

基于改进近端策略优化算法的双馈风电场站 无功裕度优化研究

余达¹, 武志韬², 陈子文³, 林旭¹, 王巍桦¹, 刘崇茹^{2*}

(1. 广东电网有限责任公司电力调度控制中心, 广东省 广州市 510030; 2. 新能源电力系统
国家重点实验室(华北电力大学), 北京市 昌平区 102206; 3. 中国长江三峡集团有限公司,
湖北省 武汉市 430010)

Research on Reactive Power Margin Optimization of Doubly-Fed Induction Generator Wind Farms Based on Improved Proximal Policy Optimization Algorithm

YU Da¹, WU Zhitao², CHEN Ziwen³, LIN Xu¹, WANG Weihua¹, LIU Chongru^{2*}

(1. Electric Power Dispatching and Control Center, Guangdong Power Grid Co., Ltd., Guangzhou 510030, Guangdong Province, China; 2. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources (North China Electric Power University), Changping District, Beijing 102206, China; 3. China Three Gorges Corporation, Wuhan 430010, Hubei Province, China)

摘要:【目的】为了在平抑双馈风电场站并网点电压波动的同时提高其无功裕度, 增强其暂态电压支撑能力, 提出一种基于改进近端策略优化算法的双馈风电场站无功裕度优化方法。【方法】以双馈风电机组和静止无功发生器为主要无功调节设备, 建立双馈风电场站无功裕度优化数学模型, 并将其转化为马尔可夫决策过程模型; 针对原始的近端策略优化算法中裁剪系数设置不当, 导致难以平衡智能体探索和利用行为的问题, 提出了一种基于变裁剪系数的近端策略优化算法。基于改进的IEEE 39节点系统, 验证了所提算法的正确性和有效性。【结果】所提算法可以提高智能体的收敛速度, 且在决策速度和无功裕度优化效果上优于原始的近端策略优化算法和启发式算法。【结论】该算法有效提升了双馈风电场站的无功裕度, 增强了其在暂态下的电压支撑能力, 能更好地解决考虑源荷不确定性的电力系统无功优化问题。

关键词: 双馈风电场站; 无功裕度优化; 深度强化学习; 近端策略优化; 裁剪系数

ABSTRACT: [Objectives] To mitigate voltage fluctuations at the grid-connected points of doubly-fed induction generator

wind farms while enhancing their reactive power margin, thereby strengthening their transient voltage support capability, a reactive power margin optimization method based on an improved proximal policy optimization algorithm is proposed for doubly-fed induction generator wind farms. [Methods] Taking doubly-fed induction generator wind turbines and static var generators as the main reactive power regulation equipment, a mathematical model for reactive power margin optimization of a doubly-fed induction generator wind farm is established and transformed into a Markov decision process model. Addressing the issue of improper setting of the clipping coefficient in the original proximal policy optimization algorithm, which makes it difficult to balance the exploration and exploitation behaviors of the agent, a proximal policy optimization algorithm based on a variable clipping coefficient is proposed. Based on the improved IEEE-39 node system, the correctness and effectiveness of the proposed algorithm are verified. [Results] The proposed algorithm can improve the convergence speed of agents, and is superior to traditional proximal policy optimization algorithms and heuristic algorithms in terms of decision speed and reactive power margin optimization. [Conclusions] The proposed algorithm effectively improves the reactive power margin of doubly-fed induction generator wind farms, enhances their voltage support capability under transient conditions, and is of great significance for better solving

基金项目: 国家自然科学基金项目(U23B6008); 南方电网公司科技项目(GDKJXM20220335)。

Project Supported by National Natural Science Foundation of China (U23B6008); Science and Technology Project of China Southern Power Grid Co., Ltd. (GDKJXM20220335).

reactive power optimization problems in power systems with uncertain sources and loads.

KEY WORDS: doubly-fed induction generator wind farm; reactive power margin optimization; deep reinforcement learning; proximal policy optimization; clipping coefficient

0 引言

构建新能源占比逐渐提高的新型电力系统是实现“双碳”目标的必由之路,风能作为一种清洁、可再生的能源,近年来受到了国内外学者的广泛关注^[1-7]。高比例风电的接入给电力系统的运行带来了显著的双面效应,一方面,风电机组具有随机性、间歇性和波动性的特点,发电侧与负荷侧的双重不确定性给电网的无功电压问题带来了新的挑战^[8-9];另一方面,风电机组又具有一定的无功源特性,可在电网发生故障后支撑电网电压,有助于风电机组及其接入系统的安全稳定运行^[10-12]。因此,如何在平抑风电场站并网点电压波动的同时提高风电场站的无功裕度是亟待解决的问题。

文献[13]从提升风机无功裕度出发,提出一种基于粒子群算法的双馈异步风力发电机(doubly-fed induction generator, DFIG)和静止无功补偿器(static var compensator, SVC)协调控制策略;文献[14]以降低电压偏差和提升风场无功裕度为目标函数,构建了DFIG风场无功电压优化的数学模型,并采用基于粒子群优化算法的退火罚函数算法进行求解;文献[15]分析了DFIG风场的无功电压特性,提出了一种基于遗传算法的风场无功电压控制方法。上述文献均采用启发式算法求解优化问题,然而,启发式算法通常决策速度较慢,且容易陷入局部最优解,在面对考虑源荷双侧不确定性的风场无功优化问题时难以发挥很好的作用。

