

考虑预测不确定性的微电网实时控制策略研究

李龙胜¹, 冯文韬¹, 潘可佳¹, 郑言蹊¹, 邓冰妍¹, 景致远²

(1. 国网四川省电力公司信息通信公司, 四川 成都 610041;

2. 电子科技大学机械与电气工程学院, 四川 成都 611731)

摘要: 风能、光伏等可再生能源的高比例并网成为了缓解全球能源危机的一项重要措施。然而, 可再生能源实时出力中的间歇性和波动性给系统的安全性带来了一定的挑战。为了在提高可再生能源利用率的同时保证系统安全性, 提出了一种基于深度强化学习 (DRL) 算法的运行优化实时调度模型。首先, 构建了负荷预测模型实现负荷预测和高斯混合模型拟合预测误差; 其次, 考虑系统各节点的约束条件, 以系统运行成本和安全运行作为优化目标, 建立相应优化模型; 然后, 将优化问题转化为马尔可夫决策过程, 并采用双延迟深度确定性策略梯度算法求解; 最后, 利用 DRL 算法的环境交互机制和策略自由探索, 获得联合调度策略的最优结果。实验结果表明, 所提方法具有良好的适应性, 并且可以进行在线实时调度。

关键词: 预测不确定性; 深度强化学习; 实时控制

中图分类号: TM 734 **文献标志码:** A **文章编号:** 1003-6954(2024)01-0022-06

DOI: 10.16527/j.issn.1003-6954.20240104

Real-time Control Strategy for Microgrid with Prediction Uncertainty

LI Longsheng¹, FENG Wentao¹, PAN Kejia¹, ZHENG Yanxi¹, DENG Bingyan¹, JING Zhiyuan²

(1. State Grid Sichuan Information and Communication Company, Chengdu 610041, Sichuan, China;

2. School of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, Chengdu 611731, Sichuan, China)

Abstract: The high-ratio of renewable energy sources such as wind and PV integrated with power grid has emerged as an essential initiative to mitigate global energy crisis. However, the intermittent and volatility of renewable energy sources present certain challenges to the reliability of the system. A real-time scheduling model for operation optimization based on deep reinforcement learning (DRL) algorithm is introduced to enhance the utilization of renewable energy while guaranteeing system security. Firstly, a load forecasting model is constructed to achieve load forecasting and Gaussian mixture model which is applied to fit forecasting errors. Secondly, considering the constraints of each node of the system, taking system operating cost and safe operation as optimization target, the appropriate optimization model is formulated. And then, the optimization issue is converted into a Markov decision process and addressed by the twin delayed deep deterministic policy gradient (TD3) algorithm. Finally, the optimal joint scheduling strategy is acquired by environment interactive mechanism and policy discretionary exploration of DRL algorithm. The experimental results demonstrate that the proposed method has excellent adaptability and allows for online real-time scheduling.

Key words: forecast uncertainty; deep reinforcement learning; real-time control

0 引言

在过去的十年里, 随着环境问题日益严重, 智能电网的技术突飞猛进, 可再生能源在全球能源系统

中占据了越来越重要的地位^[1]。微电网中采用不同类型的分布式发电设备和储能装置来提升新能源的消纳比例^[2-3]。然而, 可再生能源的高度间歇性和不确定性对微电网的经济性和可靠性提出了重大挑战。

微电网运行优化研究的主流。文献[4]构建了一个包含风光储柴在内的多目标微电网优化模型,采用改进粒子群算法在运营成本和可再生能源消纳二者之间获得了最优的策略。文献[5]建立了考虑微电网之间信息交互的双层优化模型,以实现可再生能源的消纳与节点电压之间的平衡。文献[6]提出了一种基于近似动态规划的算法,将微电网运行优化问题转化为随机混合整数非线性规划问题。文献[7]应用了基于有限时间一致性的分布式优化算法来进行网络经济调度优化。文献[8]建立了一个能源管理系统,利用多个储能装置最大程度吸收可再生能源。文献[9]将可再生能源出力、电价和电力负荷设置为随机变量,并使用基于近似动态规划的经济调度算法减少了源荷预测不确定性对系统运行的影响。然而,这些方法在求解过程中未充分挖掘历史数据中的潜在信息,面对新问题时不仅需要重新训练且训练时间过长。

