

DOI: 10.19783/j.cnki.pspc.250175

基于信息熵量化评价的深度强化学习储能微网 柔性补偿自抗扰稳压技术

周雪松¹, 王馨悦¹, 马幼捷¹, 陶珑¹, 问虎龙², 赵明³

(1. 天津理工大学, 天津 300384; 2. 天津瑞能电气有限公司, 天津 300381;
3. 承德电智尚节能科技有限公司, 河北 承德 067000)

摘要: 直流微电网母线电压稳定是实现新能源高水平利用的重要前提。为解决源荷互动不确定性引起的母线电压波动问题, 提出了一种基于信息熵量化评价的深度强化学习储能微网柔性补偿自抗扰稳压技术。首先, 分析了传统扰动补偿在能量交互不确定性下的局限。其次, 运用信息熵评价指标量化不确定性, 以无序系统有序化为目标引入深度强化学习设计柔性补偿, 确保算法在母线电压稳定范围内收敛。进而, 从变结构、变参数、变阻尼三方面剖析柔性补偿改善系统特性的内涵。最后, 通过仿真实验验证得到, 柔性补偿技术在源-荷-储多种不确定性工况下具有显著抗扰性能优势, 可改善直流母线电压稳定性。

关键词: 储能变换器; 自抗扰; 深度强化学习; 信息熵; 抗扰性

Flexible disturbance-rejection voltage regulation for energy storage microgrids using deep reinforcement learning with information entropy-based quantitative evaluation

ZHOU Xuesong¹, WANG Xinyue¹, MA Youjie¹, TAO Long¹, WEN Hulong², ZHAO Ming³

(1. Tianjin University of Technology, Tianjin 300384, China; 2. Tianjin Ruineng Electric Co., Ltd., Tianjin 300381, China;
3. Chengde Electric Zhishang Energy Saving Technology Co., Ltd., Chengde 067000, China)

Abstract: Stable DC bus voltage is a critical prerequisite for achieving high utilization of new energy in DC microgrids. To address bus voltage fluctuations caused by uncertainties in source-load interactions, a flexible disturbance-rejection voltage regulation technique for energy-storage microgrids is proposed, based on deep reinforcement learning (DRL) with information entropy-based uncertainty quantification. First, the limitations of traditional disturbance compensation under uncertain energy interactions are analyzed. Second, information entropy evaluation index is used to quantify uncertainty, and DRL is introduced with the objective of transforming a disordered system into an ordered one, enabling flexible compensation and ensuring algorithmic convergence within the allowable voltage range. Furthermore, mechanism by which flexible compensation enhances system performance is examined from three perspectives: variable structure, variable parameters, and variable damping. Finally, simulation results verify that the proposed flexible compensation technology offers strong disturbance-rejection capability under a wide range of uncertainties in source-load-storage interactions, significantly improving DC bus voltage stability.

This work is supported by the Major Project of National Natural Science Foundation of China (No. U24B6011).

Key words: energy storage converter; active disturbance rejection control; deep reinforcement learning; information entropy; disturbance rejection performance

0 引言

发展新型电力系统是实现双碳目标的重要抓手,

基金项目: 国家自然科学基金重大项目资助(U24B6011); 国家自然科学基金重点项目资助(U23B20142)

而新型电力系统“双高”特征——高渗透率新能源、高占比电力电子设备带来不确定性共性挑战, 关乎新能源高水平利用^[1-5]。直流微网作为典型的新型电力系统, 源荷互动下新型电力系统的“低惯量、弱阻尼”特征使得母线电压极易受到波动, 危害系统安全稳定运行^[6-7]。

目前研究多运用储能技术平抑母线电压波动,不仅可以为系统提供惯量支撑,还能在多时空尺度上抑制能量不确定性带来的波动^[8-9]。热点研究趋势分为三方面,其一为在传统控制框架下溯源不确定性扰动,划分来源、时间尺度、恶劣程度等特性,并依据这些特性分层次建模,利用储能平抑母线电压波动。文献[10]为了解决新能源组网系统不确定性对母线电压质量的影响,溯源扰动发生源,并将线路电阻及储能荷电状态作为控制参数补偿到下垂控制中,提升母线电压支撑能力;文献[11]设计了一种改进型高阶滑模自抗扰控制,抑制双极性直流微电网中的母线电压波动。其二为依托数智技术^[12-13],以储能为核心构建能源互济系统^[14],通过通感一体、实时全联、云边协同的智能能源管控,以保障母线电压稳定^[15],文献[16]基于虚拟储能的多层能量管理及协同优化,从系统调度层面削弱了源-荷非计划性多尺度波动。其三为两者有机融合,在传统控制框架下利用数据驱动对储能技术关键环节进行智能解析与态势感知决策,大幅减小运算的算力,同时提升运维效率^[17]。文献[18]提出采用超松弛双Q学习算法,求解多区域储能系统的协同控制策略,解决分布式电网模式下由强扰动引起的频率失衡、控制性能标准变差问题;文献[19]提出一种结合神经网络技术的改进下垂控制方法,以实现公共直流母线电压的动态偏差最小。但鲜少有文献构建不确定性量化指标剖析二者融合的效果与机理。

本文针对上述问题,提出一种基于信息熵量化评价的深度强化学习储能微网柔性补偿自抗扰稳压策略(flexible compensation active disturbance rejection control strategy based on deep reinforcement learning, FC-ADRC)。在纯微分框架下重构储能变换器自抗扰控制,并引入柔性补偿环节实时适度抵消不确定性,从而稳定母线电压。运用信息熵指标量化新型电力系统的不确定性,以抑制系统不确定性为核心,设计强化学习的目标奖励函数,运用深度确定性策略梯度算法(deep deterministic policy gradient, DDPG)在线优化柔性补偿的控制规律。从“变结构、变参数、变阻尼”三方面挖掘柔性补偿的内涵,阐明运用人工智能方法解决电气工程科学问题的机理。仿真实验结果表明,FC-ADRC在不同工况下均具有良好的动、稳态特性。

1 直流微网储能变换器建模

图1为典型的直流微网结构图,其由风电、光伏、混合储能单元和负载组成。其中光伏由 Boost

电路与母线相连,风机经 AC-DC 整流电路与母线相连,储能单元经双向 DC-DC 变换器与母线构成能量双向流通回路。新能源的波动性、负荷的随机性引发电能供需失衡,易导致直流母线电压波动,需要配置储能单元,控制其充放电以平抑波动^[20]。

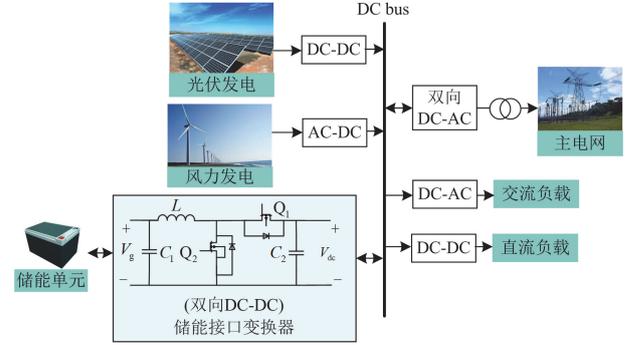


图1 直流微网结构

Fig. 1 DC microgrid structure

本文以储能接口变换器的控制为核心研究对象,旨在提升储能接口变换器的综合性能。采用成本低、可靠性高的隔离型双向 DC-DC 变换器作为储能接口变换器,通过控制 MOSFET 管 Q_1 、 Q_2 的导通与关断,利用储能元件进行能量交换。

图1中: V_g 为储能侧电压; V_{dc} 为直流母线电压; C_1 、 C_2 为滤波电容; L 为滤波电感; D 为占空比。选取电容电压 V_C 、电感电流 i_L 为状态变量。 T_s 表示单个周期,当MOSFET管 Q_1 处于导通和关断状态,分析状态变量的微分方程,并根据状态空间平均法,得到完整周期内的状态空间平均方程,后经小信号建模,可得电路工作在 Buck 模式时的传递函数,如式(1)所示。

$$\begin{cases} G_{id1} = \frac{i_L}{d} = \frac{V_g RC_1 s + V_g}{RLC_1 s^2 + Ls + R} \\ G_{vd1} = \frac{V_C}{d} = \frac{V_g R}{RLC_1 s^2 + Ls + R} \end{cases} \quad (1)$$