随着人工智能技术的快速发展,深度强化学习(deep reinforcement learning, DRL)方法为解决复杂的优化问题提供了新的思路^[16-21]。文献[22]提出了一种考虑安全性的馈线-台区电压协同控制策略,并采用深度Q网络算法(deep Q network, DQN)求解,然而,DQN只能解决离散动作空间

的问题,无法处理连续的动作空间;文献[23]考虑新型电力系统下的源荷不确定性,提出一种基于深度确定性策略梯度(deep deterministic policy gradient, DDPG)算法的无功电压优化方法,DDPG虽然可以解决连续动作空间的问题,但其软更新的机制可能导致目标网络与当前网络之间的差异过大,影响智能体的学习效果;文献[24]采用近端策略优化(proximal policy optimization, PPO)算法求解无功优化问题,并通过设计考虑约束-目标划分和目标预设的奖励函数来提升智能体性能,然而,不当的超参数设置可能导致PPO的性能不佳。

综上所述,为了在解决风电场站并网点电压波动问题的同时提高风电场站的无功裕度,本文以DFIG和静止无功发生器(static var generator, SVG)为主要的无功调节设备,针对原始PPO算法中采用固定裁剪系数难以平衡探索和利用的问题,提出一种基于改进PPO算法的风电场站无功裕度优化方法,并通过改进的IEEE 39节点系统仿真验证所提算法的正确性和有效性。

1 DFIG风电场站无功裕度优化模型

1.1 数学模型

DFIG是目前风力发电的主流机型,其定子侧直接连接电网,转子侧通过励磁变换器进行交流励磁,电磁功率通过定子侧、网侧换流器双通道与电网进行交换,可实现对输出有功功率、无功功率的独立解耦控制^[25]。

为提升DFIG风电场站的无功裕度,首先分析DFIG风电机组的无功极限,包括定子侧无功极限和网侧换流器无功极限^[26-27]。

DFIG定子侧无功极限为

$$\begin{cases} Q_{s,\max} = -\frac{3U_s^2}{2X_s} + \sqrt{\left(\frac{3}{2}\frac{X_m}{X_s}U_sI_{r,\max}\right)^2 - P_s^2} \\ Q_{s,\min} = -\frac{3U_s^2}{2X_s} - \sqrt{\left(\frac{3}{2}\frac{X_m}{X_s}U_sI_{r,\max}\right)^2 - P_s^2} \end{cases} \quad (1)$$

式中: $Q_{s,\max}$ 、 $Q_{s,\min}$ 分别为DFIG定子侧无功功率的最大值和最小值; U_s 为定子电压; $I_{r,\max}$ 为转子最大电流; X_s 、 X_m 分别为定子电抗和励磁电抗; P_s 为定子侧输出有功功率。

DFIG网侧换流器无功极限为

$$\begin{cases} Q_{g,\max} = \sqrt{S_g^2 - (sP_s)^2} \\ Q_{g,\min} = -\sqrt{S_g^2 - (sP_s)^2} \end{cases} \quad (2)$$

式中： $Q_{g,\max}$ 、 $Q_{g,\min}$ 分别为DFIG网侧换流器输出无功功率的最大值和最小值； S_g 为网侧换流器容量； s 为转差率。

风电场站通常会配置一定容量的无功补偿设备，典型电网动态无功补偿设备包括电容器组、调相机、SVC、SVG等，本文通过在稳态时调节无功资源的静态工作点来提高风电场站的无功裕度，进而增强其暂态电压支撑能力，因此，选择响应速度较快的SVG为主要的无功补偿设备。

我国陆上风电并网导则要求风电场站充分利用风电机组的无功容量及其调节能力^[28]，此外，考虑到DFIG的动态无功响应约为60 ms，而SVG的动态无功响应约为20 ms，为此，在稳态时优先利用DFIG进行无功调节，从而预留出快速的无功调节资源在暂态时支撑电网电压。

考虑无功响应速度的不同，分别定义DFIG和SVG的无功裕度如下式所示：

$$K_{\text{wtg}} = \begin{cases} \frac{Q_{s,\max} + Q_{g,\max} - Q_{\text{wtg}}}{Q_{s,\max} + Q_{g,\max}}, & Q_{\text{wtg}} \geq 0 \\ \frac{Q_{s,\min} + Q_{g,\min} - Q_{\text{wtg}}}{Q_{s,\min} + Q_{g,\min}}, & Q_{\text{wtg}} < 0 \end{cases} \quad (3)$$

$$K_{\text{svg}} = \begin{cases} \frac{Q_{\text{svg},\max} - Q_{\text{svg}}}{Q_{\text{svg},\max}}, & Q_{\text{svg}} \geq 0 \\ \frac{Q_{\text{svg},\min} - Q_{\text{svg}}}{Q_{\text{svg},\min}}, & Q_{\text{svg}} < 0 \end{cases} \quad (4)$$

