

DOI:10.14044/j.1674-1757.pcrpc.2026.03.009

含高比例分布式光伏的配电网双时间尺度智能电压 调控策略

许会广¹, 张刘冬², 张思源¹, 张天海³, 李琦¹

(1. 国电南瑞科技股份有限公司, 南京 211106; 2. 国网江苏省电力有限公司, 南京 210009;
3. 江苏方天电力技术有限公司, 南京 211102)

摘要: 针对高比例分布式光伏接入条件下配电网中易出现的电压越限、网络损耗增加及机械调压设备频繁动作等问题, 提出一种基于强化学习的双时间尺度电压调控策略。首先, 构建配电网双时间尺度电压调控优化模型, 以节点电压偏差和系统网络损耗为优化目标, 并计及机械调压设备运行约束。其次, 在慢时间尺度上, 以有载调压变压器(on-load tap changer, OLTC)和并联电容器为控制对象, 采用深度Q网络(deep Q-network, DQN)实现机械调压设备离散决策。然后, 在快时间尺度上, 以逆变器群体为控制对象, 采用ASRN-MAD3PG算法实现无功快速调节。最后, 通过算例分析验证了所提模型及求解方法的有效性。

关键词: 配电网电压调控; 双时间尺度; 智能调控; 多智能体无功优化; OLTC/并联电容器

Dual-time-scale Intelligent Voltage Control Strategy for Distribution Networks with High-penetration Distributed Photovoltaics

XU Huiguang¹, ZHANG Liudong², ZHANG Siyuan¹, ZHANG Tianhai³, LI Qi¹

(1. NARI Technology Co., Ltd., Nanjing 211106, China; 2. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210009, China; 3. Jiangsu Fangtian Electric Power Technology Co., Ltd., Nanjing 211102, China)

Abstract: Aiming at the problems such as voltage limit violation, increased network loss and frequent operation of mechanical voltage regulation equipment that are prone to occur in distribution networks with a high proportion of distributed photovoltaic access, a dual-time-scale voltage regulation strategy based on reinforcement learning is proposed. Firstly, a dual-time-scale voltage regulation optimization model for distribution networks is constructed, with node voltage deviation and system network loss as the optimization objectives, and the operation constraints of mechanical voltage regulation equipment are considered. Secondly, on the slow time scale, the on-load tap changer (OLTC) and parallel capacitors are taken as the control objects, and the deep Q-network (DQN) is used to achieve discrete decision-making of mechanical voltage regulation equipment. Then, on the fast time scale, the inverter group is taken as the control object, and the ASRN - MAD3PG algorithm is used to achieve rapid reactive power regulation. Finally, the effectiveness of the proposed model and solution method is verified through case studies.

Keywords: distribution network voltage regulation; dual time scales; intelligent control; multi-agent reactive power optimization; OLTC/shunt capacitors

0 引言

随着风能、光伏等可再生能源在配电网中的高

比例接入, 源荷状态呈现出显著的不确定性和时变性, 典型问题表现为日内电压越限和网络损耗上升。同时, 由于有载调压变压器(on-load tap changer,

收稿日期:2026-04-10; 修回日期:2026-05-08

基金项目:江苏省重点研发计划项目(BE2023016-2)。

Project Supported by Jiangsu Provincial Key Research and Development Program(BE2023016-2)。

OLTC)、分组电容器等离散慢动作设备与逆变器等连续快动作设备在响应时标和物理属性上存在明显差异,如何兼顾短时电压质量与长期设备寿命/运行成本变得更加困难。因此,面向“小时级(慢)一分钟级(快)”协同的电压调控(以无功支撑为主要手段)成为工程必需,且需要在不依赖精确网模的条件下具备实时自适应能力。

现有研究大致沿两条路径展开。第1类模型驱动优化:文献[1]提出基于混合整数线性规划的集中式无功电压优化,协调 OLTC/电容以降低网损并维持电压合规,但对网络参数与预测精度敏感,规模扩大时计算复杂度上升;文献[2]采用二阶锥松弛提升了非凸问题的可解性,但该方法对模型参数依赖较强,在复杂不确定场景下鲁棒性仍有不足;文献[3]采用进化算法求解含离散变量和非线性约束的优化问题。该方法虽具有一定的全局搜索能力,但收敛速度较慢,在线应用难度较大;文献[4]与文献[5]分别以交替方向乘子法(alternating direction method of multipliers, ADMM)与对偶分解实现分布式求解,增强可扩展性但对通信与同步条件要求较高,时延与量测不完备会影响收敛稳定;文献[6-7]尝试采用分散式或准实时控制方式以缩短决策链路,但在跨区域协同和全局一致性方面仍存在一定局限。总体而言,模型驱动方法的优势在于可解释性强、约束刻画完整,适合将电压/电流边界、装置最小停留时间与日动作上限等工程要求显式纳入最优潮流(optimal power flow, OPF)、混合整数二阶锥规划(mixed-integer second-order cone programming, MISOCP)或混合整数线性规划(mixed-integer linear programming, MILP)框架,并可通过分层或两阶段协调增强求解效率。然而,该类方法对网络参数与预测精度较为敏感,在高渗透可再生导致的时变不确定、量测噪声与通信时延作用下,鲁棒性与在线可扩展性受限;当离散变量增多或规模扩大时,在线求解负担也随之上升。因此,工程实践中更倾向于将其作为慢时间尺度的计划或基线,仍需配合快速校正机制以应对分钟级波动。

第2类方法为数据驱动的强化学习方法(reinforcement learning, RL):文献[8-9]以表格Q学习验证无模型控制可行性,但状态—动作空间扩张导致难以扩展;文献[10-11]采用DQN优化电容投切,在短时间抑制电压偏差但仅适用于离散动作;文献[12]引入深度确定性策略梯度(deep deterministic policy gradient, DDPG)以应对逆变器连续无功与不确定工况,单智能体框架在多装置协同与规模化方