式中: s 为微分算子; d 为控制量; R 为负载阻值; G_{id1} 为 i_L 对 d 的传递函数; G_{vd1} 为 V_C 对 d 的传递函数。

同理可得 Boost 模式下,状态变量的传递函数 G_{id2} 和 G_{vd2} ,如式(2)所示。

$$\begin{cases} G_{id2} = \frac{i_L}{d} = \frac{V_g}{(1-D)} \cdot \frac{RC_2 s + 2}{RLC_2 s^2 + Ls + R(1-D)^2} \\ G_{vd2} = \frac{V_C}{d} = \frac{R(1-D)^2 - Ls}{(1-D)(RC_2 s + 2)} \end{cases} \quad (2)$$

2 扰动补偿下的自抗扰控制

在图1所示的能量流动过程中, 为改善母线电压稳定性, 通常会采用电压外环、电流内环的双闭环控制方式。被控对象不再如式(1)所示表现为一阶形式, 而变为高阶系统, 为简化设计可利用根轨迹法将高阶被控对象降为二阶系统, 状态方程和输出如式(3)所示。

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = f + bu \\ y = x_2 \end{cases} \quad (3)$$

式中: f 为总扰动, 包括一切对系统期望运动轨迹产生不良影响的因素, 包括建模不精确部分、新能源出力波动等^[21]; b 为控制器增益; x_1 、 x_2 为简化系统的状态变量; \dot{x}_1 、 \dot{x}_2 分别为 x_1 、 x_2 的微分; u 为控制器输出; y 为系统输出。

2.1 传统线性自抗扰局限性

假设总扰动 f 可微, 根据状态观测器理论将其扩展为新的状态变量 x_3 , 则 $\dot{f} = \dot{x}_3$, 式(3)可改写为

$$\dot{x} = Ax + Bu + B\dot{f} \quad (4)$$

式中: $x = [x_1, x_2, x_3]^T$; $B_1 = [0, b, 0]^T$; $B = [0, 0, 1]^T$;

$$A = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}.$$

传统线性扩展状态观测器(linear extended state observer, LESO)形式为

$$\dot{z}_e = Az_e + Bu + L_e e_e \quad (5)$$

式中: $z_e = [z_{e1}, z_{e2}, z_{e3}]^T$ 为三维状态估计量, 用于估计 x_1 、 x_2 、 x_3 ; e_e 为各维状态估计量与其所估计状态变量的误差; L_e 为观测器增益矩阵, 使系统赫尔维茨稳定。

$$e_e = \begin{bmatrix} e_{e1} \\ e_{e2} \\ e_{e3} \end{bmatrix} = \begin{bmatrix} x_1 - z_{e1} \\ x_2 - z_{e2} \\ x_3 - z_{e3} \end{bmatrix}; L_e = \begin{bmatrix} l_{e1} & 0 & 0 \\ l_{e2} & 0 & 0 \\ l_{e3} & 0 & 0 \end{bmatrix}$$

传统LESO观测收敛存在误差的原因为状态估计量不满足微分关系^[22], 导致出现误差积累效应, 如式(6)所示。

$$\begin{cases} \dot{z}_{e1} = z_{e2} \\ \dot{z}_{e2} = z_{e3} + b_0 u \end{cases} \quad (6)$$

式中: b_0 为控制增益。根据式(4)、式(5)可得, 误差 e_{e2} 为

$$e_{e2} = x_2 - z_{e2} = \dot{x}_1 - \dot{z}_{e1} + l_{e1} e_{e1} = \dot{e}_{e1} + l_{e1} e_{e1} \neq \dot{e}_{e1} \quad (7)$$

式中: l_{e1} 、 l_{e2} 为观测器增益。由式(7)可知, 误差 e_{e2}

并非 e_{e1} 的微分, 还包括 $l_{e1} e_{e1}$, 即使 e_{e1} 很小, 误差 e_{e3} 仍有高增益成分 $l_{e1} \dot{e}_{e1} + l_{e2} e_{e1}$ 。

$$e_{e3} = f - z_{e3} = (\dot{x}_2 - bu) - (\dot{z}_{e2} - bu - l_{e2} e_{e1}) = \dot{x}_2 - \dot{z}_{e2} + l_{e2} e_{e1} = \dot{e}_{e2} + l_{e2} e_{e1} = \ddot{e}_{e1} + l_{e1} \dot{e}_{e1} + l_{e2} e_{e1} \quad (8)$$

由式(8)可知, LESO对扰动的观测能力受扰动形式限制, 若构造出一个函数来补偿总扰动 f , 就可以等效地抵消误差方程, 从而降低干扰形式对LESO观测能力的限制。

2.2 扰动补偿自抗扰控制

为解决传统LESO非导形式造成的误差积累效应, 影响观测精度的问题, 文献[23]设计了纯微分形式的龙伯格观测器, 表示为

$$\begin{cases} \dot{z}_1 = z_2 \\ \dot{z}_2 = L_1 e_1 + L_2 e_2 + b_0 u \\ \hat{f} = \dot{z}_2 - b_0 u = L_1 e_1 + L_2 e_2 \end{cases} \quad (9)$$

式中: z_1 为 x_1 的估计值; z_2 为 x_2 的估计值; \hat{f} 为 f 的估计值; L_1 、 L_2 为观测器增益; e_1 、 e_2 为观测误差。

为了消除总扰动 f 对估计误差的影响, 在观测器中引入补偿函数 \tilde{f} , 表示为

$$\begin{cases} \dot{z}_1 = z_2 \\ \dot{z}_2 = L_1 e_1 + L_2 e_2 + \tilde{f} + b_0 u \\ \hat{f} = L_1 e_1 + L_2 e_2 + \tilde{f} \end{cases} \quad (10)$$

式(3)减去式(10)得到

$$\begin{cases} \dot{e}_1 = e_2 \\ \dot{e}_2 = -(L_1 e_1 + L_2 e_2) + (f - \tilde{f}) \end{cases} \quad (11)$$

如式(11)所示, 观测误差 e_1 、 e_2 随总扰动 f 和补偿函数 \tilde{f} 之差的减小而减小, 而 \hat{f} 是 f 的估计值, f 和 \hat{f} 需同时逼近 f 才可保证观测精度与收敛性, 故通过低通滤波器将扰动估计值 \hat{f} 与补偿函数 \tilde{f} 相连, 则补偿函数表示为式(12), 并将其定义为扩张状态量 z_3 。

$$z_3 = \tilde{f} = \frac{\lambda}{s + \lambda} \hat{f} \quad (12)$$

式中: λ 为补偿参数。结合式(10)、式(12), 扰动补偿观测器(compensation function observer, CFO)可表示为式(13)。

$$\begin{cases} \dot{z}_1 = z_2 \\ \dot{z}_2 = L_1 e_1 + L_2 e_2 + z_3 + b_0 u \\ \dot{z}_3 = \lambda(L_1 e_1 + L_2 e_2) \\ \hat{f} = L_1 e_1 + L_2 e_2 + z_3 \end{cases} \quad (13)$$

由式(13)可得 CFO 特征方程表示为

$$s^3 + L_1 s^2 + (\lambda L_1 + L_2) s + \lambda L_2 = 0 \quad (14)$$

根据式(5)、式(13)、式(14)及频域分析可知,扰动补偿自抗扰(compensation function observer-linear active disturbance rejection control, CFO-LADRC)抗扰能力比传统自抗扰(extended state observer-linear active disturbance rejection control, ESO-LADRC)更强; CFO-LADRC 通过增大 λ 来增强系统抗扰性能,且确保不会增加系统对高频噪声的敏感度,这是其性能优于 ESO-LADRC 的关键。

3 扰动柔性补偿下的自抗扰控制

3.1 信息熵量化评价

在源荷深度互动、变量耦合复杂的微网环境中,干扰补偿过程具有非线性、强时变、能量无序性特征,其对新型电力系统运行稳定性的影响不容忽视。以频域特性分析结果作为性能评价依据,难以全面评估补偿强度是否与不确定性干扰适配,可将结构固定、参数定常的 CFO-LADRC 理解为灵活性与抗扰性均受限制的“刚性”扰动补偿。

