



基于RAGAN的工业过程运行指标前馈反馈多步校正

杨宇晴 王德睿 丁进良

RAGAN Based Feedforward-feedback Multi-step Correction of Operational Indices for Industrial Processes

YANG Yu-Qing, WANG De-Rui, DING Jin-Liang

在线阅读 View online: <https://doi.org/10.16383/j.aas.c210408>

您可能感兴趣的其他文章

基于多注意力机制的维吾尔语人称代词指代消解

Anaphora Resolution of Uyghur Personal Pronouns Based on Multi-attention Mechanism

自动化学报. 2021, 47(6): 1412-1421 <https://doi.org/10.16383/j.aas.c180678>

基于ISDAE模型的复杂工业过程运行状态评价方法及应用

Operating Performance Assessment Method and Application for Complex Industrial Process Based on ISDAE Model

自动化学报. 2021, 47(4): 849-863 <https://doi.org/10.16383/j.aas.c200475>

基于注意力机制的概念化句嵌入研究

Conceptual Sentence Embeddings Based on Attention Mechanism

自动化学报. 2020, 46(7): 1390-1400 <https://doi.org/10.16383/j.aas.2018.c170295>

基于注意力机制的协同卷积动态推荐网络

Attention-based Collaborative Convolutional Dynamic Network for Recommendation

自动化学报. 2021, 47(10): 2438-2448 <https://doi.org/10.16383/j.aas.c190820>

复杂工业过程智能优化决策系统的现状与展望

Research Progress and Prospects of Intelligent Optimization Decision Making in Complex Industrial Process

自动化学报. 2018, 44(11): 1931-1943 <https://doi.org/10.16383/j.aas.2018.c180550>

数据驱动的工业过程运行监控与自优化研究展望

Perspectives on Data-driven Operation Monitoring and Self-optimization of Industrial Processes

自动化学报. 2018, 44(11): 1944-1956 <https://doi.org/10.16383/j.aas.2018.c180207>

基于 RAGAN 的工业过程运行指标前馈-反馈多步校正

杨宇晴¹ 王德睿¹ 丁进良¹

摘要 针对工业过程运行指标反馈校正存在滞后及一步推理校正模型可解释性差的问题, 提出了基于递归注意力生成对抗网络 (Recurrent attention generative adversarial networks, RAGAN) 的运行指标前馈-反馈多步校正方法. 该方法采用基于负相关正则化的集成随机神经网络, 建立综合生产指标预报模型, 为校正提供前馈信息补偿反馈校正的滞后性. 提出的 RAGAN 校正, 采用多步校正实现一次调整的思想, 将当前时刻运行指标映射到低维潜变量空间简化数据复杂度, 利用长短期记忆 (Long short-term memory, LSTM) 模型实现数据的分步输入, 提高模型可解释性; 采用分布式注意力 (Distributed attention, DA) 机制构建数据读入网络, 使校正环节获取任务相关性更高的数据, 降低任务复杂度, 减小噪声干扰, 利用校正后的运行指标, 保证系统的综合指标尽可能地跟随设定值运行. 采用中国西部地区最大选矿厂实际数据的仿真实验, 验证了所提方法的有效性.

关键词 复杂工业过程, 运行优化, 多步校正, 注意力机制, 前馈-反馈校正

引用格式 杨宇晴, 王德睿, 丁进良. 基于 RAGAN 的工业过程运行指标前馈-反馈多步校正. 自动化学报, 2023, 49(5): 999-1009

DOI 10.16383/j.aas.c210408

RAGAN Based Feedforward-feedback Multi-step Correction of Operational Indices for Industrial Processes

YANG Yu-Qing¹ WANG De-Rui¹ DING Jin-Liang¹

Abstract To address the problems of time delay in feedback correction and weak interpretability of the correction model of the operational indices, this paper proposes a feedforward-feedback multi-step correction method for operational indices based on the recurrent attention generative adversarial networks (RAGAN). A global production indices prediction model is adopted to provide feedforward information for the feedback correction and compensate the time delay, which is established by the integrated stochastic weight neural network based on negative correlation regularization. The proposed RAGAN based correction approach adopts the idea of multi-step correction to realize one-time adjustment, mapping current indices to low-dimensional latent variable space to simplify data complexity, the long short-term memory (LSTM) is used to realize the step-by-step input of data which can improve the interpretability of the proposed correction model. In addition, a distributed attention (DA) mechanism is adopted to construct a data sensing network, which enables the correction model to obtain more task-related data and reduce the complexity as well as noise interference. The corrected operational indices are able to ensure that the global production indices follow their target values as far as possible. Simulation experiments based on actual data collected from the largest mineral processing plant in western China verify the effectiveness of the proposed approach.

Key words Complex industry process, operation optimization, multi-step correction, attention mechanism, feedforward-feedback correction

Citation Yang Yu-Qing, Wang De-Rui, Ding Jin-Liang. RAGAN based feedforward-feedback multi-step correction of operational indices for industrial processes. *Acta Automatica Sinica*, 2023, 49(5): 999-1009

收稿日期 2021-05-13 录用日期 2021-12-21
Manuscript received May 13, 2021; accepted December 21, 2021

国家自然科学基金 (61988101, 62161160338), 国家重点研发计划 (2018YFB1701104) 资助

Supported by National Natural Science Foundation of China (61988101, 62161160338) and National Key Research and Development Program of China (2018YFB1701104)

本文责任编辑 谢永芳

Recommended by Associate Editor XIE Yong-Fang

1. 东北大学流程工业综合自动化国家重点实验室 沈阳 110819

1. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819

复杂工业过程通常由多个子单元构成. 每个单元具有不同功能, 完成不同的中间生产指标 (运行指标); 同时, 这些单元协同工作, 以实现最终生产目标 (综合生产指标)^[1] 的要求. 各个单元的运行指标决策是根据实际工艺要求和生产经验来设定运行指标的目标值^[2], 但是由于复杂工业过程易受到原材料成分波动、生产工况变化等不确定性干扰的影响, 导致设定的运行指标不完全适用于当前工况, 以至于实际综合生产指标无法达到预期值^[3]. 因此

如何解决这种不确定性干扰对复杂工业过程的影响,引起了学术界和工业界的广泛关注。

许多基于知识的决策方法(例如模糊认知图^[4-6]、贝叶斯网络^[7]、案例推理^[8]和关联规则挖掘^[9-11]等)已经应用并实现工业过程运行指标的动态调整。但是这些算法均不同程度地遇到“知识瓶颈”即解决实际问题时,存在求解复杂度高、自学习能力差和适应性差等难题^[12]。文献^[13]提出了基于对抗性学习的决策(Adversarial learning-based decision making, DMGAN)的运行指标校正方法,该方法无需复杂的迭代推理,具有较强的自学习能力,有效地解决了基于知识的决策方法面临的“知识瓶颈”问题;但是,该方法仅利用了生产指标的反馈信息,具有一定的滞后性。此外,上述方法均采用一步推理方法^[14]产生决策,所有数据一次性全部输入模型,直接产生整个增量决策,这使模型一次性获得大量输入导致模型可解释性差、易受噪声干扰,且存在一定程度上的过拟合。

针对一步推理方法存在的可解释性差、易受噪声干扰,以及基于反馈的校正方法的滞后性问题,本文提出了基于递归注意力生成对抗网络(Recurrent attention generative adversarial networks, RAGAN)的复杂工业过程运行指标前馈-反馈多步校正方法。本文方法的特点是:1)采用集成随机神经网络^[15]搭建综合生产指标预报模型,为运行指标校正环节提供前馈信息,以补偿反馈校正方法的滞后性;2)采用长短期记忆(Long short-term memory, LSTM)^[16]模块构建校正环节,实现输入数据的循环