随着人工智能的崛起,基于数据驱动的强化学习(reinforcement learning, RL)可以通过历史数据获得经验从而实现在线优化^[10-11]。文献[12]提出了一种基于深度强化学习(deep reinforcement learning, DRL)的分布式能源运行优化模型,基于历史数据训练学习后可实时获取各设备实时控制策略。文献[13]针对多种可再生能源并入的特定微电网网络构建了对应的优化模型。文献[14]考虑到混合动力汽车电池寿命,提出了一种基于深度 Q 网络(deep Q-network, DQN)算法的行驶模式自适应策略。然而,上述方法在面对连续控制问题存在一定的局限性。

针对上述问题,下面提出一种基于负荷预测辅助的双延迟深度确定性策略梯度(twin delayed deep deterministic policy gradient, TD3)算法的微电网优化策略,主要包括:

1) 提出一种同时考虑微电网经济性和安全性的负荷预测辅助多目标优化控制策略;

2) 通过引入电池储能(battery energy storage, BES)元件提升微电网消纳可再生能源的比例;

3) 所提方法通过历史训练数据离线训练后可以做出实时决策。

1 问题建模

微电网的具体框架结构如图 1 所示,主要包括

了主网、风力发电站、光伏发电站、电池储能站及用电负荷。




图 1 微电网框架结构

1.1 优化模型

所提方法通过控制电池储能、风力发电站和光伏发电站三者的相关出力,保证系统运行安全的同时实现日运营成本最低。

优化目标函数为:

$$F = \min \sum_{t=1}^{24} C_{\text{gird},t} \quad (1)$$

$$C_{\text{gird},t} = p_t \cdot L_t \quad (2)$$

式中: F 为日运营成本; $C_{\text{gird},t}$ 为时刻 t 的运营成本; p_t 为时刻 t 的电价; L_t 为时刻 t 时微电网所需电量。

电池储能的容量越限惩罚和电压越限惩罚的表达式为:

$$C_{v,t} = \begin{cases} \eta & V_{i,t} \leq V_{\min} \text{ or } V_{i,t} > V_{\max} \\ 0 & V_{\min} \leq V_{i,t} \leq V_{\max} \end{cases} \quad (3)$$

$$C_{\text{BES},t} = \begin{cases} \chi & S_{\text{oc},t} < S_{\text{oc},\min} \text{ or } S_{\text{oc},t} > S_{\text{oc},\max} \\ 0 & S_{\text{oc},\min} \leq S_{\text{oc},t} \leq S_{\text{oc},\max} \end{cases} \quad (4)$$

式中: $C_{v,t}$ 为时刻 t 的电压惩罚成本; η 为一个惩罚常数,根据实际情况进行设定; $V_{i,t}$ 为时刻 t 节点 i 的电压值; V_{\min} 为电压阈值最小值; V_{\max} 为电压阈值最大值; $C_{\text{BES},t}$ 为时刻 t 电池储能的惩罚值; χ 为一个常数; $S_{\text{oc},t}$ 为时刻 t 电池储能的容量值; $S_{\text{oc},\min}$ 和 $S_{\text{oc},\max}$ 分别为电池储能容量的最小值和最大值。

1.2 马尔科夫决策建模

所提方法将微电网实时优化调度问题转化为一个马尔科夫决策,主要包含环境、智能体、动作、状态、奖励值和转移函数。

环境:微电网网络。

智能体:用于求解的深度强化学习算法。

状态:主要包括时刻 t 各节点所需电功率、光伏

电站有功出力、风力发电站有功出力、电池储能容量、各节点电压和当时电价。

动作:主要包括时刻 t 电池储能元件有功输出、光伏无功出力、风电无功出力和电池储能无功出力。

奖励值:智能体执行当前动作时所获得的奖励,为运营成本、电池储能容量越限惩罚值和电压越限惩罚值三者之和。

状态转移函数:表示从当前状态转移到下一个状态的概率函数。

1.3 相关约束

系统其他相关约束如式(5)一式(10)所示,其中式(5)一式(6)为微电网潮流计算公式。

$$P_{i,t} = P_{\text{load},i,t} - P_{\text{Wind},t} - P_{\text{PV},t} - P_{\text{BES},t} - P_{S,t}, i \in N \quad (5)$$