面受限;为提升协同能力,文献[13]基于多智能体深度强化学习并在集中训练、分散执行(centralized training, decentralized execution, CTDE)范式下实现装置级自治与系统级协同;进一步地,文献[14-15]提出两阶段/双时间尺度策略:小时级优选 OLTC/电容基调,分钟级以 MADRL 细化逆变器实时电压调控,兼顾性能与实时性,但存在跨时标目标口径不一致、工程约束嵌入不系统等问题。面向多装置协同和不确定场景,强化学习方法通常结合双时间尺度和多智能体框架:慢时间尺度多采用值函数类算法,以增强离散动作决策的稳定性;快时间尺度多采用策略梯度类算法,并在 CTDE 范式下实现逆变器的协同控制。为提升样本效率与可扩展性,近期研究在快层进一步引入基于电气相似性的区域化/集群化建模,并通过奖励成分对齐、分钟级到小时级窗口聚合与动作掩码/安全约束等机制,统一跨时标目标口径、抑制跨区牵动^[16-19]。该类方法在不依赖精确网络模型的条件下具有较好的自适应能力,但其收敛稳定性和可复现性仍在较大程度上依赖于经验回放、探索策略及时窗统计等训练设置。

综合来看,当前主要挑战在于跨时标目标对齐不足,慢层优化目标与快层奖励函数的口径不一致容易引发层间策略冲突^[20];工程约束融入不够系统,例如将 OLTC/电容的日动作上限与切换惩罚统一纳入训练与评估的流程仍不完善^[21-31];复现与部署的口径不统一,时标、单位与统计窗口在不同模块之间缺乏一致标注,从而削弱了结果的可比性与落地性。

针对现有配电网双时间尺度调压方法中存在的上下层控制目标衔接不紧、层间信息利用不足以及快时间尺度高波动工况下训练稳定性较差等问题,本文的主要工作和创新体现在以下3个方面:

1)构建了计及节点电压偏差、系统网络损耗和机械调压设备动作代价的双时间尺度电压调控模型,实现了电压质量、运行经济性与设备动作成本的统一建模。

2)在求解框架上,慢时间尺度采用DQN处理OLTC和并联电容器的离散调节决策,快时间尺度采用文献[12]所提出的ASRN-MAD3PG算法实现逆变器群体的快速无功调节,并形成与设备响应特性相匹配的分层控制结构。

3)设计了上层动作注入、快层窗口回报聚合及顺序协调控制机制,使快层控制能够感知慢层调节边界,慢层策略能够评价其动作对后续快层调节效果的影响,从而实现双时间尺度目标对齐与协同优化。

1 双时间尺度电压调控模型

1.1 配电网双时间尺度电压调控优化模型

针对高比例分布式光伏接入条件下配电网易出现的电压越限和网络损耗增加问题,本文综合考虑有载调压变压器、并联电容器和逆变器等调压资源的协同作用,将配电网双时间尺度电压调控任务建模为一个优化问题。本文的调控目标为:在满足节点电压和设备运行约束的前提下,最小化节点电压偏差与系统网络损耗。具体优化目标函数为

$$\min F = \lambda_1 F_V + \lambda_2 F_{\text{loss}} \quad (1)$$

式中: F_V 为节点电压偏差指标; F_{loss} 为系统网络损耗指标; λ_1 和 λ_2 分别为对应目标项的权重系数。

其中,节点电压偏差指标表示为

$$F_V = \sum_{i \in N} (U_i - U_{\text{ref}})^2 \quad (2)$$

系统网络损耗指标表示为

$$F_{\text{loss}} = \sum_{(i,j) \in \mathcal{E}} P_{\text{loss},ij} \quad (3)$$

式中: N 为系统节点集合; $\mathcal{E}$ 为系统支路集合; V_i 为节点 i 的电压幅值; V_{ref} 为节点参考电压; $P_{\text{loss},ij}$ 为支路 ij 的有功损耗。

优化过程中需满足以下等式与不等式约束:

1) 配电网潮流平衡方程

$$P_{ij} - \sum_{m \in N_j} P_{jm} = p_j + r_{ij} \frac{P_{ij}^2 + Q_{ij}^2}{U_i^2} \quad (4)$$

$$Q_{ij} - \sum_{m \in N_j} Q_{jm} = q_j + x_{ij} \frac{P_{ij}^2 + Q_{ij}^2}{U_i^2} \quad (5)$$

$$U_j^2 = U_i^2 - 2(r_{ij} P_{ij} + x_{ij} Q_{ij}) + (r_{ij}^2 + x_{ij}^2) \frac{P_{ij}^2 + Q_{ij}^2}{U_i^2} \quad (6)$$

式中: P_{ij} 和 Q_{ij} 分别为支路 ij 上的有功功率和无功功率; p_j 和 q_j 分别为节点 j 的净有功注入和净无功注入; r_{ij} 和 x_{ij} 分别为支路 ij 的电阻和电抗; N_j 为节点 j 的下游节点集合。

2) 节点电压约束

$$U_{\min} \leq U_i \leq U_{\max}, \quad i \in N \quad (7)$$

式中, $U_{\min}$ 和 $U_{\max}$ 分别为节点电压允许下限和上限。

3) OLTC 运行约束

$$n_{\text{tap},\min} \leq n_{\text{tap}} \leq n_{\text{tap},\max} \quad (8)$$

式中: n_{tap} 为有载调压变压器分接头位置; $n_{\text{tap},\min}$ 和 $n_{\text{tap},\max}$ 分别为其最小和最大允许挡位。

4) 并联电容器运行约束

$$u_c \in \{0, 1\}, \quad c \in C \quad (9)$$

式中: u_c 为并联电容器组 c 的投切状态; C 为并联电容器组集合; 当 $u_c = 1$ 时表示电容器投入运行, 当 $u_c = 0$ 时表示电容器退出运行。

5) 逆变器运行约束

$$(P_i^{\text{inv}})^2 + (Q_i^{\text{inv}})^2 \leq (S_i^{\text{inv}})^2, \quad i \in G \quad (10)$$

$$Q_{i,\min}^{\text{inv}} \leq Q_i^{\text{inv}} \leq Q_{i,\max}^{\text{inv}} \quad (11)$$

式中: G 为逆变器所在节点集合; P_i^{inv} 和 S_i^{inv} 分别为节点 i 处逆变器的有功输出、无功输出和额定视在容量; $Q_{i,\min}^{\text{inv}}$ 和 $Q_{i,\max}^{\text{inv}}$ 分别为逆变器无功出力下限和上限。

1.2 双时间尺度电压调控马尔可夫决策过程建模

为便于采用强化学习方法求解上述双时间尺度电压调控优化模型,本文进一步将慢时间尺度机械调压决策过程建模为马尔可夫决策过程,将快时间尺度逆变器协同调压过程建模为多智能体决策过程。