处理,使模型能够以迭代自校正的方式逐步构建运行指标的动态表示;3)设计了一种能够根据过去的信息和任务需求动态选择输入数据区域的分布式注意力(Distributed attention, DA)机制,并利用该机制构建数据读入网络,使校正环节每一步都能动态地选择当前所需的运行指标位置,降低任务复杂度,减少噪声干扰。最后,利用选矿实际生产流程数据作为运行指标校正的仿真实验,验证了本文方法的有效性。

1 复杂工业过程运行指标校正问题描述

复杂工业生产全流程运行指标决策过程如图1所示,该决策过程主要包含计划调度层、运行指标决策层、运行优化控制层和过程控制层4个层次。首先,计划调度层根据实际生产需求及设备、能源、原料等约束条件^[17]确定整个工厂的综合生产指标 Q_k 的目标值 Q_k^* 及其变化范围 $Q_k \in [Q_{k,\min}, Q_{k,\max}]$, $Q_{k,\max}$ 与 $Q_{k,\min}$ 分别表示各综合生产指标的上限和下限。运行指标决策层根据综合生产指标的目标值 Q_k^* 及其范围 $Q_k \in [Q_{k,\min}, Q_{k,\max}]$ 等确定各工序的运行指标设定值 r_{ij}^* ,其中 $i = 1, 2, \dots, I$,表示第 i 个工序, $j = 1, 2, \dots, J$ 分别表示第 j 个工序的质量、产量与消耗等指标。运行优化控制层根据各工序的运行指标目标值 r_{ij}^* 确定过程控制系统的设定值 $y_i^*(t)$,过程控制系统使被控对象的输出 $y_i(t)$ 跟踪设定值 $y_i^*(t)$,从而使得综合生产指标的实际值在目标范围内^[1]。

由于实际生产运行过程中易受到运行环境变化、原料成分波动、生产需求调整等不确定性因素的影响,

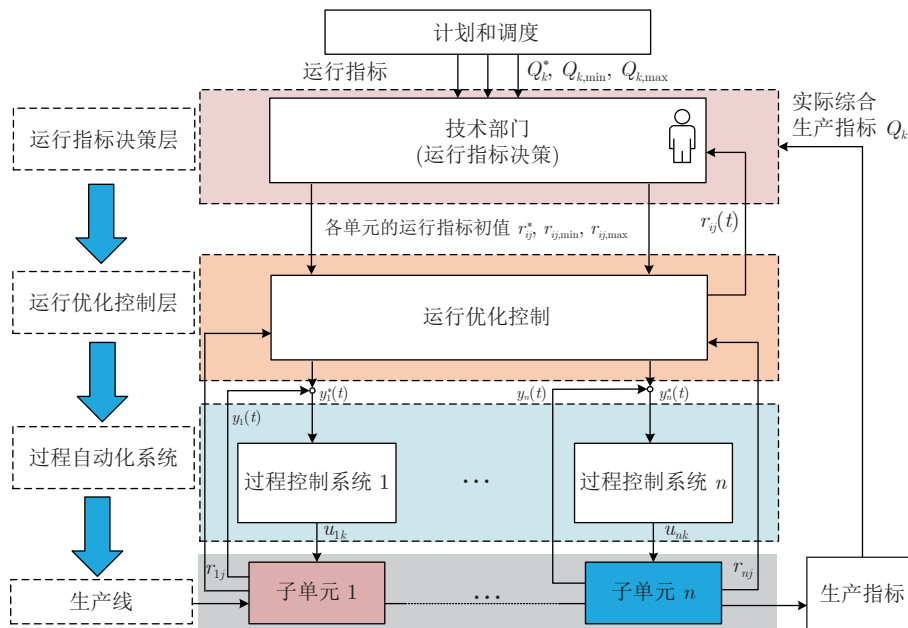


图1 复杂工业过程运行指标决策过程

Fig. 1 Decision-making of operational indices for complex industrial processes

响, 导致预先设定的运行指标目标值无法满足实际生产需要, 因此如何根据实际生产情况及时动态调整运行指标, 减少不确定性对综合生产指标的影响, 成为完成实际生产目标、维持生产流程平稳运行的关键性问题. 传统的运行指标决策过程, 需要工艺工程师根据生产流程的工艺要求以及生产经验依据当前工况实现交互式调整, 这种决策方法依赖于技术人员的经验与习惯, 具有很强的随机性, 无法保证生产操作的优化^[2, 17]. 学者们提出的基于知识的运行指标校正方法, 也在工业过程中得到了应用, 但是由于复杂工业过程的结构层次复杂, 具有强耦合、非线性等特点, 导致这类方法的规则提取难度大, 且受到不同工艺工程师调整经验差异的影响, 导致难以达到预期的生产目标. 此外, 由于复杂工业过程运行周期较长, 传统校正方法仅根据前一时刻的实际工况、运行指标、综合生产指标等反馈信息, 实现当前时刻的运行指标调整, 导致运行指标调整具有很强的滞后性.

综上所述, 为了实现对整个生产流程的动态调整, 在保证生产稳定性的同时, 尽可能地减少不确定性干扰对整个生产流程的影响, 以实现综合生产指标的目标值, 本文提出了基于 RAGAN 的运行指标前馈-反馈多步校正方法, 实现对生产全流程运行指标的校正.

2 基于 RAGAN 的运行指标前馈-反馈多步校正模型

2.1 综合生产指标预报模型

本文的综合生产指标预报模型采用基于负相关正则化的集成随机神经网络^[18]建立. 该模型由多个单隐层前馈神经网络 (Single-hidden layer feed-forward neural network, SLFN)^[19]构成, 每个 SLFN 的输入权值和隐藏节点偏置随机产生, 通过最小化模型输出预报值与实际值之间的均方误差, 采用最小二乘法求出每一个 SLFN 输出权值, 获得集成随机神经网络模型. 通过对多个 SLFN 预测结果求均值即获得所需的预报值. 为了提高模型的泛化性能, 避免模型过拟合, 训练模型的代价函数中引入了附加相关性惩罚项和正则化项, 故模型的代价函数为:

$$e_m = \frac{1}{2} \sum_{n=1}^N (f_m(x_n) - Q_n)^2 - \lambda \sum_{n=1}^N (f_m(x_n) - \bar{f}(x_n))^2 + \alpha_m \|\beta_m\|_2^2 \quad (1)$$

$$\bar{f}(x_n) = \frac{1}{M} \sum_{m=1}^M f_m(x_n) \quad (2)$$

式 (1) 中, $m = 1, \dots, M$ 表示第 m 个集成网络, β_m 是第 m 个基本模型的输出权值, α_m 表示正则化系数, λ 表示惩罚项系数.

2.2 基于 RAGAN 的运行指标校正模型

校正模型策略分为训练和运行两个阶段. 训练阶段整体流程结构如图 2 所示. 该阶段的模型训练为两部分: 1) 预报模型训练. 即预报模型根据上一时刻的综合生产指标 $Q_k(t-1)$ 、运行指标 $r_{ij}(t-1)$ 和当前工况 $d(t)$ 等信息, 更新自身参数, 以期能够根据当前时刻的信息, 尽可能精确地获取下一时刻的综合生产指标预报值 \hat{Q}_k , 进而利用该信息对运行指标进行前馈校正. 2) RAGAN 校正模型训练. 该模型由编码器 E 、生成器 G 和判别器 D 组成. 首先, 构建由运行指标调整量 $\Delta r_{ij}(t)$ 和工况条件变化量 $\Delta d(t)$ 组成的增量运行条件变量 s 和由综合生产指标预测值与目标值的偏差 $\Delta \hat{Q}_k$ 与上一采样时刻的运行指标 $r_{ij}^*(t-1)$ 、综合生产指标调整量 $\Delta Q_k(t-1)$ 、工况运行条件 $d(t)$ 组成的条件变量 ℓ . 编码器 E 和生成器 G 构成自编码结构, 通过显式地鼓励模型学习增量运行条件变量空间与潜变量空间之间的双向映射, 以保证生成器能够从噪声先验分布 $p(z)$ 生成运行指标校正值. 同时, 以条件变量 ℓ 作为条件输入的生成器 G 和判别器 D 构成生成对抗网络 (Generative adversarial networks, GAN) 模型, 以保证生成器 G 生成的运行指标校正值, 匹配于真实校正值的数据分布.