$$Q_{i,t} = Q_{\text{load},i,t} - Q_{S,t}, i \in N \quad (6)$$

$$-1 \leq W_{\text{Wind},t} \leq 1 \quad (7)$$

$$-1 \leq W_{\text{PV},t} \leq 1 \quad (8)$$

$$-1 \leq W_{\text{BES},t} \leq 1 \quad (9)$$

式中: $P_{i,t}$ 、 $Q_{i,t}$ 分别为时刻 t 节点 i 需注入的有功功率和无功功率; $P_{\text{load},i,t}$ 、 $Q_{\text{load},i,t}$ 分别为时刻 t 节点 i 负荷需求的有功功率和无功功率; $P_{\text{Wind},t}$ 为时刻 t 风机输出有功功率; $P_{\text{PV},t}$ 为时刻 t 光伏输出有功功率; $P_{\text{BES},t}$ 为时刻 t BES 输出有功功率; $P_{S,t}$ 、 $Q_{S,t}$ 分别为时刻 t 系统所需的有功功率与无功功率; $W_{\text{Wind},t}$ 为时刻 t 风机无功出力比例; $W_{\text{PV},t}$ 为时刻 t 光伏无功出力比例; $W_{\text{BES},t}$ 为时刻 t BES 无功出力比例。

2 所提方法

2.1 预测模型

典型基于深度神经网络(deep neural network, DNN)的预测模型表达式^[15]为:

$$y' = h_n \{h_{n-1} [h_{n-2} \cdots h_1(X)]\} \quad (10)$$

$$h_d(\cdot) = \omega_d h_{d-1} + k_d, d = 1, 2, \dots, n \quad (11)$$

式中: X 为第1层输入数据集; $h_n(\cdot)$ 为第 n 层网络的输出值; y' 为经过 n 层神经网络计算后的预测值; ω_d 为第 d 层网络的权值; k_d 为第 d 层网络的偏差。

损失函数为:

$$E = \frac{1}{k} \sum_{f=1}^k (y_f - y'_f)^2 \quad (12)$$

$$\tau_{t+1} = \tau_t - \alpha \nabla E \quad (13)$$

式中: k 为选取测试的数据量; y_f 为第 f 组数据真实值; τ_t 为 t 时刻 DNN 参数; α 为学习率; ∇E 为下降

梯度。

2.2 高斯混合模型

常用的高斯混合模型是一种数据概率分布模型,它将具有连续性的数据分类为有限数量的叠加高斯分布函数^[16]。

$$P(\mathbf{x}) = \sum_{z=1}^Z \omega_z G(\mathbf{x} | \gamma_z, \zeta_z) \quad (14)$$

式中: \mathbf{x} 为数据集; ω_z 、 γ_z 和 ζ_z 分别为第 z 个高斯分布的权重比、均值和斜方差; Z 为混合高斯分布中高斯分布函数的数量。高斯混合函数可以表示为

$$G(\mathbf{x} | \gamma_z, \zeta_z) = \frac{1}{2\pi^{D/2} \sqrt{\zeta_z}} \cdot \exp\left[-\frac{1}{2}(\mathbf{x} - \gamma_z)^T \cdot \zeta_z^{-1}(\mathbf{x} - \gamma_z)\right] \quad (15)$$

式中, D 为数据的维度。

2.3 TD3 算法

强化学习例如 Q-learning 在求解时需要遍历整个 Q 表,每次计算都需要循环一次,且取得的动作必须是离散的。为了提高求解速度以及应对连续性问题,DRL 的概念被提出。所采用的 TD3 算法在深度确定性策略梯度(deep deterministic policy gradient, DDPG)算法的基础上,增加了两个状态网络解决 Q 值高估问题^[17]。