为全面提升系统稳态灵活性和暂态抗扰性,首先要量化全局不确定性,再寻找“柔性”补偿规律。

引入信息熵 H [24]定义不确定性评估指标,如式(15)所示。

$$H(p_1, \dots, p_n) = -\sum_{i=1}^n p_i \log_o(p_i) \quad (15)$$

式中: n 表示母线电压发生不同程度波动的可能事件数; p_i 表示第 i 种可能事件发生的概率; $-\log_o(p_i)$ 表示发生事件蕴含的信息量,且对数底 o 通常根据信息度量尺度选取; $H(p_1, \dots, p_n)$ 表示消除此事件的不确定性所需要的统计信息量,即微网系统的混乱程度。

关于可能事件机理,母线电压波动主要分为扰动型波动和振荡型波动两类,扰动型波动主要由负荷波动/投切、电源波动/投切引起,发生的主要原因是母线电压功率交互失衡造成能量不确定性,运用储能系统可有效平抑此类波动;振荡型波动主要由谐波交互、电网故障引起,往往具有长时特性。以扰动型波动为例,分别根据图 1 中局部变换器单向模型和双向模型、表 2 中参数和式(15)绘制系统的信息熵与扰动补偿参数关系 $H(\lambda)$, 如图 2 所示。

由图 2(a)可以看出,当微网不确定性出现在能量单向流动过程中,即不确定性交互较弱时,全局不确定性评估指标 H 的变化规律:当 λ 增大, H 变小,即补偿强度越大,系统混乱程度减弱、抗扰性能增强。由于单减函数反函数 $\lambda(H)$ 也具备单减性,可得到补偿参数 λ 的设计规律:系统混乱程度 H 减

小、抗扰性增强时, λ 增大。

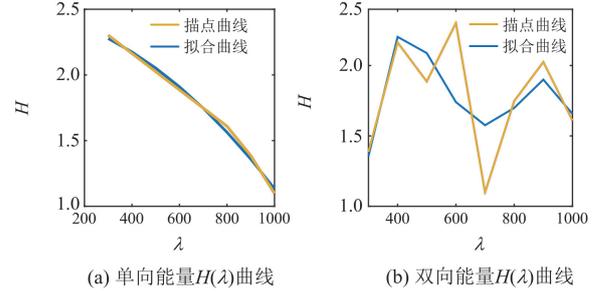


图 2 信息熵与扰动补偿关系示意图

Fig. 2 Schematic diagram of the relationship between information entropy and disturbance compensation

由图 2(b)可以看出,当微网不确定性发生于能量双向流通过程,即不确定性复杂交互时,如多种新能源叠加效果无法估计、极端天气难以预测、源荷深度互动等情况, $H(\lambda)$ 与 $\lambda(H)$ 不再具备单调性,而受复杂环境影响。

若探索兼顾不确定性量化评估与扰动补偿设计的双向动态规律,需以不确定性量化指标为优化目标,协同数据与模型联合驱动优化“柔性”补偿动态调整,实现无序系统的实时最优秩序重构。

3.2 深度确定性策略梯度算法下的柔性调整

ADRC 控制过程具有马尔可夫性,可描述为一个马尔可夫决策过程[25],且由于扰动补偿过程属于连续动作控制,可将深度确定性策略梯度算法(deep deterministic policy gradient, DDPG)融入 CFO-LADRC 框架:通过信息熵量化不确定性,并将其作为奖励指标来评估干扰补偿能力,以最小化不确定性为核心目标,通过调节干扰补偿强度来更新系统动作,从而在不确定性扰动补偿中提供最优柔性控制,平抑母线电压波动,FC-ADRC 控制方案如图 3 所示。

FC-ADRC 控制方案包括环境提取、数据存储、训练网络、输出动作 4 部分。具体为:提取环境状态空间,并将过渡数据保存至经验池,DDPG 智能体根据当前状态 s_t 基于策略网络 Actor Network(μ 网络)选择动作 a_t ,价值网络 Critic Network(Q 网络)通过最小化损失更新临界值,随后更新 Actor Network,环境根据输出动作得到下一状态 s_{t+1} ,并计算奖励值 r_t ,DDPG 智能体持续与微网环境交互直至最大化奖励收敛。此过程涉及两个重要变量和一个关键函数,即状态空间、动作空间、奖励函数。

图 3 中: L 表示损失函数; y_t 表示目标函数; s_t 表示 t 时刻状态; r_t 表示奖励值; θ^μ 、 θ^Q 表示当前网络权重参数; $Q(s_t, a_t | \theta^Q)$ 表示当前 Q 网络输出

的 Q 值; θ^r 、 θ^Q 表示目标网络权重系数。根据图 3 定义状态空间 s 、动作空间 a 。

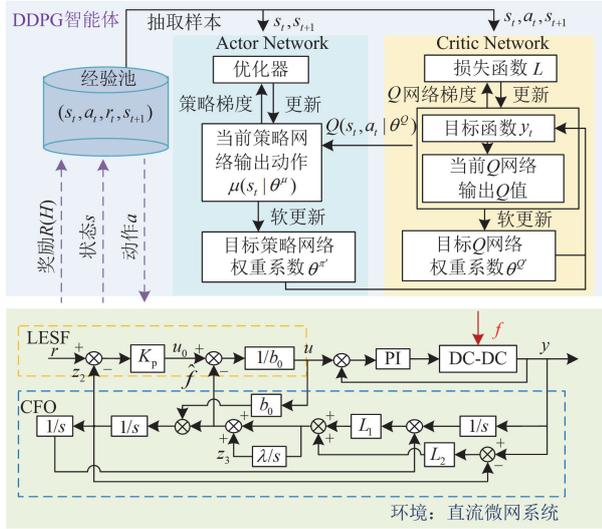


图 3 FC-ADRC 控制方案

Fig. 3 FC-ADRC control scheme

1) 状态空间 $s(e, e_2, y)$: 系统输出 y 与电压参考值 v 之间的误差 e ; 系统输出 y 与其估计值 z_2 之间的误差 e_2 ; 系统输出 y 。

2) 动作空间 a : 补偿参数 λ 。

3.3 深度强化学习奖励函数

奖励函数 R 为智能体计算的“目标”，也是算法的核心部分，根据式(15)的不确定性量化评估结果 H 及其变换形式来设计奖励函数。对于微网环境，为在最小化系统不确定性的同时，实现算力轻量化，离散奖励 r 表示为

$$r_1, r_2, \dots, r_n = -mH(p_1, \dots, p_n) = m \sum_{i=1}^n p_i \log_o(p_i) \quad (16)$$

式中: m 为伸缩变换尺度。

则奖励函数 R 表示为

$$R = \begin{cases} r_1, |e_2| < 0.5 \\ r', k < |e_2| < k' \\ r_n, |e_2| > 10 \end{cases} \quad (17)$$

式中: $k \sim k'$ 为观测误差波动分段, 包含 $n-2$ 个误差细分区间; r' 为波动区间奖励, 包含 r_2, \dots, r_{n-1} , 分别为 $k \sim k'$ 中细分误差区间 $k_1 \sim k_2, \dots, k_{n-2} \sim k_{n-1}$ 的对应奖励。设训练环境下新能源随机出力下观测误差在 0.5 以内的概率为 p_1 , 给予奖励 r_1 ; 在 $k \sim k'$ 之间的概率对应于误差细分区间为 p_2, \dots, p_{n-1} , 分别施加奖励 r_2, \dots, r_{n-1} ; 在 10 以上的概率为 p_n , 施加奖励 r_n 。综合式(16)、式(17)可知, 概率分布的稀疏性会增大奖励与惩罚的权重, 进而加快收敛速度。

系统柔性补偿越适度, 则奖励越大, 从而使控制策略最终收敛于最优补偿值。

3.4 奖励函数内涵

根据信息熵的性质, 剖析奖励函数内涵如下。

3.4.1 干扰预测特性

若 X 、 Y 表示随机变量, A 、 B 表示事件, 不同干扰源引起母线电压波动事件 $X=A$ 、 $Y=B$ 同时发生且相互独立, 则此时信息熵具有可加性, 表示为

$$\begin{cases} p(X=A, Y=B) = p(X=A) \cdot p(Y=B) \\ H(X, Y) = H(X) + H(Y) \end{cases} \quad (18)$$