运行阶段流程结构如图 3 所示, 预报模型根据上一时刻的综合生产指标 $Q_k(t-1)$ 、运行指标 $r_{ij}(t-1)$ 和当前工况 $d(t)$ 等信息获得综合生产指标预报值 \hat{Q}_k . 将综合生产指标预报值与综合生产指标目标值的偏差 $\Delta \hat{Q}_k$ 、运行指标 $r_{ij}(t-1)$ 、当前工况 $d(t)$ 和综合生产指标调整量 $\Delta Q_k(t-1)$ 等信息作为条件变量 ℓ 与从先验分布 (高斯分布) 采样的噪声 z_r 同时输入生成器 G 产生运行指标调整量 $\Delta \hat{r}_{ij}(t)$, 获得的校正值叠加到运行指标初值 $\bar{r}_{ij}(t)$ 获得更新值 $r_{ij}^*(t)$:

$$\begin{cases} r_{ij}^*(t) = \bar{r}_{ij}(t) + \Delta \hat{r}_{ij}(t) \\ \Delta \hat{r}_{ij}(t) = G(z_r | \ell) \end{cases} \quad (3)$$

更新后的运行指标 $r_{ij}^*(t)$ 作为各个子过程新的目标值, 以减小不确定干扰对整个生产过程的影响, 从而达到综合生产指标目标值要求.

2.2.1 GAN 的基本原理

生成对抗网络^[20]由生成器 G 和判别器 D 两部分构成. 生成器 G 期望学习真实数据分布, 使生成的样本尽可能地接近真实样本值. 判别器 D 期望尽

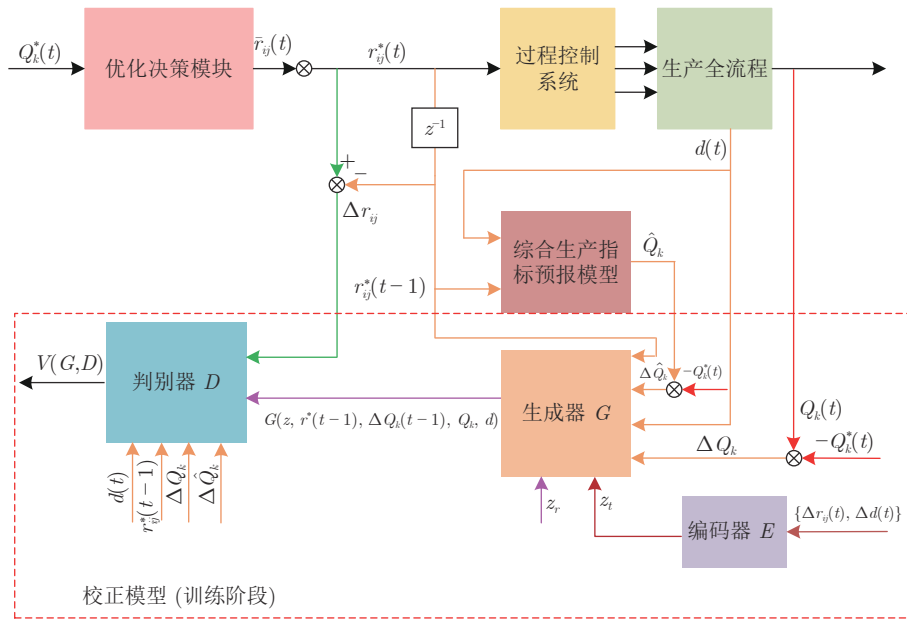


图 2 校正模型的训练过程

Fig.2 The training process of the correction model

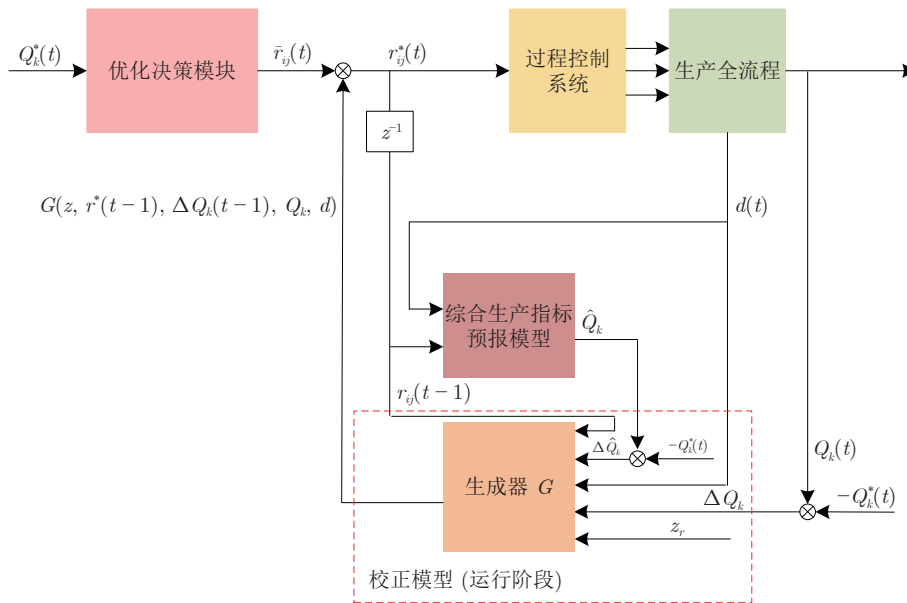


图 3 校正模型运行过程

Fig.3 The running process of the correction model

可能准确地判别出输入的样本是否来自真实样本数据. 两者通过零和博弈理论交替训练, 不断提升自身性能, 直至判别器 D 无法正确分辨输入数据真假时, 则认为生成器 G 学到了真实数据分布, 其目标函数为:

$$\min_G \max_D (E_{x \sim p_{\text{data}}(x)} [\ln D(x)] + E_{z \sim p(z)} [\ln(1 - D(G(z)))]) \quad (4)$$

式中, z 表示从先验分布 $p(z)$ (比如高斯分布) 采样

获得的噪声向量, $p_{\text{data}}(x)$ 表示训练集中真实数据服从的分布.

由于 GAN 经常遭遇模式崩溃、训练不稳定等问题, 学者们提出了许多 GAN 的变种, 用于提高 GAN 的稳定性和可控性. 条件生成对抗网络^[21] 在 G 和 D 的输入中附加条件信息, 用于指导生成器生成更真实的数据; 深度卷积生成对抗网络^[22] 采用反卷积神经网络和卷积神经网络代替全连接层 (Multi-layer perceptron, MLP) 构建生成器 G 和判别器 D ,

从实验的角度对 GAN 进行了优化; 变分自编码生成对抗网络^[23]使变分自编码与 GAN 互补结合, 使生成器 G 间接地获取真实图片信息, 有效地提升了 GAN 的稳定性; 沃瑟斯坦生成对抗网络^[24]从原理上分析了 GAN 训练不稳定的原因, 提出使用 Earth-mover 距离代替原本计算 JS (Jensen-Shannon) 散度的方式优化 GAN, 并从实验的角度给出了一些 GAN 的训练技巧; 序列生成对抗网络^[25]采用强化学习的策略梯度实现模型参数更新, 解决了早期的 GAN 无法生成离散数据分布的问题。

2.2.2 RAGAN 总体结构

RAGAN 总体流程如图 4 所示, 本文采用 LSTM 递归神经网络构建编码器 E 、生成器 G 和判别器 D 以实现多步推理校正。同时, 为了控制计算资源的消耗, 实现选择每步条件变量的选择性输入, 本文采用 DA 机制构建数据读入及写入模型。在时间步长 t 下, 编码器 E 将读入网络 $read^{enc}$ 选择的条件变量区域 p_t 和上一步 G 的输出 h_{t-1}^{gen} 拼接作为输入, 用于更新当前时刻 E 输出的中间状态变量 h_t^{enc} :

$$\begin{cases} p_t = read^{enc}(s, h_{t-1}^{gen}) \\ h_t^{enc} = Enc(h_{t-1}^{enc}, [p_t, h_{t-1}^{gen}]) \end{cases} \quad (5)$$