2.3.1 评价网络

TD3 算法的评价网络包括了两个计算 Q 值的评价函数,即 $Q_1(s_t, a_t | \theta_1)$ 和 $Q_2(s_t, a_t | \theta_2)$,设 m_t 为 t 时刻目标评价函数结果,即^[17]:

$$m_t = r_t + \tau \min_{j=1,2} Q'_j(s_{t+1}, a_{t+1} | \theta'_j) \quad (16)$$

式中: r_t 为时刻 t 的奖励值; τ 为折扣系数; $Q'_j(\cdot)$ 为第 j 个目标评价函数; s_{t+1} 为时刻 $t+1$ 的状态; a_{t+1} 为时刻 $t+1$ 的动作; θ'_j 为第 j 个目标评价函数的参数。

评价网络损失函数为

$$L(\theta_j) = E\{[m_t - Q_j(s_t, a_t | \theta_j)]^2\}, j = 1, 2 \quad (17)$$

式中, $E(\cdot)$ 为数学期望计算函数。其梯度计算公式为:

$$\nabla_{\theta_j} J(\theta_j) = E\{[m_t - Q_j(s_t, a_t | \theta_j)]^2 \cdot \nabla_{\theta_j} Q_j(s_t, a_t | \theta_j)\}, j = 1, 2 \quad (18)$$

$$\theta_{j,t+1} = \theta_{j,t} - \alpha \nabla_{\theta_j} J(\theta_j), j = 1, 2 \quad (19)$$

式中: $\nabla_{\theta_j} J(\theta_j)$ 为评价网络下降梯度; α 为评价网络参数更新的学习率,取值较小。

2.3.2 动作网络

动作网络中的动作函数表达式为^[18]

$$a = \pi_{\theta}(s_{t+1} | \vartheta) \quad (20)$$

式中: $\pi_{\vartheta}(\cdot)$ 为动作函数; ϑ 为动作函数的参数。

梯度可以表示为:

$$\nabla_{\vartheta} J(\vartheta) = E\{\nabla_a Q(s_t, a_t | \theta) \cdot \nabla_{\vartheta} [\pi_{\vartheta}(s_t) + \varphi]\} \quad (21)$$

$$\vartheta_{t+1} = \vartheta_t - \beta \nabla_{\vartheta} J(\vartheta) \quad (22)$$

式中: φ 为目标动作函数中增加的噪声,为了降低求解中过拟合造成智能体动作的选择陷入局部最优中,在目标动作函数中都选择增加了较小的噪声; β 为动作函数的学习率。

目标动作函数的表达式为:

$$a' = \pi_{\vartheta'}(s'_{t+1} | \vartheta') + \varphi \quad (23)$$

$$\varphi \sim \text{clip}[N(0, \delta), -e, e], e > 0 \quad (24)$$

式中: δ 为方差; e 为取值截断位置。式(24)表示 φ 为一个服从正态分布中的噪声。

目标动作函数和目标评价函数的相关参数通过设置平滑系数进行软更新,即:

$$\theta'_{t+1} = \zeta \theta_t - (1 - \zeta) \theta'_t \quad (25)$$

$$\vartheta'_{t+1} = \zeta \vartheta_t - (1 - \zeta) \vartheta'_t \quad (26)$$

式中: θ' 为目标动作函数的参数; ζ 为平滑系数; ϑ' 为目标评价函数系数。

算法详细的流程如图 2 所示。

3 算例分析

算例采用的相关数据来自网上开源数据。负荷预测详细结果如图 3 所示,从图中可以看出基于 DNN 的预测模型能够较好进行日前预测。为更好地验证所提 DNN 算法的先进性,选取了线性回归算法和支持向量回归算法作为对比实验,结果如表 1 所示。常用的预测指标主要包括平均绝对误差(mean absolute error, MAE)和平均绝对百分比误差(mean absolute percentage error, MAPE),具体的计算方式参考文献[19]。从表 1 可以看出,所提 DNN 算法在 MAE 或 MAPE 上的数值都小于其他两种方法,再次验证了所提算法的先进性。为扩大优化模型训练数据的不确定性,高斯混合模型基于预测误差结果拟合新的误差数据。将基于高斯混合模型生成的误差结果作为噪声输入到所提控制方法的训练集中,以此实现控制模型在优化中考虑预测的不确定性,同时实现预测端与运行优化二者相结合,从而获取更有效的控制策略。

