

基于改进深度强化学习理论的台区微电网 电压控制策略

张凌浩¹, 陆晓星², 肖小龙², 岳付昌³, 吴凡², 李光熹³

(1. 国网江苏省电力有限公司, 江苏 南京 210000;

2. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103;

3. 国网江苏省电力有限公司连云港供电分公司, 江苏 连云港 222004)

摘要: 分布式能源因其小规模且伴有波动性和间歇性的固有特性, 给台区微电网的运行策略设计带来了显著挑战。尽管微电网系统成功地融合了多样化的分布式能源与外部电网, 但其电压管理层面却日益复杂。鉴于此, 提出了一种基于深度强化学习理论的台区微电网实时电压控制策略。首先, 采用循环神经网络(RNN)模型, 精准识别并处理系统内源荷功率数据中的损坏与缺失部分, 确保数据质量。随后, 综合考量了电能传输过程中的线路损耗以及电压越限的潜在风险, 构建了台区微电网的电压管理模型。鉴于该模型内含复杂的非线性约束条件, 采用了改进深度强化学习算法进行高效求解, 通过 ϵ -贪婪递减策略来指导智能体的动作选择, 以克服传统方法的局限性。最后, 为了验证所提策略的有效性和可行性, 将本策略与传统控制策略进行对比测试, 结果显示, 提出电压控制策略在减小电压波动、降低网损等多个关键指标上均展现出显著优势。

关键词: 分布式能源; 微电网; 电压控制; 循环神经网络; 改进深度强化学习算法

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed26056

Voltage Control Strategy for Distribution Area Microgrids Based on Improved Deep Reinforcement Learning Theory

ZHANG Linghao¹, LU Xiaoxing², XIAO Xiaolong², YUE Fuchang³, WU Fan², LI Guangxi³

(1. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210000, Jiangsu, China; 2. Science and Technology Research Institute of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, Jiangsu, China; 3. Lianyungang Power Supply Branch of State Grid Jiangsu Electric Power Co., Ltd., Lianyungang 222004, Jiangsu, China)

Abstract: The inherent characteristics of distributed energy resources (DERs), including their small scale, volatility, and intermittency, pose significant challenges to the design of operational strategies for distribution area microgrids. Despite the successful integration of diverse DERs and external power grids within microgrid systems, voltage management has become increasingly complex. In light of this, a real-time voltage control strategy for distribution area microgrids was proposed based on deep reinforcement learning theory. Firstly, a recurrent neural network (RNN) model was employed to accurately identify and handle corrupted or missing data in the source-load power data within the system, ensuring data quality. Subsequently, a voltage management model for the distribution area microgrid was constructed, comprehensively considering line losses during power transmission and the potential risk of voltage violations. Given the complex nonlinear constraints inherent in this model, an improved deep reinforcement learning algorithm was adopted for efficient solution, and an ϵ -greedy decreasing strategy was adopted to guide the agent's action selection, overcoming the limitations of traditional methods. Finally, to validate the effectiveness and feasibility of the proposed strategy, comparative tests were conducted against traditional control strategies. The results show that the voltage control strategy presented exhibits significant advantages in multiple key indicators, including reducing voltage fluctuations and minimizing network losses.

基金项目: 国网江苏省电力有限公司科技项目(J2023167)

作者简介: 张凌浩(1975—), 硕士, 高级工程师, 主要研究方向为配电运行、配电自动化, Email: zhlh_nj@sina.com

通讯作者: 肖小龙(1990—), 博士, 高级工程师, 主要研究方向为配电自动化、分布式能源与微电网, Email: ethan518@126.com

Key words: distributed energy resources (DERs); microgrid; voltage control; recurrent neural network (RNN); improved deep reinforcement learning algorithm

随着可再生新能源发电技术和电力电子技术的迅猛进步,现代新型电力系统显著特征在于高比例新能源渗透与高度电力电子化^[1]。作为这一新型电力体系的核心构成,台区微电网扮演着促进大量新能源有效整合、助力实现碳达峰及碳中和目标的关键角色^[2]。然而,随着高占比新能源发电与多样化负荷接入的日益普遍,台区微电网在维持安全、高效、优质运行方面面临着严峻考验。具体而言,新能源与负荷两端的不匹配现象以及电力潮流的双向流动特性,显著加剧了电网系统中电压越限问题的严峻性^[3-4]。

传统电压调节装置(如有载调压变压器及并联电容器组)受限于其机械式操作机制,仅能提供非连续的、离散化的控制手段,难以实现电压的连续精准调整^[5]。此外,这些设备受制于操作次数的物理限制,投切过程耗时较长,操作策略多设计为离线预设模式^[6]。鉴于新能源发电具有显著的随机性特点,电压波动幅度较大且频繁,这对电压调节的即时响应能力提出了更为严苛的需求。

