0.9, 初始权值和阈值为随机生成. 以上网络模型网络学习率均为 0.01, 激励函数为 Sigmoid 函数, 迭代次数为 600 次, 对乙烯产量进行预测的结果如图 9-10 所示.

根据图 9-10 可以看出, LABC_BGRU 乙烯产率预测精度高于 BGRU_AM, BGRU_AM 与 LABC_BGRU 的平均相对误差分别为 6.51%, 5.48%. 因此利用 LABC_BGRU 模型进行预测, 可以更小误差地预测乙烯产率.




图 9 BGRU_AM 预测结果

Fig. 9 Prediction results of BGRU_AM




图 10 LABC_BGRU 预测结果

Fig. 10 Prediction results of LABC_BGRU

5 结论

本文针对乙烯裂解炉这一复杂装置, 从深入分析裂解炉生产工艺流程和内在机理出发, 提出 LABC_BGRU 乙烯产率网络预测模型. 基于 BGRU 的深度学

习建模方法可有效描述复杂的乙烯裂解过程, 将深度强化学习用于智能调整 LABC 算法的搜索机制从而执行全局最优的局部搜索, 并采用 LABC 全面优化和设计 BGRU 网络预测模型的结构、初始权值和阈值、训练比和动量因子, 使模型能快速收敛达到较高预测精度. 本文通过 CCPP 标准数据集测试验证 LABC_BGRU 在预测精度、稳定性等方面比 GRU, LSTM, RBF 和 BGRU 均有一定提升, 并预测了真实乙烯装置的生产状况, 能较精确预测乙烯产率, 指导乙烯生产并提高能效. 后续工作将针对乙烯实时数据进行实时动态预测, 更进一步精确分析和预测乙烯真实的实时生产效率.

参考文献:

- [1] AHSAN M. Computational fluid dynamics (CFD) prediction of mass fraction profiles of gas oil and gasoline in fluid catalytic cracking (FCC) riser. *Ain Shams Engineering Journal*, 2012, 3(4): 403 – 409.
- [2] ASCIONE F, BIANCO N, STASIO C D, et al. Artificial neural networks to predict energy performance and retrofit scenarios for any member of a building category: A novel approach. *Energy*, 2017, 118(1): 999 – 1017.
- [3] GENG Zhiqiang, CHEN Jie, HAN Yongming. Production capacity prediction of ethylene plant based on fuzzy RBF neural network. *Journal of Chemical Engineering*, 2016, 67(3): 812 – 819. (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. *化工学报*, 2016, 67(3): 812 – 819.)
- [4] YU K J, While L, REYNOLDS M, et al. Multiobjective optimization of ethylene cracking furnace system using self-adaptive multiobjective teaching-learning-based optimization. *Energy*, 2018, 148: 469 – 481.
- [5] LEFEBVRE G, BERLEMONT S, MAMALET F, et al. BLSTM-RNN based 3D gesture classification. *International Conference on Artificial Neural Networks*. Heidelberg, Berlin: Springer, 2013: 381 – 388.
- [6] CUI X, ZHANG W, TUSKE Z, et al. Evolutionary stochastic gradient descent for optimization of deep neural networks. *The 32nd Conference on Neural Information Processing Systems (NeurIPS)*. Montreal, Canada: Elsevier, 2018: 6048 – 6058.
- [7] KARABOGA D, BASTURK B. A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm. *Journal of Global Optimization*, 2007, 39(3): 459 – 471.
- [8] HUANG H, XIA X. Wine quality evaluation model based on artificial bee colony and bp neural network. *International Conference on Network and Information Systems for Computers (ICNISC)*. Shanghai, China: IEEE, 2017: 83 – 87.
- [9] YU W, LIU L, ZHANG W. Traffic prediction method based on rbf neural network with improved artificial bee colony algorithm. *The 8th International Conference on Intelligent Networks and Intelligent Systems (ICINIS)*. Tianjin, China: IEEE, 2015: 141 – 144.
- [10] YAN T. An improved evolutionary neural network algorithm and its application in fault diagnosis for hydropower units. *International Conference on Intelligent Computation Technology and Automation (ICICTA)*. Changsha, China: IEEE, 2010, 1: 548 – 551.
- [11] KRUEKAEW B, KIMPAN W. Multi-objective task scheduling optimization for load balancing in cloud computing environment using hybrid artificial bee colony algorithm with reinforcement learning. *IEEE Access*, 2022, 10: 17803 – 17818.

- [12] YANG S, YU X, ZHOU Y. LSTM and GRU neural network performance comparison study: Taking yelp review dataset as an example. *International Workshop on Electronic Communication and Artificial Intelligence (IWECAI)*. Qingdao, China: IEEE, 2020: 98 – 101.
- [13] ISMAIL S M, RADWAN A G, MADIAN A H, et al. Dynamics of fractional and double-humped logistic maps versus the conventional one. *The 29th International Conference on Microelectronics (ICM)*. Beirut, Lebanon: IEEE, 2017: 1 – 4.
- [14] GOVARDHAN M, MISHRA M, SUNDEEP S, et al. Solution of price based unit commitment using GABC and TLBO optimization algorithms. *Proceedings of International Conference on Control, Instrumentation, Energy and Communication (CIEC)*. Calcutta, India: IEEE, 2014: 667 – 671.

作者简介:

温在鑫 硕士研究生, 目前研究方向复杂系统智能优化, E-mail: 823570766@qq.com;

钱斌 教授, 博士生导师, 目前研究方向为优化调度理论与方法、智能优化方法, E-mail: bin.qian@vip.163.com;

胡蓉 副教授, 硕士生导师, 目前研究方向为智能优化调度、物流优化, E-mail: ronghu@vip.163.com;

金怀平 副教授, 硕士生导师, 目前研究方向为复杂过程建模与机器学习, E-mail: jinhuaiping@126.com;

杨媛媛 博士研究生, 目前研究方向为智能优化调度, E-mail: yangyuanyuan0730@163.com.