式中: $p(X=A, Y=B)$ 表示事件 A 、 B 同时发生的概率; $H(X, Y)$ 表示事件 A 、 B 同时发生的信息熵; $p(X=A)$ 表示事件 A 发生的概率; $H(X)$ 表示事件 A 发生的信息熵; $p(Y=B)$ 表示事件 B 发生的概率; $H(Y)$ 表示事件 B 发生的信息熵。由式(18)可知, 解耦干扰源引起的信息熵是可加的, 在关注稳压目标的前提下, 可预测极端天气和在线复杂工况。同时奖励倍数仅代表施加奖励的力度、收敛的快慢, 不影响最终收敛结果, 所以适当改变奖励尺度的意义在于合理预测未知干扰源造成的非理想干扰。

3.4.2 跟踪特性

若事件 $X=A$, $Y=B$, 事件 B 并未发生, 则信息熵不会受到事件 B 影响。

$$\begin{cases} p(X=A, Y=B) = p(X=A) \cdot p(Y=B) \\ H(X, Y) = H(X) \end{cases} \quad (19)$$

由式(19)可知, 若实际工况下未受到不确定性干扰, 训练出的策略仍能保证跟踪性。同时干扰预测机制不会对训练结果产生负面影响。

此外, 观测误差波动分段 $k \sim k'$ 不仅可根据具体工况下母线电压波动允许区间进行调节, 配合储能电池恒流充电模式、混合储能协调要求, 还可按电流、功率、能量等状态波动进行分段设计, 具有良好的泛化能力。

3.4.3 解耦拓展特性

对于两个相互耦合的干扰源引起的母线电压波动事件 X 、 Y , 信息熵可表示为

$$H(X, Y) = H(X) + H(Y) - I(X, Y) \quad (20)$$

式中: $I(X, Y)$ 为互信息。

当多种状态变量深度耦合时, 若耦合关系已知, 可通过定义互信息解耦多维状态; 若耦合关系难以获取, 可通过互信息合理利用耦合, 从而应对动态谐波交互等引发的振荡型电压波动难题。

3.5 收敛性证明

算法和奖励共同决定着 FC-ADRC 的性能。算法收敛是保障复杂环境中母线电压稳定的关键, 其

分为两部分：首先证明压缩映射原理不动点存在且唯一，进而验证 DDPG 算法贝尔曼方程满足压缩映射原理。

3.5.1 压缩映射原理

定义：设 (W, q) 为距离空间， $T: W \rightarrow W$ 的映射，设存在一个变量 $\alpha \in (0, 1)$ ，使得式(21)成立。

$$q(T(x), T(y)) \leq \alpha q(x, y) \quad (21)$$

式中： $x, y, z \in W$ ； q 表示距离。

定理：压缩映射 T 必有唯一不动点。

$$\varepsilon = T(\varepsilon) \quad (22)$$

距离 q 满足三角公式，如式(23)所示。

$$q(x, z) \leq q(x, y) + q(y, z) \quad (23)$$

由式(24)证明存在性。

$$\begin{aligned} \forall x_0 \in W, x_{n+1} &= T(x_n) \\ q(x_{n+1}, x_n) &= q(T(x_n), T(x_{n-1})) \leq \alpha q(x_n, x_{n-1}) \\ \alpha q(T(x_{n-1}), T(x_{n-2})) &\leq \alpha^2 q(x_{n-1}, x_{n-2}) \leq \dots \leq \\ &\alpha^n q(x_1, x_0) \end{aligned} \quad (24)$$

若 $\{x_n\}$ 为柯西列，则 $\lim_{n \rightarrow \infty} x_n = \varepsilon$ 。

由柯西收敛定理，可得

$$\begin{aligned} q(x_{n+p}, x_n) &\leq q(x_{n+p}, x_{n+p-1}) + \dots + q(x_{n+1}, x_n) \leq \\ &(\alpha^{n+p-1} + \alpha^{n+p-2} + \dots + \alpha^n) \cdot q(x_1, x_0) \leq \\ &\alpha^n (1 - \alpha^p) / (1 - \alpha) \cdot q(x_1, x_0) \leq \\ &\alpha^n / (1 - \alpha) \cdot q(x_1, x_0) \end{aligned} \quad (25)$$

$$\lim_{n \rightarrow \infty} \left(\frac{\alpha^n}{1 - \alpha} \right) \cdot q(x_1, x_0) = 0 \quad (26)$$

根据夹逼定理可得

$$0 \leq q(x_{n+p}, x_n) \leq 0 \quad (27)$$

假设存在另一个不动点 ε' ，通过式(28)证明不动点的唯一性。

$$\begin{aligned} \exists \varepsilon' \neq \varepsilon, T(\varepsilon') &= \varepsilon' \\ 0 \leq q(\varepsilon', \varepsilon) &\leq \alpha \cdot q(\varepsilon', \varepsilon) \\ 0 \leq (1 - \alpha)q(\varepsilon', \varepsilon) &\leq 0 \\ \because \alpha \in (0, 1) \\ \therefore \varepsilon' &= \varepsilon \end{aligned} \quad (28)$$

3.5.2 证明 DDPG 贝尔曼方程满足压缩映射原理

在 DDPG 算法中，利用贝尔曼方程对任意策略的价值函数进行迭代更新与评估，如式(29)所示。

$$\begin{aligned} V_\pi^{j+1}(s) &= R_s^\pi + \gamma P_\pi V_\pi^j(s') \\ x_{j+1} &= T(x_j) \end{aligned} \quad (29)$$

式中： j 为迭代次数； π 为策略，表示 t 时刻由状态 θ^π 到动作 $\theta^{\pi'}$ 的映射； s' 表示环境交互后转移到的下一状态； R_s^π 为重复马尔可夫决策奖励； P_π 为按照策略行动时转移到下一状态的概率； γ 为折扣

因子； $V_\pi^{j+1}(s)$ 表示状态价值函数的贝尔曼方程。对于任意的 μ, ν 属于 W ，验证贝尔曼方程满足压缩映射原理，如式(30)所示。

$$\begin{aligned} \|T_\pi(\mu) - T_\pi(\nu)\| &= \|\gamma P_\pi \mu - \gamma P_\pi \nu\| = \\ &\gamma \|P_\pi(\mu - \nu)\| \leq \\ &\gamma \|P_\pi\| \cdot \|\mu - \nu\| \leq \\ &\gamma \|\mu - \nu\| \end{aligned} \quad (30)$$

策略持续更新迭代，直至找到最大 Q 值，从而确定最优策略 π^* ，最优贝尔曼方程 $Q_*^{j+1}(s, a)$ 如式(31)所示。

$$\begin{aligned} Q_*^{j+1}(s, a) &= \max Q_\pi(s, a) = \\ R_s^a + \gamma \sum_{s' \in S} P(s'|s, a) Q_*^j(s', a') \end{aligned} \quad (31)$$

式中： a' 表示下一时刻的动作。

根据图 3 和上述内容可知，价值网络通过梯度下降进行优化，策略网络通过梯度上升进行优化；交替学习 μ 函数和 Q 函数，如式(32)所示。

$$Q_*(s, a) = T(Q_\pi(s', a')) \quad (32)$$

式中： Q_* 为满足压缩映射原理的一个不动点，随着不断更新迭代， Q 将逐步收敛到 Q_* 。结合 3.2 节—3.4 节，母线电压波动将在收敛域内得到有效抑制。

4 柔性补偿原理剖析

从“变结构”、“变参数”、“变阻尼”3 方面剖析柔性补偿的机理，不仅能够说明其较传统控制方法的优越性，更有助于归纳运用数据驱动解决电气工程科学问题的共性规律。

4.1 变结构

区别于传统干扰补偿的定结构形式，具有预测特性的柔性补偿通过将不确定性评价指标作为定量优化目标，灵活调整补偿结构不断变化，寻找应对变化环境的最优动态补偿方式，从而实现对于能量不确定性的自趋优抑制，保障母线电压的稳定性，即变结构的核心为：应环境而变。