式中： K_{wtg} 为DFIG无功裕度； Q_{wtg} 为DFIG实际发出的无功功率； K_{svg} 为SVG无功裕度； $Q_{\text{svg},\max}$ 、 $Q_{\text{svg},\min}$ 分别为SVG无功容量的最大值与最小值； Q_{svg} 为SVG实际发出的无功功率。

结合以上分析，建立DFIG风电场站无功裕度优化的数学模型，其优化目标为关键节点的电压偏差最小以及DFIG风电场站无功裕度最大，计算公式如下：

$$\min F_1 = \sum_{i=1}^n (U_{ci} - U_{ci,\text{ref}})^2 \quad (5)$$

$$\min F_2 = \sum_{j=1}^m \left(\frac{1}{K_{j,\text{wtg}}} \right)^2 + \sum_{k=1}^p \left(\frac{1}{K_{k,\text{svg}}} \right)^2 \quad (6)$$

式中： F_1 、 F_2 分别为节点电压和无功裕度的目标函数； U_{ci} 、 $U_{ci,\text{ref}}$ 分别为关键节点*i*的实际电压和电压参考值； $K_{j,\text{wtg}}$ 为第*j*台DFIG的无功裕度； $K_{k,\text{svg}}$ 为第*k*台SVG的无功裕度； n 为关键节点数量； m 为场站内风电机组数量； p 为场站内SVG的数量。

潮流约束条件如下：

$$\begin{cases} P_i - U_i \sum_{j=1}^N U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \\ Q_i - U_i \sum_{j=1}^N U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) = 0 \end{cases} \quad (7)$$

式中： P_i 、 Q_i 分别为注入节点*i*的有功功率和无功功率； N 为节点总数； U_i 、 U_j 分别为节点*i*、*j*的电压； G_{ij} 、 B_{ij} 分别为支路*i-j*的电导和电纳； θ_{ij} 为节点*i*与节点*j*之间的相角差。

关键节点电压约束和控制变量约束如下：

$$U_{i,\min} < U_i < U_{i,\max} \quad (8)$$

$$Q_{s,\min} + Q_{g,\min} < Q_{\text{wtg}} < Q_{s,\max} + Q_{g,\max} \quad (9)$$

$$Q_{\text{svg},\min} < Q_{\text{svg}} < Q_{\text{svg},\max} \quad (10)$$

式中： $U_{i,\max}$ 、 $U_{i,\min}$ 分别为关键节点*i*的电压上、下限。

1.2 马尔可夫决策过程模型

DRL是一种结合深度学习和强化学习的机器学习方法，其融合了深度学习的感知能力和强化学习的决策能力，已经在多个领域展现出了广泛的应用潜力^[29-31]。

DRL的决策主体为智能体，智能体通过与环境交互来学习一个最优的策略，以最大化其获得的累计奖励。DRL问题通常可以用马尔可夫决策过程(Markov decision process, MDP)来描述，MDP包含状态*S*、动作*A*、状态转移概率*P*、奖励*R*和折扣因子 γ 五个主要元素，因此，建立风电场站无功裕度优化的MDP模型需要明确元组(*S*, *A*, *P*, *R*, γ)中各个元素的含义。

1) 状态空间。状态空间*S*是智能体可能遇到的所有环境状态的集合，可以是离散的或者连续的。无功裕度优化问题中状态空间包括风电机组输出有功/无功功率、无功补偿设备输出无功功率、负荷需求以及关键节点电压幅值，第*t*个决策阶段的状态*s_t*为

$$s_t = \{P_{\text{wtg},t}, Q_{\text{wtg},t}, Q_{\text{svg},t}, P_{L,t}, Q_{L,t}, U_{ci,t}\} \quad (11)$$

式中: $P_{\text{wtg},t}$ 为第 t 个决策时段风电机组输出有功功率; $Q_{\text{wtg},t}$ 为第 t 个决策时段 DFIG 输出无功功率; $Q_{\text{svg},t}$ 为第 t 个决策时段 SVG 输出无功功率; $P_{\text{L},t}$ 为第 t 个决策时段负荷有功需求; $Q_{\text{L},t}$ 为第 t 个决策时段负荷无功需求; $U_{\text{ci},t}$ 为第 t 个决策时段关键节点 i 的电压幅值。

2) 动作空间。动作空间 A 是给定状态下智能体可以执行的所有动作的集合, 动作的选择会影响环境状态以及智能体获得的奖励。在风场无功裕度优化问题中, 本文考虑的动作手段主要包括 DFIG 无功调节和 SVG 无功调节, 第 t 个决策阶段的动作 a_t 为

$$a_t = \{Q_{\text{wtg},t}, Q_{\text{svg},t}\} \quad (12)$$

3) 状态转移概率。状态转移概率 P 描述了在执行某个动作后, 从当前状态转移到另一个状态的概率。在风场无功裕度优化问题中, 状态转移概率由电力系统环境确定。

4) 奖励函数。奖励函数 R 定义了智能体在某个状态下执行某个动作后获得的即时奖励, 为智能体提供了学习的方向。奖励函数由式(5)—(10)转化而来, 具体设置如式(13)所示, 其中, 前3项分别为 DFIG 无功裕度、SVG 无功裕度以及电压偏差值的奖励值, 最后一项为惩罚值:

$$r = \lambda_1 \sum (K_{\text{wtg}})^2 + \lambda_2 \sum (K_{\text{svg}})^2 + \sum_{i=1}^n \frac{1}{(U_{\text{ci}} - U_{\text{ci,ref}})^2 + \lambda_3} + \lambda_4 \quad (13)$$