当前,针对无功-电压实时调控的挑战,两大主流策略分别是经典数学优化技术与深度强化学习技术。传统数学优化途径,通过采用诸如凸松弛技术来求解最优潮流问题^[7],旨在最小化电压偏离与网络损耗。然而,此类方法高度依赖于详尽的物理模型及精确的网络参数^[8],而现实中电网的感知能力常显不足,参数信息往往不全。此外,随着电网规模的扩张,优化问题的复杂度急剧攀升,求解过程耗时增加,限制了其在线实时应用的可行性。相比之下,深度强化学习作为一种不依赖于精确模型的数据驱动策略,展现了卓越的适应性和泛化能力。它能够从过往的交互数据中自主学习出智能体的调控策略^[9],摆脱了对精确模型参数的依赖,目前已经被广泛应用于配电网能量管理^[10]、电力市场^[11]以及需求响应^[12]等领域。更为关键的是,深度强化学习允许将繁重的训练过程移至离线环境中进行,而在实际运行时,仅需执行神经网络的快速前向计算,响应时间在ms级别,确保了极高的实时性,完美契合了无功电压控制对于在线决策的快速响应需求。在文献[13]中,研究人员设计了一种双时

间尺度电压调控策略,该策略旨在协同智能逆变器与电容器的操作。针对深度无功网络面临的维度爆炸难题,文献[14]则提出了一种新型的电压控制方案,采用深度确定性策略梯度方法提高求解效率。文献[15]提出了结合深度学习算法与二阶锥规划算法的电容器控制方法,满足长-短时间尺度的电压控制需求。在文献[16]中,通过深度神经网络构建了系统状态与离散无功补偿设备切换动作之间的映射关系,并利用深度学习技术优化了这些设备的功率输出。文献[17]针对光伏逆变器能够连续调节无功功率的特性,运用深度学习手段来控制光伏逆变器的无功输出,从而实现了电压的动态实时调控。

另一方面,关于分布式电源与可控负荷大规模接入后配电网节点电压频繁越限的难题,文献[18]依据电压灵敏度分析及越限严重集群优先处理的原则,创新性地设计了分布式储能集群的电压调节控制策略,旨在保障配电网电压安全的同时,最大化储能系统的综合效益。文献[19]则引入了一种新颖的分布式协同电压调节机制,该机制以交替方向乘子法和集中优化理论为基础,通过减少参与电压调节的智能体数量及最小化电压调节过程中的功率变动,有效降低了再调度的需求,提升了系统效率。针对高比例光伏接入引发的配电网电压质量显著下降问题,文献[20]提出了一种融合随机规划理论的两阶段电压优化策略,旨在应对配电网系统的不确定性。此外,文献[21-23]集中探讨了基于鲁棒优化理论的电压控制方法,这些方法在不确定性的最坏情况边界内实现配电网电压的优化调控,有效解决了由负荷波动和光伏快速变化引起的电压越限挑战。这些方法依据光伏逆变器的最大可用无功容量来合理分配所需的无功功率,促进了电压调节资源的高效、合理调配,确保了配电网的稳定运行。

尽管深度学习在电力系统应用中展现出显著成效,但当其应用范围扩展至大规模配电网时,面临挑战,难以有效实现电压稳定与损耗降低的双重目标。特别是在应对台区微电网这一复杂多变环境时,传统模型因其处理能力受限,导致控制效果不尽如人意。这些传统方法往往仅对区域节点的状态向量进行基础拼接,忽略了

关键特征的深度提取,进而增加了策略学习的难度,并且未能充分捕捉新能源发电与负荷变化的时序特性。此外,现有方法在训练过程中的收敛速度迟缓,制约了计算效率的提升。鉴于此,本文提出了一种基于优化深度强化学习框架的台区微电网电压控制新策略。本文的主要创新点包括以下两点:

1)考虑到微电网复杂运行工况和完全信息的难以获取,本文首先利用Seq2Seq模型对台区微电网中的源荷功率数据进行精准预处理,有效识别并修复数据中的损坏与缺失部分,从而确保数据质量。

2)针对台区微电网电压管理模型中的复杂非线性约束条件,本文采用了经过改进的深度强化学习算法进行高效求解。通过引入 ϵ -贪婪递减策略来指导智能体的动作选择,克服了传统方法在求解此类问题时的局限性。