如图 1 和图 3 所示，柔性补偿将源荷深度互动下的总扰动 f 都划入了补偿范围，包括未知多尺度新能源波动、多类型负荷随机性和多能流耦合偏差等。

当新能源存在不确定性时，储能系统通过充放电抑制此类型能量不确定性，功率传输过程关系式为

$$P_m + P_v + \Delta P + P_b \equiv P_L \quad (33)$$

式中： P_m 为风机输出功率； P_v 为光伏输出功率； ΔP 为源侧/荷侧不确定性功率波动； P_b 为储能系统功率； P_L 为负荷功率。

当负荷侧存在不确定性时，储能系统通过充放电

抑制此类型能量不确定性, 功率传输过程关系式为

$$P_m + P_v \equiv P_L + \Delta P - P_b \quad (34)$$

4.2 变参数

区别于传统定常的补偿参数 λ , 柔性补偿参数是关于时间的函数 $\lambda(t)$, 其通过智能体非线性拟合得到, 如图 4 所示。具有时变特性的柔性补偿以不确定性减小为目标, 通过迭代计算来感知补偿需求, 进而动态调整参数, 最终实现干扰补偿强度的自适应整定, 即变参数的核心为: 应需求而变。

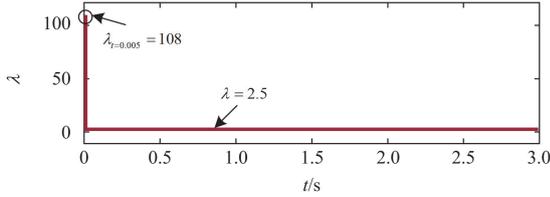


图 4 柔性补偿时变规律

Fig. 4 Flexible compensation of time-varying laws

如图 4 所示, 0.005 s 时为跟踪新能源最大出力, 柔性补偿参数增大为 108, 后恢复并稳定于 2.5。由图 4 可知, 当 FC-ADRC 和传统 CFO-LADRC 都观测到总扰动, 即扰动补偿过程结束时, 对比刚性补偿与柔性补偿, 绝对误差值积分值 $e_{FC,IAE} < e_{CFO,IAE}$, 如式(35)所示, 时变柔性补偿可提升系统的动、稳态性能。

$$\int_{t_1}^{t_n} |e_{FC}(t)| dt < \int_{t_1}^{t_n} |e_{CFO}(t)| dt \quad (35)$$

通过改变超参数、干扰时间与特性并进行多次重复训练以探索规律, 其收敛结果 $\lambda(t)$ 均表现出与图 4 相类似的规律性。故将不确定性量化评估作为智能体拟合目标, FC-ADRC 不会过度依赖于训练环境, 具有良好的在线工况拓展能力。

4.3 变阻尼

运用“第一性原理”溯源柔性补偿, 揭示“变结构”和“变参数”的内涵。通过阻抗分析法进行分析可得, FC-ADRC 控制作用等效为在储能变换器的输出滤波电容支路并联一个电阻, 并在滤波电感支路串联一个电阻, 如图 5 所示。

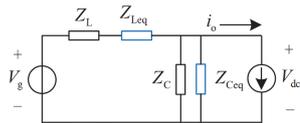


图 5 储能变换器等效电路

Fig. 5 Equivalent circuit of energy storage converter

图 5 中: Z_L 、 Z_C 分别为输出滤波电感支路和滤波电容支路的阻抗; V_g 为输入电压; V_g 与等效端

口电压干扰有关; i_o 为输出电流, i_o 与等效端口负载干扰有关; Z_{Leq} 为控制环路等效串联电阻; Z_{Ceq} 为控制环路等效并联电阻。母线电压 v_{dc} 可表示为

$$v_{dc} = \frac{Z_C // Z_{Ceq}}{Z_L + Z_C // Z_{Ceq}} V_g + \frac{(Z_C // Z_{Ceq}) Z_L}{Z_L + Z_C // Z_{Ceq}} i_o \quad (36)$$

式中: $Z_{Ceq} = (Z_L + J_i G_i G_{pwm}) / G_v G_i G_{pwm} J_v$; G_{pwm} 为 PWM 调制器等效函数; J_i 、 J_v 分别为内、外环采样系数; G_i 、 G_v 分别为内、外环控制器。

扰动补偿过程中, 内外扰均可等效为输入侧干扰或负载侧干扰, 根据式(36)可知, 通过对输出滤波电感与电容的电阻进行适时柔性调整, 改变系统阻尼, 从而有效削弱系统形变与振荡, 如式(37)所示。

$$\ddot{x} + L_1 \dot{x} + [L_1 \lambda(H) + L_2] \dot{x} + L_2 \lambda(H) x = 0 \quad (37)$$

式中: \ddot{x} 为 x 的三阶导数; \dot{x} 为 x 的二阶导数; \dot{x} 为 x 的一阶导数。“变阻尼”反映柔性补偿依据信息熵评估指标寻找效率更高的迭代模型, 逼近未知动态最优轨迹。

数据驱动下的柔性补偿是通过协同调整结构、参数与阻尼来实现的, “变结构”改变了态势感知与预测能力, 合理评估扰动补偿环境; “变参数”改变了抗扰决策与响应能力, 应需提供适度的干扰补偿; “变阻尼”是前两者的深度融合, 改变了动态寻优轨迹, 贯穿能量双向流动的始终。“三变”方法遵循的规则均为奖励中设计的核心原则: 最小化不确定性量化评估指标。

5 模型训练与算例分析

5.1 训练结果

直接使用神经网络、模糊逻辑等系统作为逼近器代替未知扰动时, 将面临模型设计复杂、训练收敛困难等问题^[26], 在量化全局不确定性的基础上, 利用数据驱动寻找柔性补偿规律可大大降低数学运算的复杂性, 有助于降低人工智能的滞后性^[27]。为应对数据更新时训练模型效果变差的问题, 通过引入多组微源、负荷及储能系统的内部干扰, 以模拟真实的源-荷-储互动不确定性工况。DDPG 算法相关参数如表 1 所示, 训练奖励变化曲线如图 6 所示。

由图 6 可以看出, 当训练次数达到 200 次时奖励曲线收敛, 累计奖励约为 -340, 能够使系统在复杂不确定性下, 仍将母线电压的波动控制在 $\pm 0.5\%$ 的误差带以内, 平抑母线电压波动。当微网环境变换时, FC-ADRC 由于具有预测性和泛化特性仍可实现柔性补偿, 维持母线电压稳定。

表 1 DDPG 算法关键参数

Table 1 Key parameters of DDPG algorithm

超参数	值
Actor Network 学习率	0.000 01
Actor Network 隐藏层神经元数	50、25
Critic Network 学习率	0.0001
Critic Network 隐藏层神经元数	25
单次样本容量	128
神经网络激活函数	ReLU
折扣因子 γ	0.97
经验池容量	1 000 000
噪声方差	0.3
噪声衰减系数	0.000 01

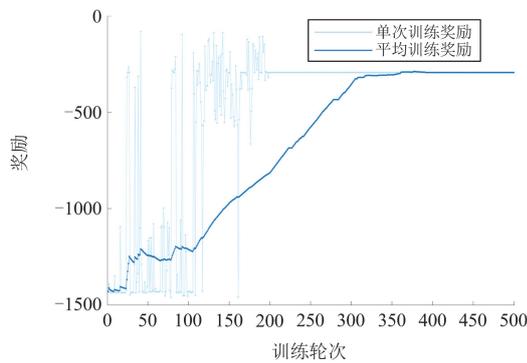


图 6 训练奖励变化曲线

Fig. 6 Training reward change curve

5.2 算例验证

为验证所提方法的有效性，在仿真平台搭建如图 1 所示的风光储联合直流微网模型，通过仿真分析系统运行时的工作状态。采用永磁直驱风机、光伏电池作为清洁型分布式发电单元；蓄电池作为储能系统，充放电控制方式采用电压电流双闭环控制策略。为了提高分布式电源的利用效率，使光伏和风电均工作于最大功率点，光伏阵列和永磁直驱式风力机分别采用扰动观测法和爬山搜索法作为最大功率跟踪算法。储能接口变换器元件参数如表 2 所示。储能接口变换器的控制方式为：双闭环 PI 控制、LADRC 控制和 FC-ADRC 控制，控制器参数如表 3 所示，其中内、外环 PI 控制参数由根轨迹法设计，由带宽法及文献[21]给出外环 LADRC 控制、FC-ADRC 控制的基础参数。为保证对比公平性，外环 PI、LADRC 控制参数近似满足文献[28]中的等效条件，LADRC、FC-ADRC 控制参数：比例控制增益 K_p 、控制增益 b_0 相同。