式中: λ_1 、 λ_2 、 λ_3 为奖励放缩因子, 本文设置 $\lambda_1=50$, $\lambda_2=100$, $\lambda_3=0.1$, 旨在提高 SVG 无功裕度优先级的同时尽可能平衡 DFIG 与 SVG 输出的无功功率; λ_4 为惩罚因子, 若智能体采取动作导致电力系统环境不满足式(7)—(10)的约束条件, 设置 $\lambda_4=-100$, 否则, 设置 $\lambda_4=0$ 。

5) 折扣因子。折扣因子 γ 用于衡量未来奖励相对于即时奖励的重要性, 其值在 $0 \sim 1$, 折扣因子越小, 智能体越倾向于获得即时奖励; 折扣因子越大, 智能体越倾向于获得长期奖励。考虑到本文无功控制手段主要为 DFIG 和 SVG, 无功裕度优化的时间尺度较短, 因此将折扣因子设置为 0.85 。

2 基于改进 PPO 的风场无功裕度优化

2.1 PPO 原始算法

PPO 是一种基于策略梯度的深度强化学习算法, 最早由 OpenAI 的研究人员提出, 其可用于解决连续或者离散动作空间的问题, 且简单高效、收敛性好、易于调整, 因而受到了研究者的广泛关注^[32]。

传统的 on-policy 策略梯度算法每次更新参数都需要重新进行数据采样, 导致样本利用率低下。PPO 通过引入重要性采样技术来提高数据的利用率, 具体来说, PPO 使用旧策略采样到的数据多次更新策略, 并通过重要性权重来修正新旧策略数据分布之间的差异, 从而确保样本的有效性和算法的稳定性。

PPO 原始算法主要有 PPO 裁剪算法和 PPO 惩罚算法2种形式, 其目标函数分别如下式所示:

$$L_{\text{CLIP}}(\theta) = E_t [\min(\frac{\pi_{\theta}(a_t|s_t)}{\pi_{\theta_{\text{old}}}(a_t|s_t)} A_t, \text{clip}(\frac{\pi_{\theta}(a_t|s_t)}{\pi_{\theta_{\text{old}}}(a_t|s_t)}, 1-\epsilon, 1+\epsilon) A_t)] \quad (14)$$

$$L_{\text{KL}}(\theta) = E_t \{ \frac{\pi_{\theta}(a_t|s_t)}{\pi_{\theta_{\text{old}}}(a_t|s_t)} A_t - \beta K_L [\pi_{\theta_{\text{old}}}(\cdot|s_t), \pi_{\theta}(\cdot|s_t)] \} \quad (15)$$

式中: L_{CLIP} 为裁剪算法的目标函数; L_{KL} 为惩罚算法的目标函数; θ 为策略参数; E_t 为智能体从当前状态出发, 执行一系列动作所能获得的期望累积奖励; π_{θ} 为新策略; $\pi_{\theta_{\text{old}}}$ 为旧策略; A_t 为优势函数的估计值, 用于衡量在给定状态下采取某个动作相比于其他动作的优势; clip 函数为裁剪函数; ϵ 为裁剪系数; β 为惩罚系数; K_L 为散度, 用以衡量2个概率分布之间的差异。

PPO 裁剪算法通过在目标函数中引入 clip 裁剪函数来限制新旧策略之间的差异, clip 裁剪函数曲线如图1所示。具体来说, 智能体计算新策略和旧策略下的动作概率比值, 并将其限定在 $[1-\epsilon, 1+\epsilon]$, 以此来确保策略更新的幅度不会过大; PPO 惩罚算法则通过在目标函数中引入 K_L 来保证策略更新的稳定性, 当新策略与旧策略的 K_L 大于设定值时, 增加对新策略的惩罚, 从而限制策略更新的幅度。同 PPO 惩罚算法相比, PPO 裁




图1 裁剪函数曲线图

Fig. 1 Clipping function curve

剪算法无需计算 K_L ，避免了计算 K_L 可能引入的额外方差，更加易于实现和调整，因此，本文采用PPO裁剪算法进行风电场站的无功裕度优化研究。

2.2 基于变裁剪系数的PPO算法

由以上分析可知，PPO裁剪算法采用clip裁剪函数限制策略更新的幅度， ε 越大，策略更新幅度越大。原始的PPO算法中 ε 通常设置为一个固定的常数，不随时间或者训练进度而调整，若 ε 设置得过小，则不利于智能体对策略的探索，可能导致策略更新过于缓慢，或者导致智能体对某一个策略的过拟合；若 ε 设置得过大，则不利于策略更新的稳定性，可能导致策略性能急剧下降，或者导致策略陷入局部最优解。