式中, $Enc(\cdot)$ 表示编码器 E 的单步映射。

根据编码器 E 输出的中间变量 h_t^{enc} 构造潜变量 z_t 的参数化分布函数, 构建该分布函数采用重参数化技巧^[26]。通过编码器 E 的中间变量 h_t^{enc} 获取潜变量分布函数的均值和方差, 构建高斯函数分布:

$$\begin{cases} q(z_t | h_t^{enc}) \sim N(Z_t | \mu_t, \sigma_t) \\ \mu_t = W(h_t^{enc}) \\ \sigma_t = \exp(W(h_t^{enc})) \end{cases} \quad (6)$$

式中, $W(\cdot)$ 表示构建基于全连接网络的线性变换, μ_t 和 σ_t 分别表示潜变量分布的均值矩阵和方差矩阵。

从潜变量分布中采样得到潜变量 z_t , 同时, 生成器读入网络 $read^{gen}$ 从当前条件变量中获取任务相关信息 p_ℓ , 潜变量 z_t 与任务相关信息 p_ℓ 组合输入

生成器 G 中, 以更新 G 输出的中间状态 h_t^{gen} ; 在该中间状态基础上, 通过写入网络 $write(\cdot)$, 生成当前步长下决策校正变量修改值的累加状态矩阵 c_t , 并将其叠加到用于生成最终决策的累加矩阵上, 该累加矩阵初始化为零, 而网络消耗的总时间步长 T 是一个超参数:

$$\begin{cases} p_\ell = read^{gen}(\ell, h_{t-1}^{gen}) \\ h_t^{gen} = Gen(h_{t-1}^{gen}, [z_t, p_\ell]) \\ c_t = c_{t-1} + write(h_t^{gen}) \\ x_T = \tanh(c_T) \end{cases} \quad (7)$$

式中, c 表示中间累加状态矩阵, c_t 表示 t 时间步所得的中间累加状态矩阵, $Gen(\cdot)$ 表示生成器 G 的单步映射。

判别器 D 的决策读入网络 $read^{dcm}$ 对上一步得到的决策矩阵 x_T 进行选择获得 \tilde{p}_t 。同时 D 的条件读入网络 $read_\ell^{dcm}$ 对条件变量 ℓ 进行选择得到 p_ℓ 。它们一同输入 D 更新其中间状态 h_t^{dcm} , 在时间步长 T 下, 对其输入做出判断概率 p_T :

$$\begin{cases} \tilde{p}_t = read^{dcm}(x_T, h_{t-1}^{dcm}) \\ p_\ell = read_\ell^{dcm}(\ell_t, h_{t-1}^{dcm}) \\ h_t^{dcm} = Dcm(h_{t-1}^{dcm}, [\tilde{p}_t, p_\ell]) \\ p_T = \text{sigmoid}(W(h_T^{dcm})) \end{cases} \quad (8)$$

式中, $Dcm(\cdot)$ 表示判别器 D 的单步映射。

2.2.3 分布式注意力机制

为了能够避免工业环境存在于条件变量的噪声及控制计算资源消耗, 在每个时间步长下, 本文构建读入网络对工业环境的条件变量进行选择, 将计算资源集中在任务相关性高的区域上。同时为了适用于工业过程中各个运行指标相对独立的特性, 本文提出 DA 机制用于构建读入网络。与经典的 DRAW (Deep recurrent attentive writer)^[14]不同, DA 机制无需指定 DRAW 中的步长, 可以直接独立参数化 N_f 个数据的位置。以生成器读入网络为例, DA 机制的基本原理为: 设定 DA 机制包含 N_f 个滤波器,

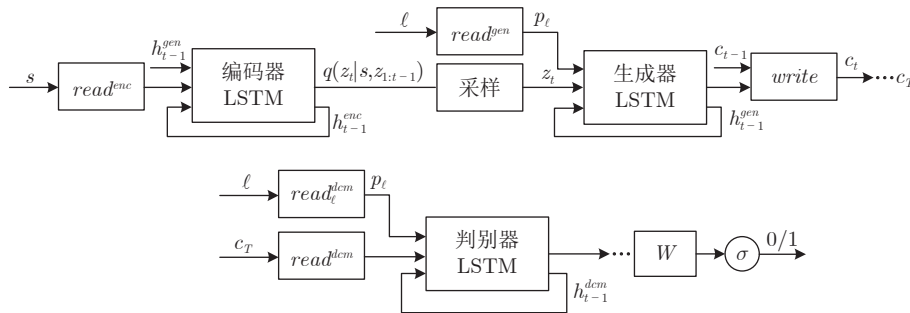


图 4 本文提出的 RAGAN 整体流程图

Fig. 4 The overall flow chart of the proposed RAGAN

对于条件变量 $\ell \in \mathbf{R}^{A \times 1}$, 在时间步长为 t 时, 通过对生成器上一步输出的中间状态变量 h_{t-1}^{gen} 进行线性变换, 动态确定 DA 机制的参数:

$$\begin{cases} (\tilde{g}_X, \ln \sigma^2, \ln \gamma) = W(h_{t-1}^{gen}) \\ \mu_X^{i_f} = \left[\frac{i_f(A-1)}{N_f-1} + 0.5 \right] (\tilde{g}_X^{i_f} + 1) \end{cases} \quad (9)$$

式中, $\tilde{g}_X \in \mathbf{R}^{N_f \times 1}$ 表示对于 N_f 个高斯滤波器在条件变量中的相对位置; $\mu_X^{i_f} \in \mathbf{R}^{N_f \times 1}$ 表示条件变量中 N_f 个高斯滤波器的分布位置; σ 表示高斯滤波器核参数的方差, γ 表示条件变量不同位置的可视性; $i_f = 0, 1, \dots, N_f - 1$ 表示第 i_f 个滤波器; A 表示条件变量个数; 根据上述所得的注意力机制的各个参数, 可获得当前时间步下的滤波器组矩阵 F_X :

$$F_X[i_f, a] = \frac{\exp\left(-\frac{(a - \mu_X^{i_f})^2}{2\sigma^2}\right)}{\sum_{a=0}^A \exp\left(-\frac{(a - \mu_X^{i_f})^2}{2\sigma^2}\right)} \quad (10)$$

式中, $a = 0, 1, \dots, A$ 表示条件变量的位置; 上述公式有 $\sum_{a=0}^A F_X[i_f, a] = 1$.

通过上述计算得到的滤波器组矩阵为不同位置的条件变量赋予系数, 从条件变量中提取任务相关度更高的部分数据:

$$read^{gen}(\ell, h_{t-1}^{gen}) = \gamma F_X \ell \quad (11)$$

2.2.4 目标函数

为了减少可能的映射函数空间, 编码器和生成器顺序连接得到的输出应与编码器的输入相同, 故定义多步重构损失函数:

$$\mathcal{L}^A(E, G) = \mathbb{E}_{s \sim p(s), \ell \sim p(\ell)} \|s - G(E(s), \ell)\|_1 \quad (12)$$

式中, $s = \{\Delta r(t), \Delta d(t)\}$ 表示增量运行指标和工况条件变量, ℓ 表示条件变量.

为使生成器能够生成有意义的运行指标调整量, 编码器输出与先验分布应尽可能地接近, 故本文定义编码器输出的潜变量分布与先验分布之间的 KL (Kullback-Leible) 散度:

$$\mathcal{L}^z(E) = \sum_{t=1}^T \text{KL}(q(z_t | s, z_{1:t-1}) \| p(z)) \quad (13)$$

式中, z_t 表示第 t 个步长的输入噪声向量, $z_{1:t-1}$ 表示 1 到 $t-1$ 步长的输入噪声向量, $p(z)$ 表示先验噪声分布, $q(\cdot)$ 表示编码器输出的噪声向量分布.