为测试源荷深度互动下母线电压的稳定性，考虑源-荷-储多端不确定性协同，分别对源侧新能源随机性干扰、荷侧负载波动干扰、储能变换器参数摄动干扰进行模拟，并对分析不同工况下系统的

动态性能。

表 2 储能接口变换器元件参数

Table 2 Interface converter component parameters

参数	取值
直流母线电压 V_{dc}/V	550
直流侧电容 $C_2/\mu F$	300
电感 L/mH	10
储能侧电容 $C_1/\mu F$	100
负载电阻 R/Ω	20

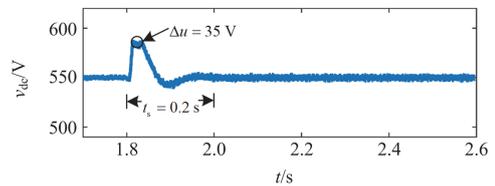
表 3 控制器参数

Table 3 Controller parameters

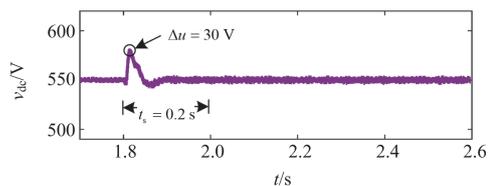
参数	取值
内环比例控制 K_{pi}	1
内环积分控制 K_{ii}	30
外环比例控制 K_{pv}	0.1
外环积分控制 K_{iv}	15
LADRC 带宽 ω_c	500 000
LADRC、FC-ADRC 比例控制增益 K_p	150
FC-ADRC 自然振荡角频率 ω_n	2500
FC-ADRC 阻尼 ξ	1
LADRC、FC-ADRC 控制增益 b_0	1 000 000

5.2.1 源侧不确定性干扰工况下的验证结果

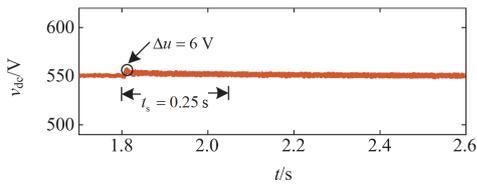
风速、光照强度波动在真实运维环境中频发，且其对母线电压的影响并非线性叠加，而是复杂非线性耦合，因此严重威胁母线电压稳定，分析此工况下直流母线电压波形具有重要意义。在 1.8 s 时模拟风、光联合波动，即风速由 10 m/s 上升至 14 m/s、光照强度由 1000 W/m^2 下降至 700 W/m^2 时的母线电压波形如图 7(a)~图 7(c) 所示，图中平稳、快速性能指标为：电压最大变化量 Δu 、恢复至 $\pm 0.5\%$ 波动范围内的调节时间 t_s 。风机、光伏电池、储能、负载功率波形如图 7(d) 所示。



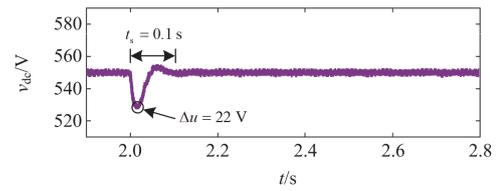
(a) PI控制母线电压



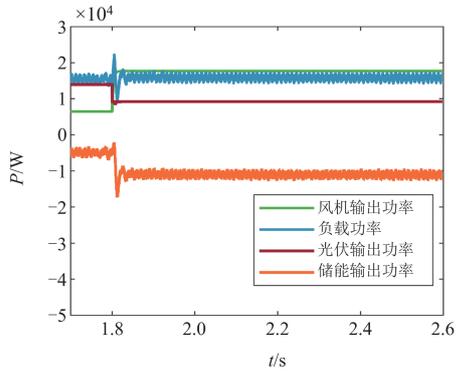
(b) LADRC控制母线电压



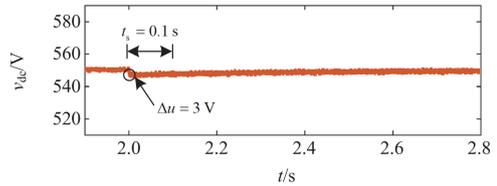
(c) FC-ADRC控制母线电压



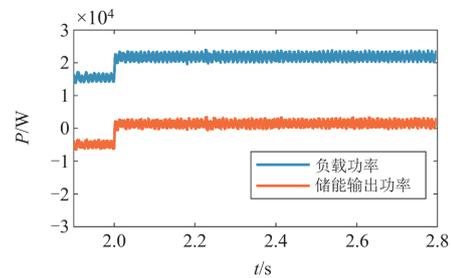
(b) LADRC控制母线电压



(d) FC-ADRC控制传输功率



(c) FC-ADRC控制母线电压



(d) FC-ADRC控制传输功率

图 7 风光干扰时输出波形

Fig. 7 Output waveform during wind and solar interference

由图 7(a)—图 7(c)可知,在平稳性上,FC-ADRC 相较于 PI 与 LADRC 控制,其最大电压变化量分别降低了 82.9%与 80%,性能提升显著。在快速性上,三者性能接近,均可在 0.3 s 内使电压达到目标值。

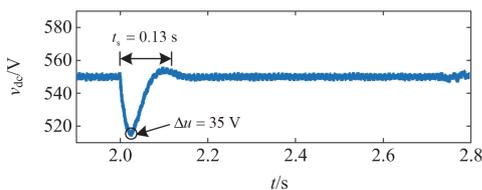
由图 7(d)可得,风机的输出功率由 6440 W 变化为 17 670 W,光伏电池的输出功率由 13 950 W 变化为 9200 W,储能输出功率也由 -5000 W 变化为 -11 480 W,始终为充电状态,使得负荷功率保持为 15 390 W,系统功率达到平衡状态。

5.2.2 荷侧不确定性干扰工况下的验证结果

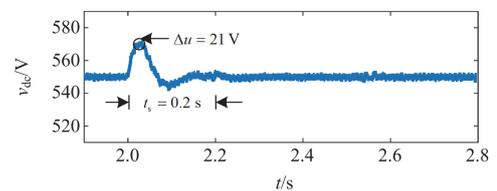
1) 负载减小

在 2 s 时模拟负载由 20 Ω 减小至 14 Ω 的条件下,母线电压波形如图 8(a)—图 8(c)所示;储能、负载功率波形如图 8(d)所示。

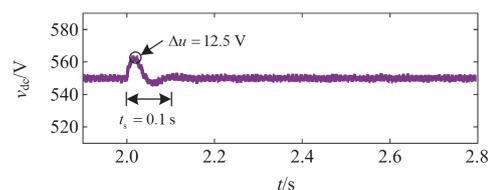
由图 8(a)—图 8(c)可知,在平稳性方面,FC-ADRC 相较于 PI 与 LADRC 控制,最大电压变化量分别降低了 91.4%与 86.4%,改善效果显著。在快速性方面,FC-ADRC 与 LADRC 响应速度相当,但较 PI 控制提升了 23.1%。



(a) PI控制母线电压



(a) PI控制母线电压



(b) LADRC控制母线电压

图 8 减载干扰时输出波形

Fig. 8 Output waveform during load shedding interference

风机的输出功率为 6440 W,光伏输出功率为 13 950 W,由图 8(d)可以看出,当负载的输出功率由 15 390 W 变化为 21 890 W 时,储能输出功率也由 -5000 W 变化为 1500 W,从充电状态转换为放电状态,系统功率达到平衡状态。