为此，本文借鉴DRL中常用的学习率衰减的思想，提出一种基于变裁剪系数的PPO算法，所提变裁剪系数按照自然指数衰减，计算公式为

$$\varepsilon = \varepsilon_0 e^{-\frac{t}{T} \ln(\frac{\varepsilon_0}{\varepsilon_1})} \quad (16)$$

式中： ε_0 、 ε_1 分别为裁剪系数的初始值和最终值； T 为训练总回合数； t 为当前训练回合数。

在智能体训练的初期，较大的 ε 可以促进智能体的探索，有利于提高策略的性能；随着训练的进行，减小 ε 可以减少不必要的探索，从而提高策略的稳定性。

2.3 基于改进PPO算法的风场无功裕度优化框架

基于改进PPO算法的DFIG风场无功裕度优化框架如图2所示。实际电网运行中，可基于电网历史运行数据训练智能体，训练完成的智能体可通过电网量测装置结合风速预测、负荷预测实时获取电网状态信息，进而给出风电场站中不同

无功资源的无功指令值。




图2 基于改进PPO算法的风场无功裕度优化框架

Fig. 2 Framework for wind farm reactive power margin optimization based on improved PPO algorithm

3 算例分析

3.1 算例设置

为验证所提无功裕度优化方法的正确性和有效性，基于Python3.10.11(64bit)环境，结合Pandapower库，搭建了改进的IEEE 39节点系统进行算例分析，所做修改如下：在保持原IEEE 39节点系统线路参数不变的基础上，将原系统第32号母线上的常规发电厂替换为容量400 MV·A的DFIG风电场站，且风电场站配备可调容量为±200 MV·A的SVG，此外，在原系统第10号母线(代表风场并网点)处接入一组负荷。

供智能体训练的风电出力、有功负荷数据取自比利时电网2023年1—12月的真实历史数据，数据采样间隔为15 min，经数据清洗后共保留33 600组数据；无功负荷训练数据以比利时电网的有功负荷历史数据为基础，基于标准正态分布按照功率因数范围[0.8, 0.95]进行构造。

3.2 训练过程

智能体共训练400回合，每一回合智能体和电力系统环境交互500次。图3为基于变裁剪系数PPO的神经网络损失值收敛过程(ε_0 设置为0.3， ε_1 设置为0.1，后文同此参数设置)，智能体通过最

小化损失函数来更新模型的参数，可以看出，在经过大约 50 回合的交互之后，神经网络损失值已接近收敛。图 4 为基于变裁剪系数 PPO 的奖励值收敛过程，可以看出，在经过大约 200 回合的交互之后，奖励值接近收敛，表明智能体已经学习到了较为稳定的策略。




图 3 损失值收敛过程

Fig. 3 Loss value convergence process




图 4 奖励值收敛过程

Fig. 4 Reward value convergence process

3.3 对比分析

为验证所提变裁剪系数 PPO 的有效性，对比裁剪系数 ϵ 分别设置为 0.1、0.3 以及变裁剪系数时的奖励值收敛过程，不同裁剪系数下的滑动平均奖励值曲线如图 5 所示。在智能体的整个训练过程中，裁剪系数 ϵ 为 0.1、0.3 时，平均奖励值分别为 46.51、46.47，采用变裁剪系数时，平均奖励值为 51.60。此外，观察滑动平均奖励值曲线可知，采用变裁剪系数时奖励最终收敛值更大，且收敛速度更快。可见，从滑动平均奖励值来看，基于变裁剪系数的 PPO 算法优于原始的固定裁剪系数的 PPO 算法。




图 5 不同裁剪系数下的滑动平均奖励值曲线

Fig. 5 Sliding average reward value curves under different clipping coefficients

为了进一步验证本文所提方法的有效性，对比固定裁剪系数 PPO、变裁剪系数 PPO、遗传算法的决策速度以及风场无功裕度优化效果。其中，遗传算法的适应度函数由 PPO 算法的奖励函数转化而来；测试数据取自比利时电网 2024 年 1 月中某 1 天的真实历史数据，采样间隔仍为 15 min，即智能体与环境的交互次数为 96 次。

不同算法的决策速度如表 1 所示。固定裁剪系数的 PPO 算法与变裁剪系数的 PPO 算法训练时长和决策时长都较为接近；遗传算法虽无需训练，但其决策时长却远高于 PPO 算法，且随着与环境交互次数的增加，PPO 算法的决策速度优势将会愈发明显。

表 1 不同算法的决策速度比较

Tab. 1 Comparison of decision speeds of different algorithms

算法	训练时长/s	决策时长/s	总时长/s
PPO($\epsilon=0.1$)	3 120.00	3.90	3 123.90
PPO($\epsilon=0.3$)	3 127.00	4.44	3 131.44
PPO(变裁剪系数)	3 177.00	3.90	3 180.90
遗传算法	0.00	3 687.30	3 687.30