为了能够增强模型的探索能力以及加速整体学习的进程, 采用对抗学习的方法构造与决策智能体 G 相匹配的判别模型 D :

$$\begin{aligned} \mathcal{L}^{GAN}(G, D) = & \mathbb{E}_{\Delta r^*, \ell \sim p(\ell)} [\ln(D(\Delta r^*, \ell))] + \\ & \mathbb{E}_{z_{1:T} \sim p_A(z), \ell \sim p(\ell)} [1 - \ln(D(G(z_{1:T}, \ell), \ell))] \end{aligned} \quad (14)$$

式中, Δr^* 表示真实运行指标校正值.

为了避免运行指标调整量过大对整个生产过程稳定运行产生影响, 本文定义运行指标校正值的总方差损失函数:

$$\mathcal{L}_1^{\text{TV}}(G) = \mathbb{E}_{z_{1:T} \sim p_z(z), \ell \sim p(\ell)} \|E(G(z_{1:T}, \ell))\|_1 \quad (15)$$

式中, TV 表示方差损失. 为了指导生成器与工业运行环境的交互过程, 实现工业生产环境的仿真, 建立运行指标动态校正值的监督学习奖励为:

$$\mathcal{L}_1^B(P, G) = \mathbb{E}_{z, \ell \sim p(z, \ell)} \|\Delta Q_k^* - P(G(z_{1:T}, \ell))\|_1 \quad (16)$$

式中, ΔQ_k^* 表示实际综合生产指标与综合生产指标目标值的偏差.

训练结果使编码器可以将实际增量运行条件变量分布映射到低维潜变量空间, 而生成器可以根据潜变量信息学习到调整量信息, 通过低维潜变量空间生成足够真实的增量运行条件变量.

3 实验研究

3.1 实验研究背景

3.1.1 选矿生产流程描述

本文采用中国西部最大的赤铁矿选矿生产线作为研究背景. 生产工艺流程如图 5 所示, 该过程包括原矿加工、竖炉焙烧、强磁磨矿和弱磁磨矿、强磁选矿和弱磁选矿、精矿脱水和尾矿浓缩处理等 5 个过程自动化子单元. 原矿筛分将原始矿石分为 0 ~ 15 mm 的粉矿和大于 15 mm 的块矿, 分别由强磁选别生产线 (High intensity magnetic production line, HMPL) 和弱磁选别生产线 (Low intensity magnetic production line, LMPL) 处理. 在 HMPL 生产线中, 粉矿在球磨机中研磨处理成为矿浆, 然后送入高强度磁选机分离成为精矿和尾矿. 在 LMPL 生产线中, 块矿被送到焙烧炉通过焙烧还原得到强磁性矿石, 并经干选选别为有用矿石和废石, 废石送入废石堆, 有用矿石被送入球磨机研磨成为合适粒度的矿浆, 然后将矿浆送入低强度磁选机分离成为精矿和尾矿. 最后, 将分离后的精矿和尾矿脱水得到成品精矿和尾矿, 输出到仓库和尾矿堆.

上述过程由于受到不确定性的影响, 精矿产量与精矿品位等综合生产指标难以达到设定值, 此时需要及时对各子单元的运行指标进行调整, 使综合生产指标达到目标值范围. 各单元的运行指标 r_{ij} 如

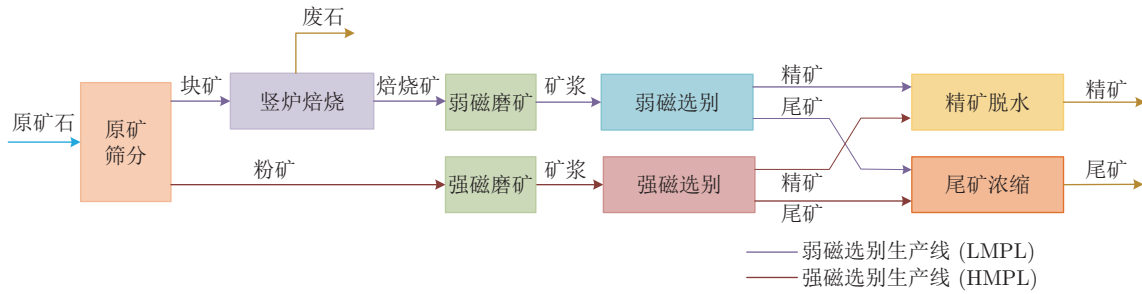


图 5 赤铁矿生产线流程图

Fig.5 Flow chart of hematite ore beneficiation production line

表 1 选矿过程的运行指标

Table 1 Operation index of the beneficiation process

生产线	工序	运行指标
弱磁选别 (LMPL)	焙烧过程	r_1 : 磁选管回收率
	磨矿过程	r_2 : 磨矿粒度
	弱磁选别	r_{31} : 弱磁精矿品位
		r_{32} : 弱磁尾矿品位
强磁选别 (HMPL)	磨矿过程	r_4 : 磨矿粒度
	强磁选别	r_{51} : 强磁精矿品位
		r_{52} : 强磁尾矿品位

表 1 所示. 根据实际情况, 目标综合铁精矿产量 Q_1^* 与综合铁精矿品位 Q_2^* 分别设定为 6 868.5 t/d 和 52.6%.


3.1.2 实验数据描述

本实验所用的选矿数据来源于上述的选矿实际生产线. 该数据样本共包含 574 组数据, 包含运行指标 $r_{ij}(t)$ 、综合生产指标 $Q_k(t)$ 和对应工况条件 $d(t)$ 三部分信息. 其中, $d(t)$ 包括弱磁入磨品位、强磁入磨品位、强磁球磨机台时处理量、弱磁球磨机台时处理量、竖炉台时处理量、球磨机运时和竖炉运时等. 模型训练前所有数据均进行了归一化处理, 并构建由运行指标调整量 $\Delta r_{ij}(t)$ 和综合生产指标变化量 $\Delta Q_k(t)$ 组成的历史数据集; 由运行指标调整量 $\Delta r_{ij}(t)$ 和工况条件变化量 $\Delta d(t)$ 构成的增量运行条件数据集; 以及由前一时刻运行指标 $r_{ij}^*(t-1)$ 、综合生产指标变化量 $\Delta Q_k(t)$ 、当前综合生产指标预报值与目标值的偏差 $\Delta \hat{Q}(t)$ 及工况条件变量 $d(t)$ 构成的条件变量数据集; 其中 500 组数据用于模型训练, 74 组数据用于模型验证.

3.2 模型实现


预报模型集成规模设置为 10, 设置惩罚项系数 λ 为 0.09, 正则化系数为 0.55.

通过最小化代价函数获得每个集成网络的输出权值, 根据式 (13) 获得预测输出, 预测结果如图 6



(a) 精矿产量预测值

(a) Predictive value of the concentrated production rate



(b) 精矿品位预测值

(b) Predictive value of the concentrated grade

图 6 综合生产指标预测值

Fig.6 Predictive value of comprehensive production indices

所示, 精矿产量和品位预测值的均方根误差分别为 107.3669 t 和 0.1070%.