全文的结构安排如下:首先利用循环神经网络(RNN)模型精准识别并修复系统中源荷功率数据中的异常与缺失,确保数据质量。随后,综合考量电能传输过程中的线路损耗风险与电压越限可能性,构建了台区微电网的精细化电压管理模型。鉴于该模型内含复杂的非线性约束条件,本文引入了改进的深度强化学习算法进行高效求解,以克服传统方法的局限性。在算例分析部分,将本文提出的控制策略与常规算法进行对比测试,结果显示,本文策略在减少电压波动、降低网络损耗等方面展现出显著优势,从而验证了其有效性与实用性。

1 基于RNN模型的源荷损坏数据提取

鉴于极端气候条件和设备自然老化所引发的问题,台区微电网中经由两侧设备汇聚的源荷功率数据常出现损坏或缺失的情况。考虑到源荷功率数据固有的时序性特点,本节研究首先采用了RNN模型来进行数据修复。在本文中,Seq2Seq模型作为RNN的一种高级形式,被选中解决此问题。与传统神经网络不同,后者在处理数据时,各元素被视为独立单元,通过全连接结构在层间传递信息,而层内节点间则无直接交互^[24]。然而,在处理时间序列数据时,由于各时间点的数据间存在内在联系,传统神经网络架构难以捕捉对应特征。因此,在图1所展示的循环神经网络架构

下,数据按时间顺序依次输入,利用隐藏层状态记忆前一时刻的信息,从而有效捕捉并建模数据间的时序依赖性,Seq2Seq模型能够从已有的数据中自动学习到数据的时序性和潜在模式,这使得它能够在缺失或损坏的数据点上生成合理的预测值^[25]。相较于RNN模型,Seq2Seq模型在处理长距离依赖关系时表现更好。它能够捕捉到输入序列中距离较远的元素之间的关联,以实现损坏或缺失数据的精准修复。




图1 循环神经网络典型结构图

Fig.1 The typical structure diagram of RNN

从图1中可以看出,RNN网络同样包括输入层 x 、隐藏层 h 、输出层 y ,且不同的隐藏层之间相互连接。对于 t 时刻隐藏层的状态 h_t ,有:

$$h_t = f(Ux_t + Ws_{t-1}) \quad (1)$$

此时, t 时刻的输出 y_t 应满足下式:

$$y_t = g(Vh_t) \quad (2)$$

在此网络模型中, U, W, V 表示信号传递过程中的共通参数角色,促进信息在网络中的流通。而 f 和 g 分别为隐藏层与输出层中激活函数,对输入信号进行非线性变换。观察图1所示的经典RNN架构,可以发现其设计假设输入与输出序列具有相同的维度,这一特性并不契合当前讨论的应用场景需求。鉴于此,本文采用了Seq2Seq网络架构作为解决方案,其基础结构如图2所示,该架构能够灵活处理输入与输出序列维度不一致的情况。




图2 Seq2Seq网络结构图

Fig.2 The structure diagram of Seq2Seq network

Seq2Seq架构由两大核心组件构成:编码器Encoder与解码器Decoder。在任意时间步 t ,Seq2Seq机制将输入序列 $X=\{x_1, x_2, \dots, x_m\}$ 按顺序逐一送入编码器的接收端。编码器内部预设了一系列非线性转换单元,这些单元对输入序列进

行处理,生成并保存一个中间向量。紧接着,解码器基于该中间向量及前 N 个时间步($t-1, t-2, \dots, t-N$)的输出结果,计算出当前时间步 t 的输出 y_t 。Seq2Seq模型的这一工作流程可以通过下式来形式化描述:

$$\begin{cases} \mathbf{c} = f(x_1, x_2, \dots, x_m) \\ \mathbf{y}_t = g(\mathbf{c}, y_1, y_2, \dots, y_{t-1}) \end{cases} \quad (3)$$

式中: \mathbf{c} 为上下文向量,由编码器生成,可捕获输入序列的所有信息,用于帮助解码器生成输出序列。

观察式(3),通过集成编码器和解码器的设计,Seq2Seq模型实现了输入输出序列长度的灵活性调整,这一特性确保了RNN网络在电力预测等多样化场景中的适用性。编码器的非线性变换机制可根据具体RNN网络的应用背景进行灵活配置,本文特别选用了GRU作为变换函数。GRU内部集成了三个关键门控机制:重置门 r 、输出门 h 以及更新门 z ,它们共同协作,调控信息的流动与更新过程,具体流程简述如下:

$$\begin{cases} r_t = \sigma(\mathbf{W}_r x_t + \mathbf{U}_r h_{t-1} + b_r) \\ z_t = \sigma(\mathbf{W}_z x_t + \mathbf{U}_z h_{t-1} + b_z) \\ h_t^1 = \tanh[\mathbf{W}_h x_t + \mathbf{U}_h (r_t h_{t-1}) + b_h] \\ h_t = (1 - z_t) h_{t-1} + z_t h_t^1 \end{cases} \quad (4)$$