高斯混合模型在不同的低维数据内都具有良好的效果,由于每个节点的电力负荷数据都不一样,因

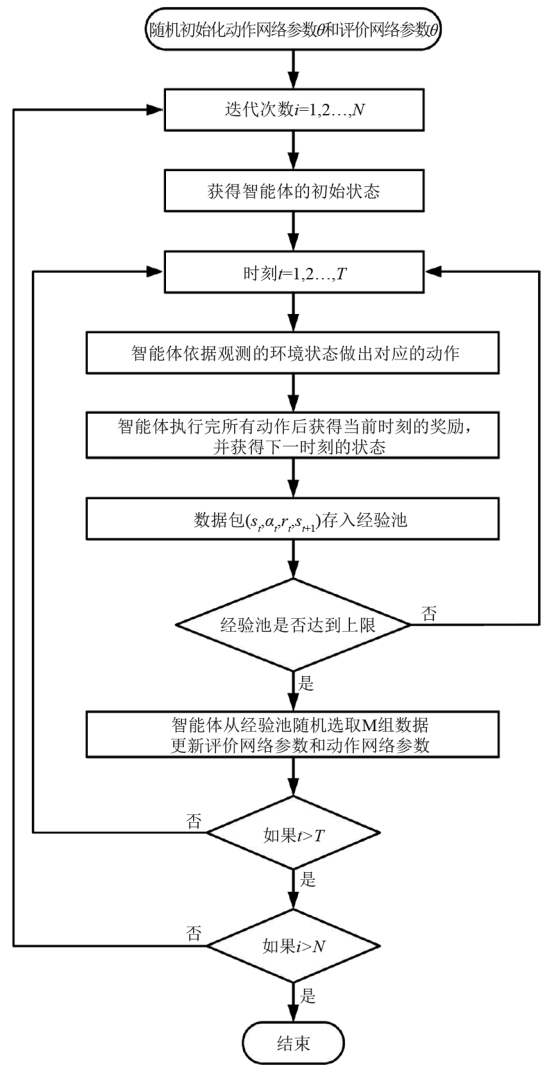


图 2 算法流程




图 3 负荷预测结果

表 1 各预测方法结果对比

方法	MAE	MAPE/%
线性回归算法	0.18	16.74
支持向量回归算法	0.11	11.43
所提 DNN 算法	0.08	9.42

此须对每个节点的负荷进行拟合。选取部分节点的结果进行展示,如表 2 所示,从表中可以看出,高斯分布的数量取决于数据分布类型,高斯分布函数的详细参数也不尽相同。

表 2 高斯混合模型相关参数

节点	权重	均值	方差
1	(0.155, 0.845)	$(7.4 \times 10^{-4}, 0.001\ 3)$	$(8.84 \times 10^{-7}, 9.81 \times 10^{-5})$
3	(0.65, 0.11, 0.24)	$(0.01, -0.01, 8 \times 10^{-4})$	$(1.5 \times 10^{-4}, 8 \times 10^{-5}, 1 \times 10^{-4})$
5	(0.68, 0.15, 0.17)	$(-0.003\ 1, -1.38 \times 10^{-4}, -0.01)$	$(3.1 \times 10^{-5}, 5.4 \times 10^{-8}, 3.9 \times 10^{-5})$
7	(0.29, 0.32, 0.39)	$(0.001\ 7, 0.028, 0.007\ 3)$	$(2.7 \times 10^{-5}, 5.05 \times 10^{-4}, 1.8 \times 10^{-4})$
9	(0.62, 0.38)	$(0.001\ 5, 0.001\ 3)$	$(8.7 \times 10^{-6}, 3.4 \times 10^{-5})$
11	(0.84, 0.14, 0.02)	$(-0.001\ 2, 3.1 \times 10^{-4}, 0.022\ 4)$	$(2.7 \times 10^{-5}, 5.05 \times 10^{-4}, 1.8 \times 10^{-4})$