2) 负载增大

在 2 s 时模拟负载由 20 Ω 增大至 26 Ω 的条件下,母线电压波形如图 9(a)—图 9(c)所示;储能、负载功率波形如图 9(d)所示。

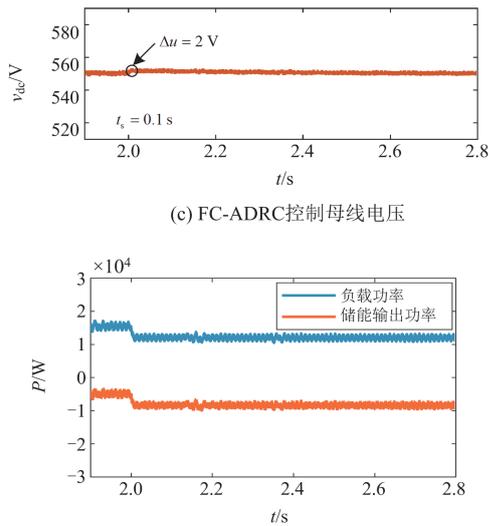


图9 增载干扰时输出波形

Fig. 9 Output waveform of load-increasing interference

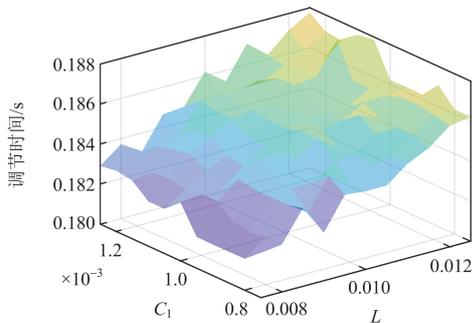
由图9(a)一图9(c)可知，在平稳性方面，FC-ADRC相较于PI与LADRC控制，最大电压变化量分别降低了90.5%与84%；在快速性方面也实现显著提升。

风机的输出功率为 6440 W，光伏输出功率为 13 950 W，由图 9(d)可以看出，当负载的输出功率由 15 390 W 变化为 12 000 W 时，储能输出功率也会相应改变，由-5000 W 变化为-8390 W，为充电状态，系统功率达到平衡状态。

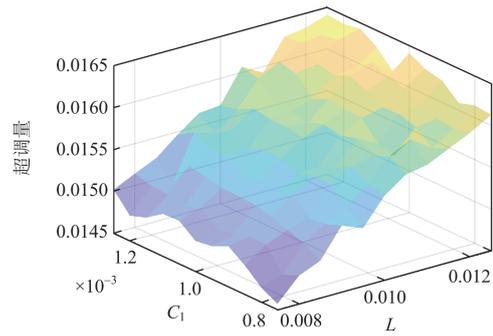
5.2.3 储能变换器不确定性干扰工况的验证结果

考虑到运维场景中，器件老化将导致储能变换器电感 L 、电容 C_1 参数产生误差。为验证 FC-ADRC 的鲁棒性，在电感 L 、电容 C_1 发生摄动工况下，对系统进行动态性能校验，电感 L 、电容 C_1 摄动范围为 $\pm 25\%$ ，电感 L 、电容 C_1 摄动工况下的动态性能如图 10 所示。

对图 10 进行分析，母线电压调节时间随电感 L 、电容 C_1 摄动波动范围较小，均保持在 0.185 s



(a) 参数摄动下的调节时间



(b) 参数摄动下的超调量

图 10 参数摄动工况下动态性能分析

Fig. 10 Dynamic performance analysis under parameter perturbation conditions

左右；同时超调量随电感 L 摄动而略有增大，浮动 1.6% 左右。综上，FC-ADRC 对储能变换器参数摄动具有良好的抑制性能与鲁棒性。

5.2.4 源-荷-储多端干扰不确定性综合量化评价

根据上述不同干扰下的数据结果，对 PI、LADRC、FC-ADRC 控制方式下的系统不确定性进行信息熵量化评估，以此验证不同控制策略在未知干扰下对直流微电网多端协同的调控性能。选取 1% 为误差尺度判定母线电压波动事件发生概率，根据式(15)可得综合量化评估结果： $H_{PI} = 1.4$ 、 $H_{LADRC} = 1.6$ 、 $H_{FC-ADRC} = 0.67$ 。由于引入柔性补偿，FC-ADRC 控制下系统的不确定性较小，对于复杂环境的适应能力较好。

6 结论

为提高新型电力系统直流母线电压的稳定性，本文将自抗扰控制与强化学习深度融合，提出了一种基于信息熵量化评价的深度强化学习储能微网柔性补偿自抗扰稳压方法。通过仿真实验验证了所提方法的有效性与可行性，得到以下结论。

1) 本文控制方法在多种常见工况下，可以提高直流母线电压的稳定性。同时，对源-荷-储多端互动不确定性表现出良好的抗干扰能力。

2) 本研究运用信息熵量化不确定性，并以其最小化为目标设计强化学习奖励，从而优化柔性补偿规则。通过证明算法收敛于最优奖励，揭示了全局不确定性量化与柔性补偿设计之间协同作用的规律。

3) 储能柔性技术是解决新型电力系统不确定性共性挑战的关键，其核心可归纳为“变结构、变参数、变阻尼”三变高度统一，即能量无序系统的有序化。

由于本文提出的 FC-ADRC 具有预测性、拓展

性、自适应性, 相较于传统控制方法更适用于强耦合、强时变、高不确定性的新型电力系统, 期望本研究可为电气工程、人工智能和控制理论的交叉融合提供有益参考。

参考文献

- [1] 王智伟, 张振宇, 李征, 等. 提升高渗透率新能源电网承载能力的 DSSC 优化配置[J]. 电力系统保护与控制, 2023, 51(6): 179-187.
WANG Zhiwei, ZHANG Zhenyu, LI Zheng, et al. Optimized DSSC configuration to enhance load-carrying capacity of the new energy grid with high permeability[J]. Power System Protection and Control, 2023, 51(6): 179-187.
- [2] 王佳, 吴任博, 肖健, 等. 新型电力系统能源调度与碳排放计价优化方法研究[J]. 电测与仪表, 2024, 61(10): 17-25.
WANG Jia, WU Renbo, XIAO Jian, et al. Research on the optimization method of energy dispatching and carbon emission pricing for novel power system[J]. Electrical Measurement & Instrumentation, 2024, 61(10): 17-25.
- [3] 樊玮, 易杨, 张军, 等. 基于区间法的一种新型电力系统动态无功电压控制[J]. 电网与清洁能源, 2024, 40(12): 54-64.
FAN Wei, YI Yang, ZHANG Jun, et al. A new type of dynamic reactive power and voltage control of new power systems based on interval method[J]. Power System and Clean Energy, 2024, 40(12): 54-64.
- [4] 郑婉婷, 赵倩宇, 王璇, 等. 绿证-碳交易机制下新型电力系统电-氢-气混合储能容量优化配置方法[J]. 供用电, 2024, 41(3): 24-31, 41.
ZHENG Wanting, ZHAO Qianyu, WANG Xuan, et al. Optimization configuration method for hybrid energy storage capacity of electricity-hydrogen-gas for new power system under the green certificate carbon trading mechanism[J]. Distribution & Utilization, 2024, 41(3): 24-31, 41.
- [5] 孙秋野, 李大双, 王睿, 等. “双高”电力系统: 一种新的稳定判据和稳定性分类探讨[J]. 中国电机工程学报, 2024, 44(8): 3016-3036.
SUN Qiuye, LI Dashi, WANG Rui, et al. Power system with high shares of renewables and power electronics: a new stability criterion and classification[J]. Proceedings of the CSEE, 2024, 44(8): 3016-3036.
- [6] 郝文斌, 孟志高, 张勇, 等. 新型电力系统下多分布式电源接入配电网承载力评估方法研究[J]. 电力系统保护与控制, 2023, 51(14): 23-33.
HAO Wenbin, MENG Zhigao, ZHANG Yong, et al. Carrying capacity evaluation of multiple distributed power supply access to the distribution network with the background of a new power system[J]. Power System Protection and Control, 2023, 51(14): 23-33.
- [7] 郝元钊, 吴豫, 苗福丰, 等. 基于不动点映射的多微网与配电网主从博弈定价策略及均衡求解方法[J]. 电测与仪表, 2023, 60(11): 37-44.
HAO Yuanzhao, WU Yu, MIAO Fufeng, et al. Fixed point mapping-based master-slave game pricing strategy and equilibrium solution method for distribution networks with multi-microgrids[J]. Electrical Measurement & Instrumentation, 2023, 60(11): 37-44.
- [8] 谢小荣, 马宁嘉, 刘威, 等. 新型电力系统中储能应用功能的综述与展望[J]. 中国电机工程学报, 2023, 43(1): 158-169.
XIE Xiaorong, MA Ningjia, LIU Wei, et al. Functions of energy storage in renewable energy dominated power systems: review and prospect[J]. Proceedings of the CSEE, 2023, 43(1): 158-169.
- [9] 刘伟, 夏敏学, 梁晨鹏. 高压直挂大容量电池储能系统实时仿真及控制研究[J]. 电力系统保护与控制, 2024, 52(14): 154-166.
LIU Wei, XIA Minxue, LIANG Chenpeng. Real-time simulation and control of a large capacity battery energy storage system directly connecting to a high-voltage grid without a transformer[J]. Power System Protection and Control, 2024, 52(14): 154-166.
- [10] 曾国辉, 朱相臣, 曾志伟, 等. 具有公共低压直流母线电压支撑功能的储能单元 SOC 自动均衡控制策略[J]. 中国电机工程学报, 2022, 42(19): 7160-7170.
ZENG Guohui, ZHU Xiangchen, ZENG Zhiwei, et al. Energy storage unit state-of-charge automatic equalization control strategy with common LVDC bus voltage support function[J]. Proceedings of the CSEE, 2022, 42(19): 7160-7170.
- [11] 陈旭, 皇金锋, 李聪林. 双极性直流微电网的改进型高阶滑模自抗扰控制[J]. 电力系统保护与控制, 2024, 52(9): 111-122.
CHEN Xu, HUANG Jinfeng, LI Conglin. Improved high-order sliding mode active disturbance rejection control for bipolar DC microgrids[J]. Power System Protection and Control, 2024, 52(9): 111-122.
- [12] YANG Nan, HAO Juncong, LI Zhengmao, et al. Data-driven decision-making for SCUC: an improved deep learning approach based on sample coding and seq2seq technique[J]. Protection and Control of Modern Power Systems, 2025, 10(2): 13-24.
- [13] 李高扬, 王宁, 高若田, 等. 面向新型电力系统智能化提效的多源异构数据融合技术研究[J]. 电测与仪表, 2024, 61(11): 116-121.
LI Gaoyang, WANG Ning, GAO Ruotian, et al. Research on multi-source heterogeneous data integration technology for smart efficiency improvement in novel power system[J]. Electrical Measurement & Instrumentation, 2024, 61(11):