式中: r_t, z_t, h_t 为时间 t 的重置门、更新门、输出门; σ 为sigmoid激活函数,将输出限制在0到1之间; $\mathbf{W}_r, \mathbf{W}_z, \mathbf{W}_h$ 为重置门、更新门和输出门的权重矩阵; $\mathbf{U}_r, \mathbf{U}_z, \mathbf{U}_h$ 分别为受前一时间步输出影响的权重矩阵; \tanh 为双曲正切激活函数,用来将输出限制在-1到1之间; b_r, b_z, b_h 分别为重置门、更新门和输出门的偏置项; h_t^1 为时间步 t 的候选隐藏状态。

2 面向台区微电网的电压控制模型

2.1 目标函数及约束

在台区微电网的运行框架内,实时无功电压管理策略聚焦于通过整合与协调无功补偿设备,在预先制定的日调度计划框架内,实施更为细致的微调。此策略的核心目的在于优化电压质量,确保稳定性,并同步降低电网运行过程中的能量损耗,如下式所示:

$$\min \sum_{t=1}^T \sum_{i=1}^N (C_{\text{Loss}} P_{\text{Loss},t} + C_a \Delta U_{i,t}) \quad (5)$$

式中: N 为系统中所包含的全部节点数目; C_{Loss} 为单位网损经济惩罚系数; $P_{\text{Loss},t}$ 为在第 t 个时刻台

区微电网网损; C_a 为电压偏离设定值时的经济惩罚系数; $\Delta U_{i,t}$ 为第 i 个节点在 t 时刻的电压偏离量。

此模型需要考虑的约束条件包括:

1)电压幅值约束:

$$U_{i,t}^{\min} \leq U_{i,t} \leq U_{i,t}^{\max} \quad (6)$$

式中: $U_{i,t}^{\min}, U_{i,t}^{\max}$ 分别为第 i 个节点在 t 时刻电压的最小允许值和最大允许值。

2)新能源出力约束。在本文中,台区微电网中考虑的新能源类型主要是小容量的分布式光伏,光伏出力应满足下列约束:

$$P_{\text{pv},t}^{\min} \leq P_{\text{pv},t} \leq P_{\text{pv},t}^{\max} \quad (7)$$

$$Q_{\text{pv},t}^{\min} \leq Q_{\text{pv},t} \leq Q_{\text{pv},t}^{\max} \quad (8)$$

式中: $P_{\text{pv},t}^{\min}, P_{\text{pv},t}^{\max}$ 分别为光伏系统的最小有功功率输出和最大有功功率输出; $Q_{\text{pv},t}^{\min}, Q_{\text{pv},t}^{\max}$ 分别为光伏系统的最小无功功率输出和最大有功功率输出。

3)光伏系统容量和输出功率约束:

$$Q_{\text{pv},t}^2 \leq S_{\text{pv}}^2 - P_{\text{pv},t}^2 \quad (9)$$

式中: S_{pv} 为光伏逆变器的额定容量。

4)有功-无功潮流平衡约束:

$$\begin{cases} P_{G,i} - P_{L,i} = U_i \sum_{j=1}^n U_j (G_{ij} \cos \delta_{ij} + B_{ij} \sin \delta_{ij}) \\ Q_{G,i} - Q_{L,i} = U_i \sum_{j=1}^n U_j (G_{ij} \sin \delta_{ij} - B_{ij} \cos \delta_{ij}) \end{cases} \quad (10)$$

式中: $P_{G,i}, Q_{G,i}$ 分别为系统内第 i 个节点的有功功率和无功功率; $P_{L,i}, Q_{L,i}$ 分别为第 i 个负荷节点的有功负荷和无功负荷; G_{ij}, B_{ij} 分别为第 i 个节点和第 j 个节点之间的电导和电纳; δ_{ij} 为第 i 个和第 j 个节点电压相角差。

2.2 求解算法

由于潮流方程的约束,台区微电网的电压调控数学模型展现出非线性和非凸性的复杂特性,传统求解策略在精确度和效率上遭遇瓶颈,难以确保解的最优化。鉴于此,本文引入了改进后的深度学习理论作为解决策略。作为机器学习领域内的一种先进范式与策略制定工具,深度学习旨在通过智能体与环境间的动态交互,学习并优化策略,以期实现最大化累积回报或达成预设目标。如图3所示,此过程通常借助马尔可夫决策过程模型进行形式化描述,该模型由五个核心元素构成:状态集(S)、动作集(A)、状态转移概率(P)、折扣因子(γ)及奖励函数(R),共同形成了一个五元组(S, A, P, γ, R)的系统框架。如图3所示,在特定环境中,智能体首先感知当前状态 S_t ,