1) 慢时间尺度马尔可夫决策过程

慢时间尺度主要负责有载调压变压器分接头位置和并联电容器投切状态的离散优化决策,其目标是在较长时间尺度上调整系统基础运行方式,为快时间尺度逆变器无功调节提供调压基础。该过程可表示为四元组 (S^s, A^s, P^s, r^s) 。

① 状态空间

慢时间尺度状态空间 S^s 包含系统在当前时段的运行信息以及上一时段机械调压设备的动作状态,可表示为

$$S^s = \{P_{L,t}, Q_{L,t}, P_{\text{DG},t}, U_t^{\text{sta}}, n_{\text{tap},t-1}, u_{c,t-1}\} \quad (12)$$

式中: $P_{L,t}$ 和 $Q_{L,t}$ 分别为时段 t 的有功、无功负荷信息; $P_{\text{DG},t}$ 为分布式电源有功出力; U_t^{sta} 为系统电压运行状态量; $n_{\text{tap},t-1}$ 和 $u_{c,t-1}$ 分别为上一时段 OLTC 分接头位置和并联电容器投切状态。

② 动作空间

慢时间尺度动作空间 A^s 为机械调压设备的联合控制集合,可表示为

$$A^s = \{\Delta n_{\text{tap},t}, \Delta u_{c,t}\} \quad (13)$$

式中: $\Delta n_{\text{tap},t}$ 为 OLTC 分接头调整量; $\Delta u_{c,t}$ 为并联电容器投切动作。慢层动作需满足 OLTC 挡位上下限及并联电容器离散投切约束。

③ 状态转移

状态转移概率 P^s 描述系统在当前状态下执行动作后转移至下一时段状态的过程,该过程主要受

负荷波动、分布式电源出力变化以及机械调压设备动作的共同影响。

④奖励函数

慢时间尺度奖励由当前周期内系统的累计运行效果和机械调压设备动作代价共同决定。由于上层动作执行后,下层智能体会在该周期内完成多步快速调节,因此慢层奖励不再仅基于单一时刻的运行状态计算,而是由该周期内快时间尺度窗口的累计电压偏差、累计网络损耗以及机械调压设备动作惩罚共同构成,即

$$r_t^s = - \left(\alpha_s \sum_{l=1}^L C_v^{t,l} + \beta_s \sum_{l=1}^L C_{\text{loss}}^{t,l} + \chi_s C_{\text{act}}^t \right) \quad (14)$$

式中: L 为当前慢时间尺度周期内包含的快时间尺度步数; $C_v^{t,l}$ 和 $C_{\text{loss}}^{t,l}$ 分别表示第 t 个慢时间尺度周期内第 l 个快时间尺度步对应的电压偏差项和网络损耗项; C_{act}^t 表示当前慢时间尺度机械调压设备动作惩罚项; α_s 、 β_s 和 χ_s 为对应权重系数。

2) 快时间尺度多智能体决策过程

快时间尺度主要实现分布式逆变器的快速无功调节,以抑制由光伏出力波动和负荷变化引起的节点电压偏差。考虑到快时间尺度控制需在慢时间尺度机械调压结果给定的条件下进行,本文将建模为多智能体决策过程。各智能体在局部运行信息的基础上,同时感知上层控制结果,从而实现双时间尺度协调控制。

①智能体集合

$$\mathcal{I} = \{1, 2, \dots, N\} \quad (15)$$

表示所有参与协同调压的逆变器智能体集合,其中 N 为智能体总数。

②状态空间

快时间尺度状态空间 S^l 表示当前控制时刻系统运行状态及上层控制信息,定义为

$$S^l = \{U_i, P_i, Q_i, \alpha, \beta | i \in N_{\text{node}}\} \quad (16)$$

式中: N_{node} 为系统节点集合; U_i 、 P_i 和 Q_i 分别表示节点 i 的电压幅值、有功功率和无功功率; α 和 β 表示上层慢时间尺度控制结果。该状态空间既反映了配电网当前运行状态,也包含了快时间尺度决策所需的上层控制边界信息。

③动作空间

节点 i 处逆变器智能体的动作空间为无功功率调节范围,即

$$A_i^l = [q_{i,\min}, q_{i,\max}] \quad (17)$$

式中, $q_{i,\min}$ 和 $q_{i,\max}$ 分别为节点 i 处逆变器无功功率上下限。

④观测空间

受通信条件限制,第 i 个智能体仅依据与自身相关的局部状态信息进行决策,其观测量可表示为

$$s_i^l = \{U_i, P_i, Q_i, \alpha, \beta\} \quad (18)$$

式中, α 和 β 为当前慢时间尺度周期内上层控制结果。通过将上层动作并入局部观测,下层智能体能够在给定机械调压边界下进行快速无功优化。

⑤奖励函数

快时间尺度奖励函数 r_i^l 表示智能体在当前状态和动作下获得的即时奖励,可定义为

$$r_i^l = -(\alpha_f C_{v,i}^l + \beta_f C_{\text{loss}}^l + \chi_f C_{q,i}^l) \quad (19)$$

式中: $C_{v,i}^l$ 为快时间尺度电压偏差或越限惩罚项; C_{loss}^l 为网络损耗项; $C_{q,i}^l$ 为逆变器无功调节代价项; α_f 、 β_f 和 χ_f 为对应权重系数。

2 双时间尺度控制框架

本文构建了配电网双时间尺度电压无功协调控制框架,双时间尺度控制框架图如图1所示。根据调压资源动作特性及响应速度差异,将控制任务划分为慢时间尺度和快时间尺度两层。慢时间尺度以有载调压变压器和并联电容器为控制对象,决策周期为1h,负责机械调压设备的离散调节;快时间尺度面向分布式电源侧快速调节过程,决策周期为15min,负责对源荷波动引起的节点电压偏移进行快速修正。




图1 双时间尺度控制框架图
Fig. 1 Dual time-scale control framework diagram

在慢时间尺度上,上层智能体根据配电网全局运行状态,对 OLTC 分接头位置和并联电容器投切状态进行联合决策。该控制动作在当前周期内保持不变,用于确定系统基础运行方式,并降低节点电压偏差、网络损耗以及机械调压设备频繁动作带来的运行代价。在快时间尺度上,下层智能体在上层控制结果给定的条件下,依据局部运行状态执行快速调节。本文以逆变器无功调节作为快时间尺度控制的主要实现方式,通过连续调节逆变器无功输出,对分布式光伏出力波动和负荷变化引起的节