表 3 给出了 DDPG 以及所提 TD3 控制方法的参数设置。为验证所提负荷预测辅助 DRL 方法的有效性,选取了经典的粒子群算法 (particle swarm optimization, PSO) 和 DDPG 作为对比算法。DDPG 作为确定性策略优化,在求解过程中容易产生 Q 值高估问题。

表 3 DDPG 与所提方法参数设置

参数	DDPG	所提方法 (TD3)
记忆库容量	12 000	12 000
奖励值折扣因子	0.95	0.98
批处理数量	64	64
训练次数	10 000	10 000
软更新因子	0.001	0.001
动作网络学习率	0.000 1	0.000 3
评价网络学习率	0.000 1	0.000 3

DDPG 与所提方法训练过程奖励的详细信息如图 4 所示。从图中可以看出,奖励值在经过前期 500 次自由探索后会急剧下降。这是因为探索过程动作值都是随机赋值,在自由探索结束后选择的动作不一定会优于自由探索阶段的动作;随着训练的继续进行,奖励值逐渐增大,3000 次以后所提方法逐渐开始收敛直到训练结束。可以看出,所提方法训练效果优于 DDPG。

为验证所提方法的有效性,用测试集验证最终效果。测试集平均成本如表 4 所示,从表中可以看出基于 TD3 算法的控制策略明显优于其他两种算法的控制策略,其与 PSO 对比经济性提升了 19.34%,相较于 DDPG 经济性提升了 11.96%。这证

明了所提方法的有效性以及先进性。

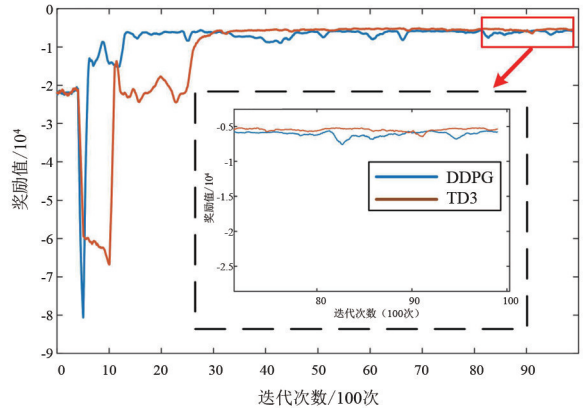


图 4 训练效果

表 4 测试集结果对比

方法	平均成本/(欧元·d ⁻¹)
PSO	7 331.95
DDPG	6 717.68
TD3	5 913.74

选取测试集中的某日进行详细的阐述,该日电负荷需求以及电价如图 5 所示。从图中可以看出:从 5:00 电负荷开始增加,直至 9:00 达到最大值并高负荷运转持续到 16:00 左右,然后开始缓缓降低;电价从凌晨到 8:00 一直维持在较低的价格,9:00—18:00 价格都保持比较稳定,19:00 电价增加到最大值并维持到 21:00。该日光伏和风电出力情况如图 6 所示。从图中可以看出:光伏从 9:00 开始吸收太阳能转化功率,逐渐升高在 12:00 达到最大值,随着太阳能的削减,光伏出力逐渐降低直至 18:00 降为 0 MW;风机在 10:00 前都是缓慢爬升,从 10:00—19:00 一直维持最大出力,直至 19:00 以后其出力开始缓慢降低。

储能元件在该日的出力结果如图 7 所示。从图中可以看出:在 7:00 之前,由于电价比较便宜,储能




图 5 测试集某日负荷需求以及电价




图 6 测试集某日光伏和风电出力情况




图 7 测试集某日储能元件出力结果

元件不断从主网购电实现充能;8:00—12:00 由于电价相较凌晨上涨较多,储能元件选择释放电能减少从主网购电来降低运营成本;13:00—17:00 电负荷逐渐降低,电价也相应地降低一部分,而可再生能源的出力达到了最大值,为提升可再生能源的消纳比例和应对 19:00 以后电价暴涨的情况,储能元件选择充能;在 18:00 开始释放自己的电能,从而降低微电网从主网购电成本。