随后基于该状态生成并执行动作 A_t 。环境响应该动作,更新至新状态 S_{t+1} ,并反馈给智能体一个即时的奖励 R_t ,以评估该动作的效果。智能体的核心目标是通过连续不断的交互与学习,优化其决策过程,从而最大化从环境中累积获得的奖励,实现总体效益的最优化。




图3 深度学习示意图

Fig.3 Diagram of deep learning

在寻求解决方案的初始阶段,采用马尔科夫决策过程模型进行系统化构建是必要的步骤。这一过程包括通过评估电气距离,将一个大型电网系统细分为多个小型区域,旨在缩减模型处理的复杂性和规模。电气距离作为度量工具,能有效反映电网内节点间电气相互依赖的强度;具体来说,当两个节点间的电气距离较近时,它们之间的电气耦合效应更为显著。鉴于台区微电网拓扑结构的自然稀疏特性,引入“邻域”的概念来进一步分析:对于任意分布式电源节点 i ,其邻域 $N(i)$ 被定义为所有通过路径直接连接至 i 且路径上不含其他分布式电源节点的节点集合。基于这一邻域定义,可以决策聚集那些在电气上高度耦合的节点,同时分离那些耦合性较弱的节点,从而将整个配电网划分为多个独立的子区域。这一划分策略有效地将原本复杂的台区微电网无功-电压控制问题转化为一系列在小范围内更易处理的优化问题。

马尔科夫博弈过程由以下部分简要描述:

1) 状态空间 S_t : S_t 代表了在任意时间点 t ,所有智能体所处的状态汇总。每个智能体的状态具体由其关联的光伏逆变器接入节点的有功功率需求、无功功率需求、光伏逆变器的实际有功输出功率以及相应节点的电压水平共同确定。

2) 协同动作集合 A_t : A_t 是指在特定时刻 t ,所有智能体所采取的动作的集合。这些动作特指每个智能体通过调整其光伏逆变器的无功功率输出来实现的控制措施。

3) 即时回馈函数 R_t :为了引导决策过程,将台区微电网无功-电压控制目标函数的负值设定为每一步决策的即时奖励 R_t 。这一设计旨在通过最大化累积奖励来间接最小化原目标函数,从而优化控制效果。

在智能体与环境互动的过程中,其目标是最大化获取的奖励,以确保在特定无功控制算法下,配电网系统能够运行于最优状态。为了加速优化过程的收敛,本文在传统模型基础上融入了探索与利用的平衡机制。探索旨在拓宽对环境未知信息的了解,而利用则侧重于根据现有知识来最大化奖励。然而,过度的探索可能导致算法效率降低且效果打折,而过度的利用则可能使算法局限于局部最优解。因此,在强化学习算法的应用中,如何巧妙地调整探索与利用之间的平衡,成为了一个核心挑战。本文区别于传统的 ϵ -贪婪策略,创新性地采用了 ϵ -贪婪递减策略来指导智能体的动作选择,其中 ϵ 作为贪婪因子的调节参数。在决策时,智能体首先依据 ϵ 的概率随机从动作集中挑选动作,进行广泛的探索;而剩余 $1-\epsilon$ 的概率则用于选择预期奖励最高的动作。在训练初期,通过设定较高的 ϵ 值,智能体能够更频繁地尝试新动作,探索可能的更优解,以期在长期内获得更高的累积奖励。随着训练进程的推进, ϵ 值逐渐减小,智能体逐渐偏向于选择当前已知的最优动作,有效利用了已积累的经验知识。 ϵ 的具体数学表示形式已在下式中详细给出,该策略通过动态调整探索与利用的比例,促进了算法的高效与稳定收敛。

$$\epsilon = \max \left\{ 0.1, \epsilon_0 - 2 \frac{k}{K_{total}} \right\} \quad (11)$$

式中: ϵ_0 为贪婪因子的初始值; k 为当前训练次数; K_{total} 为最大训练次数。

需要说明的是,在智能体学习的初期, ϵ -贪婪递减策略中的 ϵ 值较大,这意味着智能体以较高的概率随机选择动作,而不是总是选择当前认为最优的动作。这种随机性有助于智能体探索环境,发现新的状态-动作对,并收集更多的学习经验。随着学习的进行, ϵ 值逐渐减小,智能体以越来越高的概率选择当前认为最优的动作。这一阶段,智能体主要利用已学习的知识来优化其策略,以期获得更高的奖励。通过引入随机性, ϵ -贪婪递减策略允许智能体在探索阶段尝试不