点电压偏差进行实时修正。

双时间尺度之间通过状态传递与回报聚合实现协调。具体而言,在每个慢时间尺度周期开始时,上层控制结果传递至快时间尺度,作为下层调节的已知条件;在该周期内,下层完成多步快速调节,其运行结果按时间窗口进行累计,并反馈至上层奖励构造与状态更新,从而形成“慢层确定运行边界、快层执行快速修正”的协调控制机制。在求解方法上,慢时间尺度采用 DQN 实现 OLTC 和并联电容器的离散决策,快时间尺度采用文献[12]所提出的 ASRN-MAD3PG 算法实现逆变器快速无功调节。

需要指出的是,在双时间尺度调控过程中,若慢时间尺度机械调压动作与快时间尺度逆变器无功调节缺少协调,可能引起跨时间尺度控制耦合。具体而言,OLTC 分接头调整或并联电容器投切会改变系统基础电压水平和无功潮流分布,若逆变器仍依据慢层动作前的局部状态进行无功调节,可能导致局部过调或无功补偿方向不匹配,进而引起短时电压偏差增大或网络损耗增加。为此,本文采用顺序协调与信息交互相结合的控制方式:慢层动作仅在慢时间尺度周期起始时刻执行,并在当前周期内保持不变;慢层动作执行后,将 OLTC 分接头位置和并联电容器投切状态作为上层控制信息输入快层智能体观测测量,使快层逆变器能够基于更新后的系统运行边界重新计算无功调节量;同时,快层多个快速控制步内的电压偏差和网络损耗按窗口聚合后反馈至慢层奖励函数,使慢层策略能够感知其动作对后续快层调节效果的影响,从而降低跨时间尺度控制耦合引起的性能恶化风险。

3 求解算法

3.1 慢时间尺度决策模型

慢时间尺度主要负责有载调压变压器分接头位置和并联电容器投切状态的优化决策。由于 OLTC 与并联电容器均属于典型的机械调压设备,其控制动作具有离散性、调节周期较长且频繁切换会增加设备损耗,因此本文采用 DQN 对慢时间尺度调压策略进行求解。

DQN 通过神经网络逼近状态—动作值函数,其更新过程如式(20)–(23)所示。在慢时间尺度下,系统状态、机械调压动作、即时奖励和下一状态分别记为 s_t^s 、 a_t^s 、 r_t^s 和 s_{t+1}^s 。

$$Q(s_t^s, a_t^s) = r_t^s + \gamma \max_{a_{t+1}^s} Q(s_{t+1}^s, a_{t+1}^s) \quad (20)$$

式中, γ 为折扣因子。考虑到配电网运行状态维数

较高,本文采用深度神经网络对状态—动作值函数进行近似表示,公式为

$$Q(s_t^s, a_t^s; \theta) \quad (21)$$

式中, θ 为在线 Q 网络参数。

为提高训练稳定性, DQN 采用在线网络与目标网络分离更新,其目标 Q 值为

$$y_t^s = r_t^s + \gamma \max_{a_{t+1}^s} Q(s_{t+1}^s, a_{t+1}^s; \theta^-) \quad (22)$$

式中: θ^- 为目标网络参数; y_t^s 为目标 Q 值。

相应的损失函数为

$$L(\theta) = E \left[\left(y_t^s - Q(s_t^s, a_t^s; \theta) \right)^2 \right] \quad (23)$$

通过最小化损失函数更新在线网络参数,并周期性同步目标网络参数。在训练过程中,结合经验回放机制与探索策略实现慢层控制策略的迭代更新。

对于本文的慢时间尺度调压问题, DQN 的输入为第 1.2 节定义的慢时间尺度状态变量,输出为机械调压设备的离散联合动作,包括 OLTC 分接头调整量和并联电容器投切决策。与传统仅依据单时刻运行状态构造奖励的方式不同,本文慢层奖励由快时间尺度窗口内的累计电压偏差、累计网络损耗以及机械调压设备动作代价共同构成,从而使慢层策略学习能够显著感知其动作对后续快层动态调压效果的影响,并为双时间尺度协同控制提供基础运行边界。

3.2 快时间尺度决策模型

快时间尺度主要负责逆变器群体的快速无功调节,以抑制分布式电源出力波动和负荷变化引起的节点电压偏差。考虑到逆变器无功控制具有连续动作特性,且节点间调压行为存在耦合,同时高波动工况下训练稳定性较差,本文采用 ASRN-MAD3PG 算法求解快时间尺度控制策略。该算法在多智能体确定性策略梯度框架的基础上,引入自适应噪声机制、分布式价值表示和 N 步回报估计,并结合在线/目标 Actor-Critic 网络及共享经验池,实现逆变器群体的协同无功优化。快时间尺度状态空间沿用第 1.2 节决策过程定义。对第 i 个智能体,其局部状态表示为

$$s_i^l = \{V_i, P_i, Q_i, \alpha, \beta\} \quad (24)$$

其动作输出为

$$a_i^l = \mu_i(s_i^l; \theta_i) + \varepsilon_i^l \quad (25)$$

式中: $\mu_i(\cdot)$ 为策略函数; θ_i 为 Actor 网络参数; ε_i^l 为探索噪声。

为提高复杂工况下的搜索能力,算法引入自适应噪声机制。根据奖励样本波动特征进行分组,设

第 m 组内奖励样本数为 K_m , 均值为 $\bar{r}_m$, 则其标准差为

$$\sigma_m = \sqrt{\frac{1}{K_m} \sum_{k=1}^{K_m} (r_k - \bar{r}_m)^2} \quad (26)$$