采用所提控制策略该日的电压值如图 8 所示。图中的结果显示,所提控制策略在保证一天运营成本最低的同时保证了系统电压位于安全阈值范围内,即提高系统经济性的同时又保证系统的安全性,验证了所提方法的有效性。

4 结 论

提升新能源的消纳比例是实现微电网经济环保的重要举措,也是实现碳达峰、碳中和的重要途径。上面提出了一种同时考虑微电网经济性和安全性的

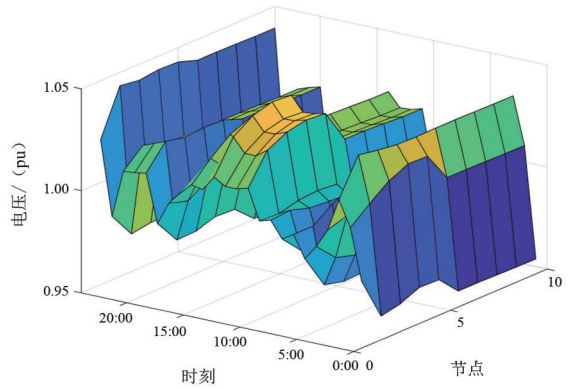


图 8 测试集某日所提方法电压值

运行实时调度模型,降低了系统运行成本。实验仿真表明:1) 所提方法的性能相较 PSO 提升了 19.34%,相较 DDPG 提升了 11.96%,控制效果更好;2) 所提控制策略通过历史数据训练以后可以根据实时状态做出最优的决策;3) 所提方法将预测不确定性与运行优化模型相结合,提升了优化控制模型应对预测不确定的泛化能力。

参考文献

- [1] HEDAYATI-MEHDIABADI M, BALASUBRAMANIAN P, HEDMAN K W, et al. Market implications of wind reserve margin [J]. IEEE Transactions on Power Systems, 2018, 33(5): 5161-5170.
- [2] ATZEM I, ORDONEZ L G, SCUTARI G, et al. Demand-side management via distributed energy generation and storage optimization [J]. IEEE Transactions on Smart Grid, 2013, 4(2): 866-876.
- [3] YAN N, ZHANG B, LI W, et al. Hybrid energy storage capacity allocation method for active distribution network considering demand side response [J]. IEEE Transactions on Applied Superconductivity, 2019, 29(2): 1-4.
- [4] 唐秀明,朱欣科,陈君,等. 计及负荷预测的风光柴储联供型微网系统的运行优化[J/OL]. 电气工程学报: 1-11[2023-06-09]. <http://kns.cnki.net/kcms/detail/10.1289.TM.20230510.1232.020.html>.
- [5] 李振坤,汪璇璇,时珊珊,等. 考虑微电网间功率交互的配电网双层优化调度[J]. 南方电网技术, 2022, 16(9): 107-118.
- [6] SHUAI H, FANG J K, AI X M, et al. Optimal real-time operation strategy for microgrid: An ADP-based stochastic nonlinear optimization approach [J]. IEEE Transactions on Sustainable Energy, 2019, 10(2): 931-942.