同的动作,从而有可能跳出局部最优解。随着 ϵ 值的递减,智能体在利用阶段越来越专注于选择最优动作,这有助于加快学习速度,使智能体能够更快地收敛到最优策略。

3 算例验证

3.1 测试系统介绍

本文利用IEEE 33节点测试系统作为验证案例。该系统内特定节点(即14号、18号、26号节点)均配置了1.5 MW容量的分布式光伏系统,具体拓扑结构如图4所示。




图4 改进的IEEE 33节点系统拓扑图

Fig.4 Topology diagram of modified IEEE 33-node system

基准电压设定为12.66 kV,而根节点的电压基准值设置为1.00(标幺值),系统安全运行的电压范围界定在0.95(标幺值)至1.05(标幺值)之间。光伏输出功率数据源自欧洲能源部门提供的实时地区电网信息,而负荷数据则取自中国广东省某地区的实际记录。研究选取了覆盖全年的数据集,其中240 d的数据被划分为训练集,剩余部分作为测试集使用。调度任务以24 h为周期,每小时进行1次调度决策。在仿真环境的构建上,结合德国电网的光伏发电数据与西班牙电网的负荷数据,并通过引入标准差为0.1的高斯噪声,模拟实际电网运行中的波动情况。在学习训练阶段,算法共进行了400个回合的迭代,关键参数配置包括:批量大小决定了每次训练迭代中使用的数据数量,本文中取值为128;经验回放池容量是指当前数据结构能够存储的最大经验数据数量,在本文中取值为4 800;折扣因子决定了未来奖励在当前时刻的价值,本文取值为0.99;每次迭代步长为200;学习率决定了模型参数在每次更新时的步长大小,本文设置值为0.000 08。这样的参数配置旨在促进数据的有效利用与分布的均衡性,进而帮助智能体更有效地适应并优化电网的运行状态。此仿真平台的设计初衷在于评估深度强化学习技术在应对电网电压控制问题中的实际应用效果,特别是在考虑光伏发电与负荷变化的波动性时,能够有效模拟电网运行

的不确定性。通过这一平台,可以为控制策略的验证与优化提供一个全面而真实的测试环境。所有仿真程序均基于Matlab 2014b软件平台开发,并在配备Intel i5 7300hq处理器(2.4 GHz)、8 GB内存的计算机上运行。

3.2 电压管理结果分析

本文算法的训练过程如图5所示。可以观察到274个迭代步次后累计奖励开始收敛,保持在稳定水平,此时模型达到最佳训练效果。




图5 算法迭代收敛效果图

Fig.5 Algorithm iteration convergence effect diagram

为了凸显所提出方法的效能,将其与经典的 $Q-V$ 下垂控制法、无控制方案以及传统的深度学习技术进行了全面对比。

根据表1及图6所呈现的数据,该方法在电压稳定调控及网络损耗削减方面展现出了明显的优越性。具体而言,该策略在电压管理上达到了平均电压偏差仅为0.004 62(标幺值)的最低水平,且其处理速度仅需42 ms,相较于其他对比方法均展现出更为出色的性能,能够更高效地应对无功-电压控制中的分布式电源出力波动问题,满足在线控制的快速需求。

表1 不同控制策略结果对比

Tab.1 Comparison of results from different control strategies

控制策略	电压最大值 (标幺值)	电压最小值 (标幺值)	平均计算 时间/ms	平均网损/ kW
本文方法	1.004 59	0.995 32	42.3	923.7
$Q-V$ 下垂 控制策略	1.009 19	0.990 69	84.5	1 154.6
无控制策略	1.034 72	0.960 95	75.1	1 052.3
传统深度 学习策略	1.034 73	0.965 32	59.4	962.8

观察结果显示,光伏的大规模并网会引发节点电压出现显著波动现象。若缺乏及时的调控手段,光伏输出过剩将造成负荷吸纳能力不足,进而触发潮流反向流动,最终导致节点电压超出




图6 不同控制策略下24 h电压平均值

Fig.6 Average voltage over 24 h under different control strategies
安全阈值。本文提出的算法有效地将节点电压维持在安全操作区间内,显著优化了配电网的电压分布曲线。进一步地,该策略在降低网络损耗方面表现出卓越性能,相较于 $Q-V$ 下垂控制方法和传统学习方法,分别实现了20.0%和4.1%的网损减少,这充分验证了其在配电网无功电压管理领域的应用效果与经济价值。通过上述对比分析, $Q-V$ 下垂控制策略本质上是一种基于下垂特性的控制方法,通过调整逆变器的输出电压和电流来实现对微电网电压的控制。这种方法通常依赖于系统的稳态特性和下垂曲线的设置,对于动态变化的微电网环境可能不够灵活。 ϵ -贪婪递减策略改进的深度强化学习策略能够通过学习不断优化策略,逐渐逼近最优解。 $Q-V$ 下垂控制策略的收敛速度可能受到系统参数和下垂曲线设置的影响,收敛速度相对较慢。此外, $Q-V$ 下垂控制策略可能受到系统动态特性和外部干扰的影响,导致电压波动相对较大。相比之下,本文所提出的电压控制策略在台区微电网系统的整体效能与运行稳定性方面具有明显优势。