图 6 为不同算法无功裕度优化下系统第 10 号节点(代表风场并网点)的电压幅值。我国陆上风电并网导则规定，稳态时风场应将其并网点电压控制在标称电压的 97%~107%，据此，本文以 1.0 pu 为风场并网点电压控制目标，分别以 1.07、0.97 pu 为电压上、下限。

由图 6 可知，不同算法均能将并网点电压限制在规定范围，其中，遗传算法对 DFIG 风场并网




图6 不同算法下的风场并网点电压幅值

Fig. 6 Voltage amplitudes at grid-connected points of wind farm under different algorithms

点电压控制效果最佳, 整个测试过程的平均电压幅值为1.016 pu, 本文所提基于变裁剪系数的PPO算法控制效果与遗传算法接近, 平均电压幅值为1.018 pu, 固定裁剪系数的PPO算法控制效果则较差, ε 为0.1、0.3对应的电压幅值分别为1.033、1.026 pu。

图7、8分别为不同算法下DFIG无功出力 and SVG无功出力。其中, 在DFIG无功裕度方面, 不同算法下DFIG无功出力接近; 在SVG无功裕度方面, 本文所提变裁剪系数的PPO算法预留了最多的无功裕度, 整个测试过程的平均无功裕度为84.97%, 对风场暂态电压支撑能力的提升效果最明显, 固定裁剪系数为0.1、0.3的PPO算法平均无功裕度分别为40.90%、63.16%, 遗传算法下的SVG平均无功裕度为6.11%, 无功裕度优化效果最差, 且多次达到了SVG无功出力限值。

综合考虑不同算法的决策速度以及对并网点




图7 不同算法下的DFIG无功输出功率

Fig. 7 Reactive power output of DFIG under different algorithms




图8 不同算法下的SVG无功输出功率

Fig. 8 Reactive power output of SVG under different algorithms

电压、风电场站无功裕度的优化效果, 本文所提基于变裁剪系数的PPO算法优于固定裁剪系数的PPO算法以及遗传算法。

4 结论

为解决考虑源荷不确定性的DFIG风场无功裕度优化问题, 提出一种基于变裁剪系数的PPO算法, 在平抑并网点电压波动的同时提升了风电场站的无功裕度, 最后通过和不同算法的对比验证了所提算法的正确性和有效性, 主要结论如下:

1) 与原始的PPO算法相比, 所提算法在训练初期通过较大的裁剪系数促进策略的探索, 在训练后期通过较小的裁剪系数保障策略的稳定, 解决了固定裁剪系数难以兼顾收敛速度与优化质量的问题。

2) 基于改进的IEEE 39节点系统对比分析了所提算法、原始的PPO算法和遗传算法的优化效果, 所提算法无功裕度优化效果更好, 预留了更多的快速无功储备用于风场暂态电压支撑。

3) 所提算法单次决策时长仅需3.9 s, 较之遗传算法决策速度提升约3个数量级, 且随着控制周期缩短、交互频次增加, 所提算法的效率优势将进一步扩大, 更契合新型电力系统源荷快速波动场景下的在线无功优化需求。

参考文献

- [1] 张智刚, 康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 2022, 42(8):