相应地, 第 m 组噪声初始幅值定义为

$$\eta_m^0 = \lambda \sigma_m \quad (27)$$

并随训练过程衰减为

$$\eta_m^t = \eta_m^0 \left(1 - \frac{t}{T}\right) \quad (28)$$

式中: λ 为比例系数; T 为总训练步数; t 为当前训练步数。根据奖励所属区间选取对应噪声强度并叠加至动作输出, 以增强高波动场景下的策略探索能力。

考虑到噪声引入后状态—动作回报具有随机性, 评价函数采用概率分布形式表示。设离散支撑集为 $\{z_j\}_{j=1}^{N_z}$, 则有

$$Z(s, a) = \sum_{j=1}^{N_z} p_j(s, a) \delta(z_j) \quad (29)$$

式中, $p_j(s, a)$ 为评价值落在支撑点 z_j 处的概率。对应的贝尔曼更新为

$$TZ = r + \gamma Z(s', a') \quad (30)$$

并利用投影算子将更新后的分布映射回预定义离散空间。在 Critic 网络训练时, 采用交叉熵损失函数更新参数。公式为

$$L(\omega_i) = CE(\hat{Z}_i, Z_i(s^l, a^l; \omega_i)) \quad (31)$$

式中: ω_i 为 Critic 网络参数; $\hat{Z}_i$ 为目标分布。Actor 网络采用确定性策略梯度进行更新, 公式为

$$\nabla_{\theta_i} J(\theta_i) = E \left[\nabla_{\theta_i} \mu_i(s_i^l; \theta_i) \nabla_{a_i} Z_i(s^l, a^l) \mid_{a_i = \mu_i(s_i^l)} \right] \quad (32)$$

为提高对长期调压效益的刻画能力, 进一步引入 N 步返回机制, 其表达式为

$$G_t^{(N)} = \sum_{k=0}^{N-1} \gamma^k r_{t+k} + \gamma^N Z(s_{t+N}, a_{t+N}) \quad (33)$$

式中, 前项为未来 N 步累积奖励, 后项为第 N 步的评价值。 N 步返回机制有助于提升策略对长期调压效益的评估能力。

对于本文的快时间尺度调压问题, ASRN-MAD3PG 输入为第 1.2 节定义的快时间尺度局部观测量, 输出为各逆变器智能体的连续无功调节动作。与传统仅依据局部量测进行快速调压的方式不同, 本文将慢时间尺度机械调压结果作为上层控制信息并入快层状态观测, 使逆变器群体能够在给定机械调压边界下执行快速无功优化; 同时, 快层多步调节结果按窗口聚合后反馈至慢层奖励构造, 从而实现双时间尺度控制过程中的信息交互与协同优化。

3.3 训练流程

双时间尺度协同训练流程如图 2 所示。训练开始时, 初始化慢层 DQN 智能体、快层 ASRN-MAD3PG 智能体及经验回放池。在每个训练回合中, 首先令慢时间尺度计数器 $t=0$ 。当 $t < T$ 时, 上层智能体根据当前全局状态生成 OLTC 分接头和并联电容器投切动作, 并在满足设备运行约束和安全约束的条件下执行该动作, 作为当前慢时间尺度周期内的基础运行方式。




图2 双时间尺度算法总体流程图

Fig. 2 Overall flowchart of the dual time-scale algorithm

在上层动作执行后, 令快时间尺度计数器 $\tau=0$ 。当 $\tau \leq n$ 时, 各下层逆变器智能体根据局部观测量及上层控制信息计算无功调节动作, 环境反馈即时奖励和下一局部状态, 并将快时间尺度交互样本存入经验回放池; 随后令 $\tau = \tau + 1$, 继续执行下一快时间尺度步, 直至当前慢时间尺度周期内的快层循环结束。

快层循环结束后, 根据该慢时间尺度周期内快时间窗口的累计运行结果构造慢层奖励, 具体包括累计电压偏差、累计网络损耗以及机械调压设备动

作代价,并将对应的慢时间尺度状态转移样本存入经验回放池。随后利用经验回放样本分别更新慢层和快层智能体网络参数,令 $t=t+1$,进入下一慢时间尺度周期。当 $t=T$ 时,当前训练回合结束,并进入下一训练回合,直至满足训练终止条件。

与传统分层独立训练不同,本文并未将慢层机械调压与快层逆变器调压割裂处理,而是通过“上层动作注入—快层多步调节—窗口回报聚合”的方式建立层间闭环:慢层动作在当前周期内保持不变并作为快层调节边界,快层多步运行结果经窗口聚合后反馈至慢层奖励构造,使慢层策略能够评价其动作对后续快层调节效果的影响,从而实现双时间尺度控制目标的一致性与策略协同优化。

4 算例分析

为验证本文所构建的基于强化学习的双时间尺度协同调压框架的有效性,本节通过数值仿真系统评估所提策略在电压质量改善、网络损耗降低以及设备动作成本控制等方面的综合性能。

4.1 实验与评估设置

本章算例仿真基于经改造的 IEEE 123 节点配电系统。为构建含多类调压设备的测试场景,在该系统中增设有载调压变压器和并联电容器组,光伏与储能的具体配置参数、各调压设备的主要参数、接入位置及运行约束见表 1。

表 1 调压装置参数 Table 1 Voltage regulating device parameters			
设备	参数	安装节点	运行限制
光伏	0.5 MW	8, 11, 16, 20, 33, 39, 48, 59, 66, 75, 83, 92, 104	—
储能	0~2 MWh	30, 41, 56	—
OLTC	$\pm 5\times 1\%$	1	4
SC	0.2 Mvar	18, 51, 61	5

本文决策时标与双时间尺度控制框架保持一致,其中慢时间尺度决策周期为 1 h,快时间尺度决策周期为 15 min。慢层用于机械调压设备控制,快层用于逆变器快速无功调节。

为比较不同控制策略的调压效果,设置 3 种对比方案:1)无主动电压调控;2)仅采用快时间尺度控制;3)慢层与快层智能体独立训练。

其中,仅快时间尺度控制策略用于分析不引入 OLTC 和并联电容器组等慢时间尺度机械调压设备时,单纯依靠逆变器无功快速调节的控制效果,从而验证慢时间尺度调压资源引入的必要性。分层独立训练策略用于分析慢层 DQN 智能体和快层 ASRN-MAD3PG 智能体在缺少上层动作注入和快层

窗口回报聚合机制时的控制效果,从而验证本文跨时间尺度协同训练机制的有效性。因此,上述两种方法分别从“是否引入慢层调压资源”和“是否进行跨时间尺度协同训练”两个角度与本文方法进行对比。

4.2 训练结果分析

图 3-4 分别给出了慢时间尺度 DQN 智能体在训练过程中的累计奖励值曲线和损失函数曲线。由图 3 可见,随着训练回合数增加,累计奖励值总体呈上升趋势,并在后期逐渐趋于稳定,表明智能体能够在与环境的持续交互过程中不断优化控制策略。由图 4 可见,损失函数在训练初期下降较快,随后波动幅度逐渐减小,并稳定在较低水平,说明网络参数更新过程逐步收敛。