根据本文提出的 RAGAN 校正方法, 构建 RAGAN 模型生成运行指标的校正. 基本设置如下: 训练周期、批次大小分别为 150、64; 各个读入网络设置的高斯核个数 $N = \{N_r^{enc}, N_r^{gen}, N_w, N_{rx}^{dcm}, N_{rl}^{dcm}\}$, 包括编码器读入高斯核数 N_r^{enc} 、生成器条件读入高斯核数 N_r^{gen} 、生成器写入高斯核数 N_w 、判别器读入高斯核数 N_{rx}^{dcm} 、判别器条件读入高斯核数 N_{rl}^{dcm} 默认值分别为 7、4、7、5、5; 多步推理的步数 N_{iter} 为 [1, 5, 10, 20]; 生成器 G 接收来自于高斯分布采样的随机噪声维度为 [4, 10, 20, 32, 64, 100]; 编码器 E 、生成器 G 与判别器 D 均采用 LSTM 递

神经网络组成, 其隐含层节点数分别为 256、256; 累加状态矩阵初始状态 c_0 、编码器初始输出 h_0^{enc} 、生成器初始输出 h_0^{gen} 、判别器初始输出 h_0^{disc} 均初始化为 0; 采用自适应矩阵估计算法优化 RAGAN. 本文方法中, 学习率 α 为 2×10^{-4} , 动量 β 为 0.5.

3.3 性能评估指标

本文采用三个维度的校正性能评估指标, 对运行指标动态校正效果进行评估^[13].

1) 模型校正性能 (Model adjustment performance, MAP). 该指标是校正过程中最关键的指标, 用于衡量实际获得的综合生产指标值 $Q_k(t)$ 与目标值 Q_k^* 之间的差距. 在实际中, 需要综合生产指标实际值应尽可能接近计划调度设计的目标值, 故该性能指标尽可能小:

$$\min \sum_{k=1}^2 |Q_k(t) - Q_k^*|^2 \quad (17)$$

2) 运行指标校正值的能量消耗 (Energy minimum, EM). 为了实现生产流程的稳定运行, 需要对运行指标的校正进行约束, 使运行指标的调整量尽可能地小, 避免剧烈的变化对生产的稳定、安全和效率造成影响, 故有:

$$\min \sum_{i=1}^I \sum_{j=1}^J |\Delta \hat{r}_{ij}(t)| \quad (18)$$

3) 基于互信息的信息差异评估 (Mutual information knowledge dissimilarity assessment, MIKDA). 该指标用于评估所建立模型的输出与人工校正的差异性. 希望它尽可能小, 以保证所建立模型尽可能地接近人工经验知识决策结果, 故有:

$$\min D(\Delta \hat{r}_{ij}(t) || \Delta r_{ij}^*(t)) \quad (19)$$

式中, $\Delta r_{ij}^*(t)$ 表示运行指标调整量的目标值, $\Delta \hat{r}_{ij}(t)$ 表示运行指标的实际调整量, D 表示基于互信息的信息差异评估方法.

上述 3 个评估指标之间可能存在矛盾, 需要在 3 个指标间取舍. 由于运行指标校正的根本目的是实现综合生产指标目标值, 同时尽可能避免对生产稳定性产生影响, 所以当 3 个指标存在矛盾时, 其优先级为 MAP 优于 EM, EM 优于 MIKDA.

3.4 实验结果与分析

3.4.1 实验结果

为了验证本文方法的多步校正及前馈-反馈校正的有效性, 本文首先与文献^[13]中基于 DMGAN 运行指标校正模型进行了对比, 然后分别构建了基于全

连接层的一步校正模型、基于 LSTM 的多步校正模型 (RAGAN_b) 和基于 LSTM 的前馈-反馈多步校正模型 (RAGAN_p), 对比结果如表 2、表 3 所示. 表 2 给出 74 组验证数据实验结果的平均值和方差. 由表 2 可以看出, RAGAN_p 相较于 DMGAN 方法在 MAP 和 EM 两个指标上表现更好, 但在 MIKDA 指标上表现相对较差, 说明前馈校正补偿了滞后性, 让校正算法表现效果更好. 同时 MIKDA 衡量的是校正方法与人工决策的差异性, 人工操作时一般根据经验具有随意性, 利用前馈进行补偿校正的 RAGAN 类方法获得的运行指标与人工经验数据相差较大, 故 MIKDA 评估指标表现更差. 与 MLP 相比, RAGAN_p 能在 3 个性能指标之间取得很好的平衡, 得到更优的校正效果, 表明多步校正方法能够有效提升运行指标校正性能. RAGAN_p 较 RAGAN_b 模型在 MAP 和 MIKDA 性能指标上提升了 7% 左右, EM 指标提升了 15% 左右, 表明增加预测信息辅助模型校正, 能够有效改善反馈模型具有的滞后性问题, 提升模型性能.

表 2 校正前后评价指标对比
Table 2 Comparison of evaluation indexes before and after correction

方法	MAP	EM	MIKDA
DMGAN	0.2324 ± 0	1.2190 ± 0	0
RAGAN_p	0.0335 ± 0.0025	0.8879 ± 0.0532	0.4010 ± 0.0061


表 3 不同校正方法对比
Table 3 Comparison of different correction methods

方法	MAP	EM	MIKDA
DMGAN	0.0480 ± 0.0078	1.0708 ± 0.3157	0.2300 ± 0.0017
MLP	0.1174 ± 0.0094	0.4796 ± 0.0698	0.3365 ± 0.0041
RAGAN_b	0.0362 ± 0.0025	1.0496 ± 0.0589	0.4281 ± 0.0022
RAGAN_p	0.0335 ± 0.0025	0.8879 ± 0.0532	0.4010 ± 0.0061

此外, RAGAN_p 的仿真结果与现有系统决策模型对比如图 7 所示, 其中 x 轴表示采样时间步长; y 轴表示对应生产指标的值, 红线与蓝线分别表示由现有决策系统决定的综合生产指标和通过 RAGAN_p 校正后得到的综合生产指标. 所得到的生产指标实际值越接近设定值说明模型校正性能效果越好. 由图 7 可以看出, 本文 RAGAN_p 的性能优于现有的决策系统. 同时, 本文方法和现有方法对比的性能指标如表 3 所示, 可以看出, 本文方法的性能在 MDA、EM 和 MKIDA 上均表现较好. 该模型能够用于抑制动态不确定性带给工业过程的影响, 从而使得综合生产指标的真实值能尽可能跟随目标值.


3.4.2 RAGAN_p 模型参数分析

下面对参数选择进行如下分析: 1) 分别改变推



(a) 精矿产量对比结果

(a) Comparison result of the concentrated production rate



(b) 精矿品位对比结果

(b) Comparison result of the concentrated grade

图7 本文方法与现有系统决策模型的对比

Fig.7 Comparison result between the proposed approach and the existing system

理步长为 1、5、10、15、20 的仿真结果对比如表 4 所示. 由表 4 可以看出, 初期当推理步长逐渐增大时, 模型的推理能力得到显著提高, 但当推理步长达到 15 之后模型能力略有下降. 分析原因可能是, 推理步长过大, 会导致过拟合, 影响模型的泛化能力. 此外, 推理步长过大, 还会增加计算量, 延长训练时间. 2) 当分别改变潜变量维度为 4、10、20、32、64、100 的仿真结果如表 5 所示. 由表 5 可以得出以下结果: a) 潜变量维度增大对 MAP 影响有一个逐渐增大的趋势; b) 对 MIKDA 的作用表现在, 当潜变量维度小于 20, MIKDA 逐渐较小, 表现出充足的潜变量空间对于决策空间的探索起促进作用; 而维度大于 20 之后, MIKDA 有所回升. 分析上述特征原因在于, 潜变量维度过大, 将会部分掩盖条件变量区域块的作用, 因此潜变量维度选择需要考虑到 RAGAN_p 模型所需噪声空间大小与输入维度之间的关系. 3) 不同高斯核数的 RAGAN_p 实验结果如表 6 所示. 由表 6 可以看出, 总体上增加高斯核数, 可以有效降低 MAP, 但是高斯核数过大, 会使模型性能降低. 分析原因可能是高斯核数过大, 会引入较多与任务无关的噪声向量, 从而导致模型性能下降; 与无注意力机制的模型相比, 基于 DA