- 性[J]. 高电压技术, 2016, 42(11):3607-3615.
- [43] ZHAO Xindong, SUN Weifeng, SUN Hong. Enhanced insulation performances of crosslinked polyethylene modified by chemically grafting chloroacetic acid allyl ester[J]. *Polymers(Basel)*, 2019, 11(4):592.
- [44] QIU Peng, CHEN Junqi, SUN Weifeng, et al. Improved DC dielectric performance of photon-initiated crosslinking polyethylene with TMPTMA auxiliary agent[J]. *Materials(Basel)*, 2019, 12(21):3540.
- [45] 李晓楠, 刘凯, 杨雁, 等. 高频表面电荷输运对油纸绝缘局部放电的影响[J]. *中国电机工程学报*, 2022, 42(3):1223-1233.
- [46] 霍振星. 基于 10 kV XLPE 电缆的绝缘老化分析研究[D]. 天津:天津大学, 2009.
- 作者简介:**
王浩铭(1997), 男, 硕士研究生, 研究方向为高电压技术;
刘巧珏(1991), 女, 博士, 副研究员, 研究方向为高电压与绝缘技术、脉冲功率及放电等离子体技术;
崔智桐(1999), 男, 硕士, 工程师, 从事电力电子变换相关研究工作;
蔡致坤(1995), 男, 硕士, 工程师, 从事电力电子变换相关研究工作;
胡武生(1996), 男, 硕士, 工程师, 从事高电压与绝缘技术的研究工作。
- (收稿日期:2023-09-03)
-
- (上接第 27 页)
- [7] MAO S, DONG Z W, SCHULTZ P, et al. A finite-time distributed optimization algorithm for economic dispatch in smart grids[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2021, 51(4):2068-2079.
- [8] GARCIA-TORRES F, BAEZ-GONZALEZ P, TOBAJAS J, et al. Cooperative optimization of networked microgrids for supporting grid flexibility services using model predictive control[J]. *IEEE Transactions on Smart Grid*, 2021, 12(3):1893-1903.
- [9] SHUAI H, FANG J K, AI X M, et al. Stochastic optimization of economic dispatch for microgrid based on approximate dynamic programming[J]. *IEEE Transactions on Smart Grid*, 2019, 10(3):2440-2452.
- [10] 胡维昊, 曹迪, 黄琦, 等. 深度强化学习在配电网优化运行中的应用[J]. *电力系统自动化*: 2023, 47(14):174-191.
- [11] FU Q M, HAN Z C, CHEN J P, et al. Applications of reinforcement learning for building energy efficiency control: A review[J]. *Journal of Building Engineering*, 2022, 50:104165.
- [12] 阮应君, 侯泽群, 钱凡悦, 等. 基于深度强化学习的分布式能源系统运行优化[J]. *科学技术与工程*, 2022, 22(17):7021-7030.
- [13] 刘俊峰, 陈剑龙, 王晓生, 等. 基于深度强化学习的微能源网能量管理与优化策略研究[J]. *电网技术*, 2020, 44(10):3794-3803.
- [14] LIN X Y, XU X H, WANG Z R. Deep Q-learning network based trip pattern adaptive battery longevity-conscious strategy of plug-in fuel cell hybrid electric vehicle[J]. *Applied Energy*, 2022, 321:119378.
- [15] SANTOS O L D, DOTTA D, WANG M, et al. Performance analysis of a DNN classifier for power system events using an interpretability method[J]. *International Journal of Electrical Power & Energy Systems*, 2022, 136:107594.
- [16] YEO T, SHIGEMATSU N, KATORI T. Dynamically recrystallized grains identified via the application of Gaussian mixture model to EBSD data[J]. *Journal of Structural Geology*, 2023, 167:104800.
- [17] FUJIMOTO S, Hoof H V, MEGER D. Addressing function approximation error in actor-critic Methods[J]. <https://arxiv.org/pdf/1802.09477v3.pdf>
- [18] HONG J C, ZHANG T Z, ZHANG Z, et al. Investigation of energy management strategy for a novel electric-hydraulic hybrid vehicle: Self-adaptive electric-hydraulic ratio[J]. *Energy*, 2023, 278:127528.
- [19] DING Y P, DANG Y G. Forecasting renewable energy generation with a novel flexible nonlinear multivariable discrete grey prediction model[J]. *Energy*, 2023, 227:127664.
- 作者简介:**
李龙胜(1976), 男, 硕士, 高级工程师, 研究方向为新型电力系统;
冯文韬(1996), 男, 硕士, 研究方向为新型电力系统;
潘可佳(1982), 男, 硕士, 高级工程师, 研究方向为新型电力系统;
郑言蹊(1994), 女, 硕士, 研究方向为电力数据服务;
邓冰妍(1996), 女, 硕士, 研究方向为电力大数据分析;
景致远(1999), 男, 硕士, 研究方向为电子信息、智能电网。
- (收稿日期:2023-06-27)