图 3 DQN 奖励值
Fig. 3 DQN reward values




图 4 DQN 网络损失
Fig. 4 DQN network loss

综合图 3-4 可以看出,慢时间尺度 DQN 智能体在训练过程中具有较好的收敛特性,能够实现对慢层调压策略的有效学习,为后续双时间尺度协同控制提供慢层决策基础。

图 5 给出了典型调度日内慢时间尺度调压设备的动作结果。由图 5 可见,OLTC 分接头位置随日内运行工况变化呈现出明显的时序特征:在日间光伏出力较高时段,分接头位置整体下调;在傍晚

负荷较高时段,分接头位置相应上调。该结果表明,OLTC 能够根据日内源荷变化对系统电压水平进行动态调节。




图5 OLTC和SC输出动作
Fig. 5 OLTC and SC output actions

并联电容器组(shunt capacitor, SC)的投切结果与系统无功需求变化基本一致。在日间光伏出力较高时段,各电容器组多处于切除或较低投入状态;在傍晚负荷上升后,电容器组投入容量增加,以提供相应的无功补偿。不同电容器组之间的动作频次存在一定差异,其中节点 61 处 SC₃ 的动作次数高于 SC₁ 和 SC₂,表明不同节点调压需求具有明显差异。

综合图 5 可以看出,慢层调压设备的动作时序与日内运行工况变化具有较好对应关系,说明所得到的慢时间尺度控制策略能够根据系统运行状态对机械调压设备进行协调调节。

图 6 给出了控制前后配电网节点电压分布对比结果。由图 6(a)可知,在未采取调压措施时,部分时段馈线末端节点电压低于 0.95 p.u.,存在低电压越限现象。由图 6(b)可知,采用所提双时间尺度电压调控策略后,全网节点电压分布得到改善,各节点电压均保持在 [0.95, 1.05] p.u. 范围内,低电压越限现象得到消除。

对比控制前后电压分布可以看出,所提策略能够有效提升馈线末端节点电压水平,并增强日内各时段的电压合规性。




图6 优化后的电压分布
Fig. 6 Optimized voltage distribution

图 7 和表 2 分别给出了不同控制策略下的电压调控结果及主要性能指标。由图 7 可知,与无主动电压调控相比,各控制策略均能够改善系统电压分布,提高节点电压水平。




图7 节点电压优化结果对比
Fig. 7 Comparison of node voltage optimization results

表2 不同优化策略下的结果对比
Table 2 Comparison of results under different optimization strategies

策略	平均网损/ MW	平均电压 偏差/p.u.	OLTC 日均 动作/次	SC 日均 动作/次
无主动电压 调控	1.53	0.039	—	—
本文方法	1.42	0.024 8	4	5
仅快时间 尺度控制	1.44	0.025 8	—	—
分层独立 训练	1.45	0.024 7	5	6

由表2可知,与仅采用快时间尺度控制相比,所提策略的平均电压偏差由0.025 8 p.u.降低至0.024 8 p.u.,平均网损由1.44 MW降低至1.42 MW;与无主动电压调控相比,所提策略的平均网损由1.53 MW降低至1.42 MW,网损降低率为7.19%,高于仅快时间尺度控制策略的5.88%和分层独立训练策略的5.23%。这说明在引入慢时间尺度机械调压设备并进行双时间尺度协同训练后,系统电压调节能力和运行经济性均得到改善。

进一步比较所提策略与分层独立训练策略,两种策略在平均电压偏差上差异较小,但所提策略的平均网损更低,且OLTC与并联电容器组的日均动作次数分别为4次和5次,低于分层独立训练策略的5次和6次。若按机械调压设备总动作次数统计,所提策略的总动作次数由11次降低至9次,减少约18.18%,满足表1所设动作约束。该结果表明,在双时间尺度框架下进行协同训练,不仅能够改善电压调控效果,还能够降低网络损耗并减少机械调压设备动作频率。

需要说明的是,图7中分层独立训练策略在部分节点处的电压调节效果略优于本文方法。其主要原因在于,该策略中慢、快时间尺度智能体分别进行策略学习,缺少跨时间尺度运行信息反馈与目标协调机制,因而可能通过增加OLTC分接头调整和并联电容器组投切次数,使部分节点电压更接近参考值。但由表2可知,该策略对应的平均网损和机械调压设备动作次数均高于本文方法,表明其局部电压改善并不一定对应全局运行性能最优。相较于仅快时间尺度控制策略,本文方法引入OLTC和并联电容器组参与慢时间尺度调节,可改善系统基础电压分布并降低逆变器单独调节压力;相较于分层独立训练策略,本文方法通过上层动作注入和快层窗口回报聚合增强了慢、快层之间的信息交互与目标协调能力,能够在降低网络损耗和减少机械调压设备动作次数方面取得更优效果。由于本文方法的优化目标强调电压偏差、网络损耗和机械动作成本的综合协调,因此个别节点处的电压偏差可能不一定达到最小,但整体运行性能更优。

综合图7和表2可以看出,所提策略能够在保证节点电压合规的基础上,兼顾网络损耗降低与机械调压设备动作次数控制,体现了双时间尺度协同训练机制的综合优化效果。

5 结语

本文针对高比例分布式电源接入下配电网电

压无功协调控制问题,构建了双时间尺度电压调控模型,并建立了相应的智能求解框架。根据机械调压设备与逆变器在响应速度和控制方式上的差异,分别在慢时间尺度和快时间尺度上实施协调控制。通过上层动作传递与下层窗口回报聚合,实现了双时间尺度控制过程中的协同优化。

算例结果表明,所提双时间尺度调压策略能够在保证机械调压设备动作次数满足约束的条件下,将配电网节点电压维持在允许范围内,并改善系统电压分布。慢时间尺度控制策略能够根据日内源荷变化对OLTC和并联电容器组进行协调调节,其动作时序与系统运行工况变化具有较好对应关系。与无主动电压调控策略及仅采用快时间尺度控制策略相比,所提策略在改善电压质量的同时,能够进一步降低平均电压偏差和系统网络损耗;与分层独立训练策略相比,在平均电压偏差基本接近的条件下,所提策略具有更低的网络损耗和更少的机械设备动作次数,说明双时间尺度协同训练有助于兼顾电压调控效果与设备运行成本。