表 4 不同推理步长对模型性能的影响

Table 4 The effect of different reasoning steps on model performance

步长数	MAP	EM	MIKDA
1	0.0711 ± 0.0043	0.2034 ± 0.0289	0.7229 ± 0.0080
5	0.0433 ± 0.0032	0.8982 ± 0.0764	0.4541 ± 0.0038
10	0.0335 ± 0.0025	0.8879 ± 0.0532	0.4010 ± 0.0061
15	0.0314 ± 0.0020	1.1687 ± 0.0396	0.4676 ± 0.0019
20	0.0363 ± 0.0023	0.9966 ± 0.0508	0.4490 ± 0.0040

表 5 不同潜变量维度对模型性能的影响

Table 5 The impact of different hidden variable dimensions on model performance

变量 z 的维数	MAP	EM	MIKDA
4	0.0306 ± 0.0023	0.6934 ± 0.0266	0.5011 ± 0.0019
10	0.0335 ± 0.0025	0.8879 ± 0.0532	0.4010 ± 0.0061
20	0.0368 ± 0.0036	1.0000 ± 0.0619	0.3823 ± 0.0020
32	0.0449 ± 0.0035	1.1559 ± 0.0809	0.4094 ± 0.0033
64	0.0469 ± 0.0042	0.8329 ± 0.0512	0.4165 ± 0.0028
100	0.0450 ± 0.0040	0.9498 ± 0.0773	0.4155 ± 0.0016

表 6 不同高斯核数对模型性能的影响

Table 6 The impact of different Gaussian kernels on model performance

高斯核数	MAP	EM	MIKDA
{5, 1, 5}	0.0455 ± 0.0040	0.8264 ± 0.0621	0.4278 ± 0.0081
{5, 3, 5}	0.0508 ± 0.0040	0.5435 ± 0.0408	0.4654 ± 0.0090
{5, 4, 5}	0.0352 ± 0.0029	0.7671 ± 0.0630	0.4315 ± 0.0038
{5, 5, 5}	0.0461 ± 0.0033	0.5582 ± 0.0345	0.5075 ± 0.0027
{5, 7, 5}	0.0413 ± 0.0031	0.6542 ± 0.0417	0.4914 ± 0.0028
{5, 9, 5}	0.0333 ± 0.0028	0.6898 ± 0.0387	0.4944 ± 0.0100
{5, 4, 3}	0.0383 ± 0.0030	0.6246 ± 0.0415	0.5332 ± 0.0040
{5, 4, 5}	0.0352 ± 0.0029	0.7671 ± 0.0630	0.4315 ± 0.0038
{5, 4, 7}	0.0355 ± 0.0038	0.9458 ± 0.0598	0.4177 ± 0.0075
{5, 4, 9}	0.0349 ± 0.0028	0.9773 ± 0.0701	0.4371 ± 0.0038
{3, 4, 7}	0.0344 ± 0.0027	1.0734 ± 0.0570	0.4409 ± 0.0020
{5, 4, 7}	0.0355 ± 0.0038	0.9458 ± 0.0598	0.4177 ± 0.0075
{7, 4, 7}	0.0335 ± 0.0025	0.8879 ± 0.0532	0.4010 ± 0.0061
{9, 4, 7}	0.0376 ± 0.0026	1.0355 ± 0.0521	0.4366 ± 0.0047
无高斯核	0.0347 ± 0.0022	1.9838 ± 0.0738	0.5216 ± 0.0021

的 RAGAN_p 可以有效提高模型在 3 个校正指标上的性能表现, 同时模型参数总量减少了约 45%. 4) 选择不同 TV 损失函数权重的模型性能指标对比如表 7 所示. 由表 7 可以看出, TV 损失函数权重与 EM 指标呈负相关关系. TV 损失权重的增加可以有效抑制 EM 指标, TV 损失的权重从 0 增加到 0.1, EM 指标降低了约 83%. 但是同时 MAP 性能

表 7 不同 TV 损失权重对模型性能的影响
Table 7 The impact of different TV loss coefficients on model performance

方程损失	MAP	EM	MIKDA
0	0.0334 ± 0.0028	1.1894 ± 0.0427	0.4603 ± 0.0016
0.0001	0.0336 ± 0.0034	0.9965 ± 0.0705	0.4488 ± 0.0041
0.0010	0.0335 ± 0.0025	0.8879 ± 0.0532	0.4010 ± 0.0061
0.0100	0.0365 ± 0.0026	0.6869 ± 0.0465	0.4326 ± 0.0057
0.1000	0.0489 ± 0.0021	0.1963 ± 0.0081	0.7533 ± 0.0036

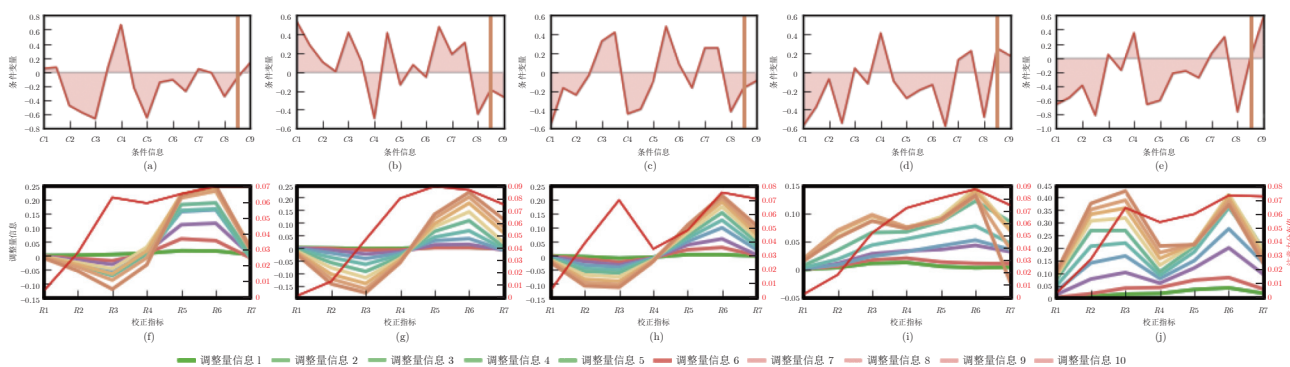


图 8 多步推理过程修正决策可视化

Fig.8 Visualization of multi-step reasoning process modifies decision

也逐渐变差. 原因是根据 EM 与 MAP 的定义, 两者本身就存在矛盾.

通过表 3~7 的实验结果对比, 本文选取参数为注意力机制 DA 的高斯核数为 {7, 4, 7}、TV 损失为 0.001、推理步长为 10 和潜变量维度为 10 的 RAGAN_p 模型实现.

3.4.3 多步推理过程可视化分析

设定超参数为默认值时, 多步推理过程修正决策可视化如图 8 所示. 图 8(a)~图 8(e) 分别对应编码器的读入模块 $read^{enc}$ 、生成器的读入模块 $read^{gen}$ 、生成器的写入模块 $write$ 、判别器的读入模块 $read^{dcm}$ 和判别器的条件读入模块 $read_l^{dcm}$ 的读入条件信息; 图 8(f)~图 8(j) 中的红色实线分别表示上述 5 个模块的条件信息变量的空间注意力分布. 可以看出, 不同的条件信息获得的注意力分布各不相同, 所以可以发现注意力机制构建的数据读入和写入模块对输入有数据筛选的作用, 且不同生产指标对模型训练的重要程度各不相同. 图 8(f)~图 8(j) 的其余线条分别对应上述 5 个模块读入的调整量信息变化. 由图 8 可以看出, 随着时间步长的增加, 最初的决策调整值是根据条件变量逐步修改的, 实现了运行指标的多步校正.

4 结束语

针对复杂工业过程受到不确定干扰影响导致的

综合生产指标难以达到其目标值范围的问题, 本文提出一种基于 RAGAN 的运行指标前馈-反馈校正方法. 本文采用集成随机神经网络构建综合生产指标预报模型, 用于为校正模型提供前馈信息, 以补偿反馈校正的滞后性; 本文模型的校正环节, 利用 LSTM 机制实现输入数据的循环利用, 以实现模型的多步迭代自校正, 提高模型的可解释性; 通过 DA 机制动态地为每一时间步选择任务相关性高的数据区域, 减少条件变量中的噪声影响, 降低任务复杂度. 此外采用某赤铁矿选矿生产线实际数据作为测试平台的仿真实验, 验证了本文方法的有效性.