- 2806-2818.
- Zhang Z G, Kang C Q. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2818.
- [2] 韩肖清, 李廷钧, 张东霞, 等. 双碳目标下的新型电力系统规划新问题及关键技术[J]. 高电压技术, 2021, 47(9): 3036-3046.
- Han X Q, Li T J, Zhang D X, et al. New issues and key technologies of new power system planning under double carbon goals[J]. High Voltage Engineering, 2021, 47(9): 3036-3046.
- [3] 周孝信, 鲁宗相, 刘应梅, 等. 中国未来电网的发展模式和关键技术[J]. 中国电机工程学报, 2014, 34(29): 4999-5008.
- Zhou X X, Lu Z X, Liu Y M, et al. Development models and key technologies of future grid in China[J]. Proceedings of the CSEE, 2014, 34(29): 4999-5008.
- [4] 任冲, 崔明建. 面向新型电力系统支撑需求的构网型技术多维量化评估体系综述[J]. 智慧电力, 2026, 54(3): 1-11.
- Ren C, Cui M J. A review of multi-dimensional quantitative evaluation system for grid-forming technologies oriented towards support requirements of new power systems[J]. Smart Power, 2026, 54(3): 1-11.
- [5] 高明, 曾平良, 冯永朝. 新型电力系统中的虚拟电厂研究综述[J]. 电力工程技术, 2025, 44(6): 143-154.
- Gao M, Zeng P L, Feng Y C. Review of virtual power plant in new power system[J]. Electric Power Engineering Technology, 2025, 44(6): 143-154.
- [6] 周勤勇, 郝绍煦, 董武, 等. “十五五”电网规划安全稳定分析关键问题[J]. 中国电力, 2025, 58(9): 138-147.
- Zhou Q Y, Hao S X, Dong W, et al. Key issues in security and stability analysis for the “15th five-year” power grid planning[J]. Electric Power, 2025, 58(9): 138-147.
- [7] 闫正义, 赵康, 王凯. 基于强化学习的新型电力系统优化策略应用综述[J]. 发电技术, 2025, 46(3): 508-520.
- Yan Z Y, Zhao K, Wang K. Review of application on optimization strategies for new-type power system based on reinforcement learning[J]. Power Generation Technology, 2025, 46(3): 508-520.
- [8] 韩民晓, 赵正奎, 郑竞宏, 等. 新能源场站电网暂态电压支撑技术发展动态[J]. 电网技术, 2023, 47(4): 1309-1327.
- Han M X, Zhao Z K, Zheng J H, et al. Development of dynamic voltage support for power grid with large-scale renewable energy generation[J]. Power System Technology, 2023, 47(4): 1309-1327.
- [9] 张建新, 刘宇明, 邱建, 等. 区域新能源并网暂态功角稳定分析与紧急控制策略优化[J]. 南方电网技术, 2024, 18(7): 129-138.
- Zhang J X, Liu Y M, Qiu J, et al. Transient power angle stability analysis of regional new energy integration and coordinated control strategy[J]. Southern Power System Technology, 2024, 18(7): 129-138.
- [10] 王渝红, 宋雨妍, 廖建权, 等. 风电电压主动支撑技术现状与发展趋势[J]. 电网技术, 2023, 47(8): 3193-3205.
- Wang Y H, Song Y Y, Liao J Q, et al. Review and development trends of DFIG-based wind power voltage active support technology[J]. Power System Technology, 2023, 47(8): 3193-3205.
- [11] 莫基晟, 尹纯亚, 黄新民, 等. 考虑有功无功协调恢复的风电场高电压穿越策略[J]. 发电技术, 2025, 46(4): 737-747.
- Mo J S, Yin C Y, Huang X M, et al. High voltage crossing strategy of wind farm considering active and reactive coordinated recovery[J]. Power Generation Technology, 2025, 46(4): 737-747.
- [12] 张成, 陈宇, 李灿, 等. 计及双馈风机无功出力的配电网无功优化[J]. 南方能源建设, 2025, 12(1): 168-176.
- Zhang C, Chen Y, Li C, et al. Reactive power optimization of distribution network considering the reactive power output of doubly fed induction generator[J]. Southern Energy Construction, 2025, 12(1): 168-176.
- [13] 孙伟伟, 付蓉, 陈永华. 计及无功裕度的双馈风电场无功电压协调控制[J]. 电力自动化设备, 2014, 34(10): 81-85.
- Sun W W, Fu R, Chen Y H. Coordinated var and voltage control of doubly-fed wind farm considering reactive power margin[J]. Electric Power Automation Equipment, 2014, 34(10): 81-85.
- [14] 张超, 王渝红, 欧林, 等. 双馈风电场无功电压分层协调控制的研究[J]. 电测与仪表, 2015, 52(3): 85-90.
- Zhang C, Wang Y H, Ou L, et al. Research of hierarchical coordination control for reactive voltage of doubly-fed wind farm[J]. Electrical Measurement & Instrumentation, 2015, 52(3): 85-90.
- [15] 崔杨, 彭龙, 仲悟之, 等. 基于DFIG可用无功裕度