后续工作可进一步考虑分布式电源出力波动、负荷预测误差等不确定因素对控制性能的影响,并结合更大规模配电网场景和实时控制平台开展进一步验证。

参考文献

- [1] 张华赢,艾精文,汪伟.基于约束型深度强化学习的主动配电网电压控制策略[J].电测与仪表,2023,60(5):159-166.
ZHANG Huaying, AI Jingwen, WANG Wei. Active distribution network voltage control strategy based on constrained deep reinforcement learning [J]. Measurement & Instrumentation, 2023, 60(5): 159-166.
- [2] 徐衍会,崔瑞顺,刘江东,等.基于分布式光伏集群协同优化的配电网电压控制策略[J].现代电力,2023,40(2):143-152.
XU Yanhui, CUI Ruishun, LIU Jiangdong, et al. Distribution network voltage control strategy based on collaborative optimization of distributed photovoltaic clusters [J]. Modern Power, 2023, 40(2): 143-152.
- [3] 葛磊蛟,崔庆雪,李昌禄,等.计及时延的智能配电网光储就地-分布电压优化控制方法[J].电力系统保护与控制,2025,53(4):48-58.
GE Leijiao, CUI Qingxue, LI Changlu, et al. Intelligent local energy storage and distributed voltage optimization control method for distribution networks considering time delay [J]. Power System Protection and Control, 2025, 53(4): 48-58.
- [4] 顾泰宇,孙丝萝,田野,等.高比例分布式光伏并网无功电压控制方法综述[J].东北电力技术,2023,44(3):1-5.
GU Taiyu, SUN Sluo, TIAN Ye, et al. A review of reactive

- power and voltage control methods for high-penetration distributed photovoltaic grid integration [J]. Northeast Electric Power Technology, 2023, 44(3): 1-5.
- [5] 张小聪. 分布式光伏电站无功补偿装置的设计与计算[J]. 电力电容器与无功补偿, 2025, 46(3): 37-44.
- ZHANG Xiaocong. Design and calculation of reactive power compensation device for distributed photovoltaic power station[J]. Power Capacitor & Reactive Power Compensation, 2025, 46(3): 37-44.
- [6] 孙文文, 何国庆, 刘纯, 等. 含高渗透率分布式光伏的配电网电压越限解决方法研究综述[J]. 现代电力, 2024, 41(2): 302-309.
- SUN Wenwen, HE Guoqing, LIU Chun, et al. A review on methods for solving voltage limit violations in distribution networks with high-penetration distributed photovoltaics [J]. Modern Power, 2024, 41(2): 302-309.
- [7] 江金成, 彭寅章, 王尚德, 等. 特高压换流站交流滤波电容器组不平衡保护定值整定研究[J]. 电力电容器与无功补偿, 2025, 46(2): 98-105.
- JIANG Jincheng, PENG Yinzhang, WANG Shangde, et al. Research on setting calculation of unbalanced protection for AC filter capacitor bank in UHV converter station[J]. Power Capacitor & Reactive Power Compensation, 2025, 46(2): 98-105.
- [8] 李龙, 钱敏慧, 赵大伟, 等. 基于无功功率裕度分配的光伏电站静态无功/电压控制策略[J]. 电力建设, 2017, 38(10): 17-23.
- LI Long, QIAN Minhui, ZHAO Dawei, et al. Static reactive power/voltage control strategy of photovoltaic power stations based on reactive power margin allocation [J]. Power Construction, 2017, 38(10): 17-23.
- [9] 林洪, 唐人, 杨军, 等. 有源配电网改进下垂曲线无功控制策略研究[J]. 自动化仪表, 2024, 45(10): 54-59.
- LIN Hong, TANG Ren, YANG Jun, et al. Research on improved droop curve reactive power control strategy for active distribution networks [J]. Automation Instruments, 2024, 45(10): 54-59.
- [10] 李圣清, 刘博文, 李焕平, 等. 基于一致性算法光伏逆变器和储能分组协调电压控制策略[J]. 太阳能学报, 2024, 45(9): 345-352.
- LI Shengqing, LIU Bowen, LI Huanping, et al. Voltage control strategy for photovoltaic inverters and energy storage group coordination based on consensus algorithm [J]. Acta Energetica Sinica, 2024, 45(9): 345-352.
- [11] MURZAKHANOV I, GUPTA S, CHATZIVASILEIADIS S, et al. Optimal design of volt/VAR control rules for inverter-interfaced distributed energy resources[J]. IEEE Transactions on Smart Grid, 2023, 15(1): 312-323.
- [12] 黄煜, 张潇潇, 岳东, 等. 基于多智能体深度强化学习的主动配电网电压调控策略[J]. 电力系统自动化, 2025, 49(18): 65-73.
- HUANG Yu, ZHANG Xiaoxiao, YUE Dong, et al. Voltage control strategy of active distribution networks based on multi-agent deep reinforcement learning [J]. Automation of Electric Power Systems, 2025, 49(18): 65-73.
- [13] R. HOSSAIN, M. GAUTAM, M. MANSOURLAKOURAJ, et al. Soft actor critic based volt-var co-optimization in active distribution grids[C]// 2022 IEEE Power & Energy Society General Meeting (PESGM), Denver, CO, USA, 2022.
- [14] 肖寒, 李振成, 王建伟, 等. 基于数据驱动的光伏—储能主动配电网电压控制方法研究[J]. 能源与环保, 2024, 46(4): 194-199.
- XIAO Han, LI Zhencheng, WANG Jianwei, et al. Research on data-driven voltage control method for photovoltaic-storage active distribution networks [J]. Energy and Environment, 2024, 46(4): 194-199.
- [15] 高冠中, 杨胜春, 郭晓蕊, 等. 深度强化学习在含分布式柔性资源的电网优化调度中的应用研究综述[J]. 中国电机工程学报, 2024, 44(16): 6385-6403.
- GAO Guanzhong, YANG Shengchun, GUO Xiaorui, et al. A review of the application of deep reinforcement learning in power grid optimal scheduling with distributed flexible resources[J]. Proceedings of the CSEE, 2024, 44(16): 6385-6403.
- [16] Q LIU, Y GUO, L DENG, et al. Two-critic deep reinforcement learning for inverter-based volt-var control in active distribution networks[J]. IEEE Transactions on Sustainable Energy, 2024, 15(3): 1768-1781.
- [17] 朱红路, 刘珠慧. 环境因素影响下的光伏系统出力特性分析[J]. 华北电力技术, 2014(8): 50-55.
- ZHU Honglu, LIU Zhuhui. Analysis of photovoltaic system output characteristics under the influence of environmental factors [J]. North China Electric Power Technology, 2014(8): 50-55.
- [18] R. HOSSAIN, M. GAUTAM, M. MANSOURLAKOURAJ, et al. Multi-agent deep reinforcement learning-based volt-var control in active distribution grids[C]// 2023 IEEE Power & Energy Society General Meeting (PESGM), Orlando, FL, USA, 2023.
- [19] 黄煜, 李忠行, 岳东, 等. 基于双稀疏化多项式混沌展开的高维配电网风险评估方法[J/OL]. 电力系统自动化, 1-17 [2025-12-08]. <https://link.cnki.net/urlid/32.1180.tp.20251114.1340.004>.
- HUANG Yu, LI Zhongxing, YUE Dong, et al. A high-dimensional distribution network risk assessment method based on double-sparsity polynomial chaos expansion [J/OL]. Automation of Electric Power Systems, 1-17 [2025-12-08]. <https://link.cnki.net/urlid/32.1180.tp.20251114.1340.004>.