另一方面,为了进一步验证本文所提策略的鲁棒性,在改进的IEEE 33节点系统的测试中,通过巧妙地调整年度周期内光伏发电的最大输出与电力负荷峰值的比例,设计了五个不同水平的新能源高渗透率测试场景,测试结果如图7所示。本文所提模型展现出了突出的适应性,即便是面对不同规模的光伏供给波动,也能保持高效运行。尤为值得注意的是,随着系统中新能源渗透率的逐步攀升,逆变器作为关键调控元件,其调节容量的显著提升成为了提升无功补偿能力与系统电压稳定性的重要推手。即便是在光伏输出急剧增长、对电网造成额外压力的极端场景下,本文方法依然能够保持电压控制策略的高效

与精准,体现了对复杂配电网环境变化的强适应性和稳定性。综上所述,本研究不仅为新能源高渗透率下的配电网优化提供了有力支持,也为未来智能电网的发展探索了一条可行的技术路径。




图7 不同光伏渗透率下的最大电压偏差与网损情况

Fig.7 Maximum voltage deviation and network loss under different photovoltaic penetration rates

4 结论

本文针对分布式能源在台区微电网中因其固有的小规模、波动性和间歇性特性所带来的运行策略设计挑战,提出了一种创新的基于深度强化学习理论的实时电压控制策略。所提策略可有效应对微电网电压管理的复杂性,为台区微电网的稳定运行提供了新的解决思路。首先,通过引入RNN模型,本文解决了分布式能源源荷功率数据中普遍存在的损坏与缺失问题,显著提升了数据质量,为后续精确分析与控制奠定了基础。其次,在构建台区微电网电压管理模型时,本文全面考虑了电能传输过程中的线路损耗以及电压越限风险;针对模型中的复杂非线性约束条件,采用了改进的深度强化学习算法进行求解。这一算法不仅克服了传统方法在处理复杂优化问题时的局限性,还通过深度强化学习的自学习能力,实现了对微电网电压控制的动态优化与实时调整。实验结果表明,该算法在提升求解效率与准确性方面表现出色,为微电网电压控制策略的实施提供了强有力的技术支持。

参考文献

[1] 刘小多,李君,林堂茂. 基于新型电力系统的石化新能源云平台[J]. 电气时代,2024(6):50-54.
LIU Xiaoduo, LI Jun, LIN Tangmao. A petrochemical renewable energy cloud platform based on new power system[J]. Electrical Age, 2024(6):50-54.
[2] 张伟,王志东,贾琼. 基于分布式滑模控制的微电网二级电