今后工作将研究复杂工业过程的马尔科夫特性, 考虑工业过程一段时间内的运行情况, 探索强化学习等方法, 实现运行指标的序列化决策, 并应用于实际的运行指标校正过程.

References

- Chai T Y, Ding J L, Wang H. Multi-objective hybrid intelligent optimization of operational indices for industrial processes and application. In: Proceedings of the 18th IFAC World Congress. Milano, Italy: 2011. 10517-10522
- Ding Jin-Liang, Yang Cui-E, Chen Yuan-Dong, Chai Tian-You. Research progress and prospects of intelligent optimization decision making in complex industrial process. *Acta Automatica Sinica*, 2018, 44(11): 1931-1943 (丁进良, 杨翠娥, 陈远东, 柴天佑. 复杂工业过程智能优化决策系统的现状与展望. *自动化学报*, 2018, 44(11): 1931-1943)
- Chai T Y. Operation optimization and feedback control of complex industrial processes. *Acta Automatica Sinica*, 2013, 39(11): 1744-1757
- Papageorgiou E I, Salmeron J L. A review of fuzzy cognitive

- maps research during the last decade. *IEEE Transactions on Fuzzy Systems*, 2013, **21**(1): 66–79
- 5 Zhang B, Yang C, Zhu H, Shi P, Gui W. Controllable-domain-based fuzzy rule extraction for copper removal process control. *IEEE Transactions on Fuzzy Systems*, 2018, **26**(3): 1744–1756
 - 6 Gonzalez J L, Aguilar L T, Castillo O. A cognitive map and fuzzy inference engine model for online design and self fine-tuning of fuzzy logic controllers. *International Journal of Intelligent Systems*, 2009, **24**(11): 1134–1173
 - 7 Mori J. Dynamic Bayesian network based networked process monitoring for fault propagation identification and root cause diagnosis of complex dynamic processes. In: Proceedings of the 10th IFAC International Symposium on Dynamics and Control of Process Systems. Mumbai, India: 2013. 678–683
 - 8 Chai T Y, Ding J L, Wu F. Hybrid intelligent control for optimal operation of shaft furnace roasting process. *Control Engineering Practice*, 2011, **19**(3): 264–275
 - 9 Ding J, Chai T, Wang H, Chen H. Knowledge-based global operation of mineral processing under uncertainty. *IEEE Transactions on Industrial Informatics*, 2012, **8**(4): 849–859
 - 10 Kamsu-Foguem B, Rigal F, Mauget F. Mining association rules for the quality improvement of the production process. *Expert Systems With Applications*, 2013, **40**(4): 1034–1045
 - 11 Wang Ling, Meng Jian-Yao, Li Jun-Fei, Peng Kai-Xiang. An evolving fuzzy inference algorithm with multi-dimensional temporal association rules. *Acta Automatica Sinica*, 2018, **44**(8): 1446–1459
(王玲, 孟建瑶, 李俊飞, 彭开香. 基于多维时态关联规则的演化模糊推理预测算法. *自动化学报*, 2018, **44**(8): 1446–1459)
 - 12 Ding Jin-Liang, Yang Cui-E, Chen Li-Peng, Chai Tian-You. Dynamic multi-objective optimization algorithm based on reference point prediction. *Acta Automatica Sinica*, 2017, **43**(2): 313–320
(丁进良, 杨翠娥, 陈立鹏, 柴天佑. 基于参考点预测的动态多目标优化算法. *自动化学报*, 2017, **43**(2): 313–320)
 - 13 Zheng N Z, Ding J L, Chai T Y. DMGAN: Adversarial learning-based decision making for human-level plant-wide operation of process industries under uncertainties. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, **32**(3): 985–998
 - 14 Gregor K, Danihelka I, Graves A, Wierstra D. DRAW: A recurrent neural network for image generation. In: Proceedings of the International Conference on Machine Learning. Lille, France: 2015.
 - 15 Kalchbrenner N, Danihelka I, Graves A. Grid long short-term memory [Online], available: <https://arxiv.org/abs/1507.01526v3>, January 6, 2015
 - 16 Li Wen-Peng, Zhou Ping. Robust regularized RVFLNs modeling of molten iron quality in blast furnace ironmaking. *Acta Automatica Sinica*, 2020, **46**(4): 721–733
(李温鹏, 周平. 高炉铁水质量鲁棒正则化随机神经网络建模. *自动化学报*, 2020, **46**(4): 721–733)
 - 17 Han Hong-Gui, Zhang Lu, Lu Wei, Qiao Jun-Fei. Research on dynamic multi-objective intelligent optimal control for municipal wastewater treatment process. *Acta Automatica Sinica*, 2021, **47**(3): 620–629
(韩红桂, 张璐, 卢薇, 乔俊飞. 城市污水处理过程动态多目标智能优化控制研究. *自动化学报*, 2021, **47**(3): 620–629)
 - 18 Lu J, Ding J L, Dai X, Chai T Y. Ensemble stochastic configuration networks for estimating prediction intervals: A simultaneous robust training algorithm and its application. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, **31**(12): 5426–5440
 - 19 Schmidt W F, Kraaijveld M A, Duin R. Feedforward neural networks with random weights. In: Proceedings of the 11th IAPR International Conference on Pattern Recognition. Hague, Netherlands: 1992. 1–4
 - 20 Goodfellow I J, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative adversarial networks. In: Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal, Canada: 2014. 2672–2680
 - 21 Mirza M, Osindero S. Conditional generative adversarial nets [Online], available: <http://arxiv.org/abs/1411.1784>, November 6,

2014


- 22 Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. In: Proceedings of the 4th International Conference on Learning Representations. San Juan, USA: 2016.
- 23 Larsen A, Snderby S K, Larochelle H, Winther O. Autoencoding beyond pixels using a learned similarity metric [Online], available: <https://arxiv.org/abs/1512.09300>, February 10, 2016
- 24 Arjovsky M, Chintala S, Bottou L. Wasserstein GAN [Online], available: <https://arxiv.org/abs/1701.07875>, December 6, 2017
- 25 Yu L, Zhang W, Wang J, Yu Y. SeqGAN: Sequence generative adversarial nets with policy gradient [Online], available: <https://arxiv.org/abs/1609.05473v3>, September 25, 2016
- 26 Makhzani A, Shlens J, Jaitly N, Goodfellow I. Adversarial autoencoders. In: Proceedings of the 4th International Conference on Learning Representations. San Juan, UAS: 2016.



杨宇晴 东北大学流程工业综合自动化国家重点实验室硕士研究生。2018年获得东北大学学士学位。主要研究方向为生成对抗网络, 深度学习和人工智能。

E-mail: yang1301067169@163.com

(YANG Yu-Qing Master student at the State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University. She received her bachelor degree from Northeastern University in 2018. Her research interest covers generative adversarial nets, deep learning, and artificial intelligence.)



王德睿 东北大学流程工业综合自动化国家重点实验室硕士研究生。2019年获得东北大学学士学位。主要研究方向为生成对抗网络, 人工智能和机器学习。E-mail: a1044261411@163.com

(WANG De-Rui Master student at the State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University. He received his bachelor degree from Northeastern University in 2019. His research interest covers generative adversarial nets, artificial intelligence, and machine learning.)



丁进良 东北大学流程工业综合自动化国家重点实验室教授。主要研究方向为复杂工业过程的建模与运行优化控制, 计算智能及应用。本文通信作者。E-mail: jlding@mail.neu.edu.cn

(DING Jin-Liang Professor at the State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University. His research interest covers modeling and operation optimization control of complex industrial process, computational intelligence and its application. Corresponding author of this paper.)