- [20]岳云峰,彭欣然,王洪庆,等.海上漂浮光伏发电技术及其融合发展展望[J].南方能源建设,2024,11(2):42-50.
YUE Yunfeng, PENG Xinran, WANG Hongqing, et al. Prospect of offshore floating photovoltaic power generation technology and its integrated development [J]. Southern Energy Construction, 2024, 11(2): 42-50.
- [21]W. LI, W. HUANG, T. ZHU, et al. Deep reinforcement learning based continuous volt-var optimization in power distribution systems with renewable energy resources[C]//2021 IEEE Sustainable Power and Energy Conference (iSPEC), Nanjing, China, 2021.
- [22]蔡雪丹,赵文会,颜俊芳.基于双注意力深度强化学习的有源配电网电压管理算法[J].上海电力大学学报,2025,41(1):35-42.
CAI Xuedan., ZHAO, Wenhui., YAN Junfang. A dual-attention deep reinforcement learning algorithm for voltage management in active distribution networks[J]. Journal of Shanghai University of Electric Power, 2025, 41(1), 35-42.
- [23]张剑,崔明建,何怡刚.结合数据驱动与物理模型的主动配电网双时间尺度电压协调优化控制[J].电工技术学报,2024,39(5):1327-1339.
ZHANG Jian, CUI Mingjian, HE Yigang. Dual-time scale voltage coordinated optimal control of active distribution networks combining data-driven and physical models[J]. Transactions of China Electrotechnical Society, 2024, 39(5): 1327-1339.
- [24]张梓泉,崔明建,张程彬,等.基于反事实多智能体强化学习和有功无功协同控制的配电网电压优化[J].电力系统保护与控制,2024,52(18):76-86.
ZHANG Zixiao, CUI Mingjian, ZHANG Chengbin, et al. Voltage optimization of distribution network based on counterfactual multi-agent reinforcement learning and active-reactive power coordinated control[J]. Power System Protection and Control, 2024, 52(18): 76-86.
- [25]黄大为,王孝泉,于娜,等.计及光伏出力不确定性的配电网混合时间尺度无功/电压控制策略[J].电工技术学报,2022,37(17):4377-4389.
HUANG Dawei, WANG Xiaoquan, YU Na, et al. Hybrid time-scale reactive power/voltage control strategy of distribution network considering uncertainty of photovoltaic output[J]. Transactions of China Electrotechnical Society, 2022, 37(17): 4377-4389.
- [26]王晴勤,温国标.基于交能融合的分布式海上风电选址与布置[J].南方能源建设,2024,11(2):59-67.
WANG Qingqin, WEN Guobiao. Site selection and layout of distributed offshore wind power based on energy and transportation integration [J]. Southern Energy Construction, 2024, 11(2): 59-67.
- [27]吴昊,张展耀,田晶.基于强化学习的主动配电网电压无功自治优化控制策略[J].电力设备管理,2025,(22):23-25.
WU Hao, ZHANG Zhanyao, TIAN Jing. Voltage and reactive power autonomous optimal control strategy of active distribution network based on reinforcement learning[J]. Power Equipment Management, 2025(22): 23-25.
- [28]李景丽,王俊诚,张建宾,等.中压配电网小电流接地系统熄弧与选线方法综述[J].电瓷避雷器,2025(4):81-99.
LI Jingli, WANG Juncheng, ZHANG Jianbin, et al. Review of arc extinguishing and fault line selection methods for small current grounding systems in medium voltage distribution networks[J]. Insulators and Surge Arresters, 2025(4): 81-99.
- [29]李宁,胡佳乐,詹晓暄,等.故障关联矩阵下弹性配电网可靠性评估[J].西安工程大学学报,2024,38(2):1-8.
LI Ning, HU Jiale, ZHAN Xiaoxuan, et al. Reliability assessment of elastic distribution network based on fault correlation matrix[J]. Journal of Xi'an Polytechnic University, 2024, 38(2): 1-8.
- [30]黄亚峰,孙博延,郝建锋,等.基于构建故障性质判据的配电网中性点动态接地系统研究[J].电瓷避雷器,2025(5):1-9.
HUANG Yafeng, SUN Boyan, HAO Jianfeng, et al. Research of neutral dynamic grounding system in distribution network based on constructing fault nature criterion[J]. Insulators and Surge Arresters, 2025(5): 1-9.
- [31]王波,季子越,汪万兴,肖朝民,张岩.柔性互联装备中零序电压注入的相间功率均衡控制[J].西安工程大学学报,2024,38(2):34-40.
WANG Bo, JI Ziyue, WANG Wanxing, XIAO Chaomin, ZHANG Yan. Phase-to-phase power balance control in flexible interconnection equipment by injecting zero sequence voltage[J]. Journal of Xi'an Polytechnic University, 2024, 38(2): 34-40.

作者简介:

许会广(1988—),男,工程师,研究方向为电力系统仿真分析。

张刘冬(1987—),男,高级工程师,研究方向为电力系统自动化。

张思源(1995—),男,工程师,通信作者,研究方向为电力系统仿真分析。E-mail: zhangsiyuan3@sgepri.sgcc.com.cn。

张天海(1989—),男,高级工程师,研究方向为网源协调技术。

李琦(1995—),男,工程师,研究方向为人工智能在电力调度控制领域的应用。