- 压控制策略[J]. 电工电气, 2024(6):29-34.
- ZHANG Wei, WANG Zhidong, JIA Qiong. Secondary voltage control strategy for microgrids based on distributed sliding mode control[J]. *Electrotechnic Electric*, 2024(6):29-34.
- [3] 刘晓明, 胡丽娟, 赵凤展, 等. 微电网运行控制关键技术评价[J]. 电器与能效管理技术, 2024(5):1-9.
- LIU Xiaoming, HU Lijuan, ZHAO Fengzhan, et al. Operation control key technology evaluation of microgrid[J]. *Electrical & Energy Management Technology*, 2024(5):1-9.
- [4] 李有亮, 刘航, 王波, 等. 交直流混合微电网母线电压波动抑制策略[J]. 电力电子技术, 2024, 58(4):105-108.
- LI Youliang, LIU Hang, WANG Bo, et al. A bus voltage fluctuation suppression strategy for AC/DC hybrid microgrid[J]. *Power Electronics Technology*, 2024, 58(4):105-108.
- [5] 程启明, 沈章平, 张家领, 等. 基于MAS的多电力弹簧分布式协同控制策略[J]. 电力自动化设备, 2024, 44(1):111-118.
- CHENG Qiming, SHEN Zhangping, ZHANG Jialing, et al. Multi-electric spring distributed cooperative control strategy of multiple power springs based on MAS[J]. *Electric Power Automation Equipment*, 2024, 44(1):111-118.
- [6] 王浩, 聂晶莹, 李斌, 等. 基于分数阶滑模的混合微电网接口变换器电压稳定控制[J]. 电力系统及其自动化学报, 2024, 36(4):141-149.
- WANG Hao, NIE Jingying, LI Bin, et al. Voltage stability control of hybrid microgrid interface converter based on fractional-order sliding mode[J]. *Proceedings of the CSEE*, 2024, 36(4):141-149.
- [7] 张宇精, 乔颖, 鲁宗相, 等. 含高比例分布式电源接入的低感度配电网电压控制方法[J]. 电网技术, 2019, 43(5):1528-1535.
- ZHANG Yujing, QIAO Ying, LU Zongxiang, et al. Voltage control for partially visible distribution network with high DG penetration[J]. *Power System Technology*, 2019, 43(5):1528-1535.
- [8] 王颖, 文福拴, 赵波, 等. 高密度分布式光伏接入下电压越限问题的分析与对策[J]. 中国电机工程学报, 2016, 36(5):1200-1206.
- WANG Ying, WEN Fushuan, ZHAO Bo, et al. Analysis and countermeasures of voltage violation problems caused by high-density distributed photovoltaic[J]. *Proceedings of the CSEE*, 2016, 36(5):1200-1206.
- [9] 张红亮, 闫丹. 电力用户用电信息采集系统应用现状[J]. 电子技术与软件工程, 2015(18):200-203.
- ZHANG Hongliang, YAN Dan. Application status of power user information acquisition system[J]. *Electronic Technology & Software Engineering*, 2015(18):200-203.
- [10] 郭国栋, 龚雁峰. 电力市场环境下基于深度强化学习的微网能量管理系统实时自动控制算法[J]. 电测与仪表, 2021, 58(9):78-88.
- GUO Guodong, GONG Yanfeng. Real-time automatic control algorithm for microgrid energy management system based on deep reinforcement learning in the electric power market environment[J]. *Electrical Measurement & Instrumentation*, 2021, 58(9):78-88.
- [11] 郭贺宏, 武灵耀, 赵庆生, 等. 基于趋势指标与长短时记忆网络的电力市场日前电价预测[J]. 智慧电力, 2022, 50(9):97-103.
- GUO Hehong, WU Lingyao, ZHAO Qingsheng, et al. Day-ahead electricity price forecasting in the electric power market based on trend indicators and long short-term memory networks[J]. *Smart Power*, 2022, 50(9):97-103.
- [12] 马天男, 王超, 彭丽霖, 等. 计及需求响应和深度结构多任务学习的电力系统短期负荷预测[J]. 电测与仪表, 2019, 56(16):50-60.
- MA Tiannan, WANG Chao, PENG Lilin, et al. Short-term load forecasting for power systems considering demand response and deep structural multi-task learning[J]. *Electrical Measurement & Instrumentation*, 2019, 56(16):50-60.
- [13] YANG Q, WANG G, SADEGHI A, et al. Two-time scale voltage control in distribution grids using deep reinforcement learning[J]. *IEEE Transactions on Smart Grid*, 2020, 11(3):2313-2323.
- [14] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. *IEEE Transactions on Power Systems*, 1989, 4(2):1401-1407.
- [15] 林俐, 马笑寒, 丁文敏. 计及构网型储能电站的新能源基地无功协调优化控制[J]. 电力系统自动化, 2025, 49(1):59-68.
- LIN Li, MA Xiaohan, DING Wenmin. Coordinated optimal reactive power control of renewable energy bases considering grid-forming energy storage stations[J]. *Automation of Electric Power Systems*, 2025, 49(1):59-68.
- [16] 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 Qi, QIAO Ying, ZHANG Yujing. Continuous reactive power optimization of distribution networks using deeping reinforcement learning[J]. *Power System Technology*, 2020, 44(4):1473-1480.
- [17] 全歆, 彭显刚, 刘涵予, 等. 基于深度强化学习的配电网实时电压优化控制方法[J]. 电网技术, 2023, 47(5):2029-2038.
- QUAN Huan, PENG Xiangang, LIU Hanyu, et al. Voltage optimization control method for distribution networks based on deep reinforcement learning[J]. *Power System Technology*, 2023, 47(5):2029-2039.
- [18] 肖伟. 电力用户用电信息采集系统在智能电网中的应用研究[J]. 电子世界, 2020(11):208-209.
- XIAO Wei. Research on the application of power user information acquisition system in smart grid[J]. *Electronics World*, 2020(11):208-209.
- [19] 龚成尧. 基于交替方向乘子法的主动配电网分布式多目标优化调度[D]. 北京:华北电力大学(北京), 2017.
- GONG Chengyao. Distributed multi-objective optimal scheduling of active distribution network based on alternating direction method of multipliers[D]. Beijing: North China Electric Power