- 的风电场无功电压控制方法[J]. 电测与仪表, 2016, 53(2): 15-20.
- Cui Y, Peng L, Zhong W Z, et al. A control strategy for reactive power and voltage of wind farm based on DFIG reactive power compensation ability[J]. Electrical Measurement & Instrumentation, 2016, 53(2): 15-20.
- [16] 毕聪博, 唐聿劼, 罗永红, 等. 电力系统优化控制中强化学习方法应用及挑战[J]. 中国电机工程学报, 2024, 44(1): 1-21.
- Bi C B, Tang Y J, Luo Y H, et al. Review on critical problems in reinforcement learning methods applied in power system optimization and control scenarios[J]. Proceedings of the CSEE, 2024, 44(1): 1-21.
- [17] 李琦, 乔颖, 张宇精. 配电网持续无功优化的深度强化学习方法[J]. 电网技术, 2020, 44(4): 1473-1480.
- Li Q, Qiao Y, Zhang Y J. Continuous reactive power optimization of distribution network using deep reinforcement learning[J]. Power System Technology, 2020, 44(4): 1473-1480.
- [18] 李鹏, 姜磊, 王加浩, 等. 基于深度强化学习的新能源配电网双时间尺度无功电压优化[J]. 中国电机工程学报, 2023, 43(16): 6255-6266.
- Li P, Jiang L, Wang J H, et al. Optimization of dual-time scale reactive voltage for distribution network with renewable energy based on deep reinforcement learning[J]. Proceedings of the CSEE, 2023, 43(16): 6255-6266.
- [19] 朱介北, 胡家兵. 新型电力系统构网控制性能评估与提升[J]. 全球能源互联网, 2025, 8(4): 416-417.
- Zhu J B, Hu J B. Performance evaluation and improvement of grid-forming control in new type power system[J]. Journal of Global Energy Interconnection, 2025, 8(4): 416-417.
- [20] 娄奇鹤, 李彦斌, 王登政, 等. 现代智慧配电网发展方向与关键技术框架研究[J]. 电力建设, 2025, 46(5): 69-83.
- Lou Q H, Li Y B, Wang D Z, et al. Framework for the development direction and key technologies of modern smart distribution networks[J]. Electric Power Construction, 2025, 46(5): 69-83.
- [21] 杜婉琳, 王玲, 罗威, 等. 基于深度强化学习的有源配电网电压分层控制策略[J]. 发电技术, 2024, 45(4): 734-743.
- Du W L, Wang L, Luo W, et al. Voltage hierarchical control strategy of active distribution network based on deep reinforcement learning[J]. Power Generation Technology, 2024, 45(4): 734-743.
- [22] 徐晓春, 李佑伟, 戴欣, 等. 基于深度强化学习的馈线-台区两阶段电压优化[J]. 电网与清洁能源, 2023, 39(3): 63-73.
- Xu X C, Li Y W, Dai X, et al. Two stage voltage optimization of feeder-station area based on deep reinforcement learning[J]. Power System and Clean Energy, 2023, 39(3): 63-73.
- [23] 周良才, 周毅, 沈维健, 等. 基于深度强化学习的新电力系统无功电压优化控制[J]. 电测与仪表, 2024, 61(9): 182-189.
- Zhou L C, Zhou Y, Shen W J, et al. Reactive voltage optimization control of novel power system based on deep reinforcement learning[J]. Electrical Measurement & Instrumentation, 2024, 61(9): 182-189.
- [24] 张沛, 朱驻军, 谢桦. 基于深度强化学习近端策略优化的电网无功优化方法[J]. 电网技术, 2023, 47(2): 562-570.
- Zhang P, Zhu Z J, Xie H. Reactive power optimization based on proximal policy optimization of deep reinforcement learning[J]. Power System Technology, 2023, 47(2): 562-570.
- [25] 张兴. 新能源发电变流技术[M]. 北京: 机械工业出版社, 2018.
- Zhang X. New Energy Generation and Converter Technology[M]. Beijing: China Machine Press, 2018.
- [26] 栗然, 唐凡, 刘英培, 等. 双馈风电场新型无功补偿与电压控制方案[J]. 中国电机工程学报, 2012, 32(19): 16-23.
- Li R, Tang F, Liu Y P, et al. A new scheme of reactive power compensation and voltage control for DFIG based wind farm[J]. Proceedings of the CSEE, 2012, 32(19): 16-23.
- [27] 王松, 李庚银, 周明. 双馈风力发电机组无功调节机理及无功控制策略[J]. 中国电机工程学报, 2014, 34(16): 2714-2720.
- Wang S, Li G Y, Zhou M. The reactive power adjusting mechanism & control strategy of doubly fed induction generator[J]. Proceedings of the CSEE, 2014, 34(16): 2714-2720.
- [28] GB/T 19963.1—2021 风电场接入电力系统技术规定第1部分: 陆上风电[S].
- GB/T 19963.1—2021 Technical specification for connecting wind farm to power system: Part 1: On shore wind power[S].
- [29] Shrestha A, Mahmood A. Review of deep learning algorithms and architectures[J]. IEEE Access, 2019, 7: 53040-53065.

[30] 倪爽, 崔承刚, 杨宁, 等. 基于深度强化学习的配电网多时间尺度在线无功优化[J]. 电力系统自动化, 2021, 45(10): 77-85.

Ni S, Cui C G, Yang N, et al. Multi-time-scale online optimization for reactive power of distribution network based on deep reinforcement learning[J]. Automation of Electric Power Systems, 2021, 45(10): 77-85.

[31] Yang Q L, Wang G, Sadeghi A, et al. Two-timescale voltage control in distribution grids using deep reinforcement learning[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2313-2323.

[32] Schulman J, Wolski F, Dhariwal P, et al. Proximal policy optimization algorithms[EB/OL]. (2017-08-28) [2024-10-15]. <https://arxiv.org/abs/1707.06347>.

收稿日期: 2025-05-07。

修回日期: 2025-07-13。

作者简介:



余达

余达(1991), 男, 硕士, 工程师, 研究方向为新能源并网与运行, dale_yuda@163.com;



武志韬

武志韬(2000), 男, 博士研究生, 研究方向为新能源场站暂态电压主动支撑技术, wuzhitao0214@163.com;



陈子文

陈子文(1994), 男, 博士, 工程师, 研究方向为海上风电机组关键技术, chen_ziwen@ctg.com.cn;



林旭

林旭(1991), 男, 博士, 高级工程师, 研究方向为新能源并网与运行, lx_gpdc_2022@sina.com;



王巍桦

王巍桦(1998), 男, 硕士, 助理工程师, 研究方向为新能源并网与运行, Wwhbw1212@163.com;



刘崇茹

刘崇茹(1977), 女, 博士, 教授, 研究方向为交直流混合系统分析与仿真、运行与控制, 本文通信作者, chongru.liu@ncepu.edu.cn。

(责任编辑 杨阳)