- 116-121.
- [14] LIU Dan, YANG Qufan, CHEN Yin, et al. Optimal parameters and placement of hybrid energy storage systems for frequency stability improvement[J]. Protection and Control of Modern Power Systems, 2025, 10(2): 40-53.
- [15] 王新迎, 闫冬, 施展, 等. 机器学习赋能的优化算法及其在新型电力系统中的应用与展望[J]. 中国电机工程学报, 2024, 44(16): 6367-6385.
WANG Xinying, YAN Dong, SHI Zhan, et al. Machine learning empowered optimization algorithms and their applications and prospects in new type power system[J]. Proceedings of the CSEE, 2024, 44(16): 6367-6385.
- [16] 张祥宇, 舒一楠, 付媛. 基于虚拟储能的直流微电网源荷储多时间尺度能量优化与分区协调控制[J]. 电工技术学报, 2022, 37(23): 6011-6024.
ZHANG Xiangyu, SHU Yinan, FU Yuan. Multi-time-scale energy optimization and zone coordinated control of DC microgrid source-load-storage based on virtual energy storage[J]. Transactions of China Electrotechnical Society, 2022, 37(23): 6011-6024.
- [17] 孟飞, 曲骅, 郭添亨, 等. 直流微电网的惯性与阻尼自适应协调控制[J]. 电力系统保护与控制, 2022, 50(20): 149-157.
MENG Fei, QU Hua, GUO Tianheng, et al. Adaptive coordinated control of inertia and damping for DC microgrid[J]. Power System Protection and Control, 2022, 50(20): 149-157.
- [18] 周博奇, 柳丹, 席磊, 等. 基于超松弛双 Q 学习的源荷储协同频率稳定算法研究[J]. 中国电机工程学报, 2024, 44(4): 1419-1430.
ZHOU Boqi, LIU Dan, XI Lei, et al. Research on source load storage cooperative frequency stabilization algorithm based on super relaxed double Q learning[J]. Proceedings of the CSEE, 2024, 44(4): 1419-1430.
- [19] 郭睿恒, 黄文焘, 余墨多, 等. 独立直流微电网电压动态轨迹神经网络优化控制策略[J]. 中国电机工程学报, 2024, 44(16): 6404-6416.
GUO Ruiheng, HUANG Wentao, YU Moduo, et al. Neural network optimal control strategy for voltage dynamic track of islanding DC microgrid[J]. Proceedings of the CSEE, 2024, 44(16): 6404-6416.
- [20] 张继红, 赵锐, 高雷, 等. 直流微网母线电压稳定控制策略[J]. 电网技术, 2021, 45(12): 4922-4929.
ZHANG Jihong, ZHAO Rui, GAO Lei, et al. DC bus voltage stability control strategy for DC microgrid[J]. Power System Technology, 2021, 45(12): 4922-4929.
- [21] 李云丰, 贺之渊, 庞辉, 等. 柔性直流输电系统高频稳定性分析及抑制策略(一): 稳定性分析[J]. 中国电机工程学报, 2021, 41(17): 5842-5856.
LI Yunfeng, HE Zhiyuan, PANG Hui, et al. High frequency stability analysis and suppression strategy of MMC-HVDC systems (part I): stability analysis[J]. Proceedings of the CSEE, 2021, 41(17): 5842-5856.
- [22] QI G, LI X, CHEN Z. Problems of extended state observer and proposal of compensation function observer for unknown model and application in UAV[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2022, 52(5): 2899-2910.
- [23] WANG C, YAN J, HENG P, et al. Enhanced LADRC for permanent magnet synchronous motor with compensation function observer[J]. IEEE Journal of Emerging and Selected Topics in Power Electronics, 2023, 11(3): 3424-3434.
- [24] MIQUEL P, DANIEL P. Palomar. Hessian and concavity of mutual information, differential entropy, and entropy power in linear vector Gaussian channels[J]. IEEE Transactions on Information Theory, 2009, 55(8): 3613-3628.
- [25] 王尧, 罗俊仁, 周棧忠, 等. 面向策略探索的强化学习与进化计算方法综述[J]. 计算机科学, 2024, 51(3): 183-197.
WANG Yao, LUO Junren, ZHOU Yanzhong, et al. Review of reinforcement learning and evolutionary computation methods for strategy exploration[J]. Computer Science, 2024, 51(3): 183-197.
- [26] KIRAN B R, SOBH I, TALPAERT V, et al. Deep reinforcement learning for autonomous driving: a survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 23(5): 408-422.
- [27] SUN Y, CAI Z, GUO C, et al. Collaborative dynamic task allocation with demand response in cloud-assisted multi-edge system for smart grids[J]. IEEE Internet of Things Journal, 2022, 9(4): 3112-3124.
- [28] 陈宗祥, 张武林, 陈克难, 等. 二自由度自抗扰控制的整定方法[J]. 安徽工业大学学报(自然科学版), 2021, 38(3): 297-304.
CHEN Zongxiang, ZHANG Wulin, CHEN Kenan, et al. Tuning method of 2-DOF active disturbance rejection control[J]. Journal of Anhui University of Technology (Natural Science), 2021, 38(3): 297-304.

收稿日期: 2025-02-23; 修回日期: 2025-05-21

作者简介:

周雪松(1964—), 男, 博士, 教授, 研究方向为电力系统的先进控制技术; E-mail: zxsmyj@126.com

王馨悦(1999—), 女, 博士研究生, 研究方向为新能源利用与储能柔性技术; E-mail: yueb333@163.com

马幼捷(1964—), 女, 通信作者, 博士, 教授, 研究方向为新能源发电系统的并网运行与控制

(编辑 许威)