

# 基于图深度强化学习的有源配电网故障恢复方法

何小龙<sup>1</sup>, 高红均<sup>1</sup>, 王仁浚<sup>1</sup>, 罗龙波<sup>2</sup>, 叶萌<sup>2</sup>, 黄媛<sup>1</sup>, 刘俊勇<sup>1</sup>

(1. 四川大学电气工程学院, 四川省 成都市 610065;

2. 广东电网有限责任公司广州供电局, 广东省 广州市 510630)

## Fault Recovery Method of Active Distribution Network Based on Graph Deep Reinforcement Learning

HE Xiaolong<sup>1</sup>, GAO Hongjun<sup>1</sup>, WANG Renjun<sup>1</sup>, LUO Longbo<sup>2</sup>, YE Meng<sup>2</sup>, HUANG Yuan<sup>1</sup>, LIU Junyong<sup>1</sup>

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, Sichuan Province, China;

2. Guangzhou Power Supply Bureau of Guangdong Power Grid Co., Ltd., Guangzhou 510630, Guangdong Province, China)

**ABSTRACT:** The topology of the distribution network changes frequently, and the uncertainty of load level and distributed generator (DG) output makes the operation scenarios more complex and variable. Based on this, a fault recovery method for an active distribution network based on graph deep reinforcement learning is proposed. Firstly, considering the time-varying characteristics of DG and load, a fault recovery framework for the distribution network based on the graph attention network (GAT) and the soft actor-critic (SAC) algorithm is constructed. The fault recovery method and its algorithm principle are introduced. Then, a graph deep reinforcement learning model for distribution network fault recovery is established. By embedding GAT into the pre-neural network of the SAC algorithm, the agent's perception ability of the distribution network operation status and topology is improved, and an invalid action masking mechanism is innovatively introduced to avoid illegal actions. Through the interaction between the agent and the environment, the optimal switch action control strategy is found to realize the optimal learning of recovery under high DG penetration. Finally, the proposed method is verified on IEEE 33-bus and 148-bus examples. Compared with multiple baseline methods, the proposed method can achieve the fastest fault recovery at the millisecond level, and has a more efficient and superior recovery effect, the load supply rate under topology change increased by 4% to 5% compared with the benchmark model.

**KEY WORDS:** active distribution network; distribution generator; fault recovery; graph attention network; soft actor-critic; invalid action masking

**摘要:** 配电网的拓扑结构变动频繁, 负荷水平和分布式电源

(distributed generator, DG) 出力的不确定性使得运行场景愈加复杂多变。基于此, 提出了一种基于图深度强化学习的有源配电网故障恢复方法。首先, 考虑 DG 与负荷的时变性, 构建起基于图注意力网络(graph attention network, GAT)与柔性策略-评价(soft actor-critic, SAC)算法相结合的配电网故障恢复框架, 介绍故障恢复方法及其算法原理。然后, 建立面向配电网故障恢复的图深度强化学习模型, 通过将 GAT 嵌入到 SAC 算法的前置神经网络来提高智能体对配电网运行状态和拓扑结构的感知能力, 并创新性地引入无效动作掩盖机制以规避非法动作, 通过智能体与环境进行交互, 寻找最优开关动作控制策略, 实现高渗透率 DG 接入下的故障恢复趋优学习。最后, 在 IEEE33 节点和 148 节点算例进行验证, 并与多种基线方法进行对比测试, 所提方法可以实现最快毫秒级故障恢复, 具有更加高效优越的恢复效果, 在拓扑变动下的负荷供电率相较于基准模型提升了 4%~5%。

**关键词:** 有源配电网; 分布式电源; 故障恢复; 图注意力网络; 柔性策略-评价; 无效动作掩盖

**DOI:** 10.13335/j.1000-3673.pst.2024.2215

## 0 引言

我国的配电网通常采用辐射状拓扑, 网络结构采用“开环运行, 闭环设计”的理念。当配电网发生故障并被继电保护装置切除后, 故障下游用户因失去电源连接从而导致不同面积范围的停电, 需要进行故障恢复及时向下游失电负荷恢复供电<sup>[1]</sup>。故障恢复通过联络开关和分段开关的不同组合倒闸操作, 重新建立网络拓扑连接关系以恢复电源与失电负荷之间的电能输送<sup>[2]</sup>。随着“双碳”这一重大战略目标的部署和实施, 传统电力系统逐渐向以新能源为主体的新型电力系统进行转型, 配电网作为电力系统的重要环节, 风电、光伏等分布式电源(distributed generator, DG)在配电网中的渗透率将

基金项目: 国家自然科学基金项目(52077146)。

Project Supported by National Natural Science Foundation of China (52077146).

会越来越大, DG 的接入使得配电网从单电源供电系统转变为多端有源系统, DG 作为辅助电源在配电网故障恢复的过程中提供了一定的电源和电压支撑能力, 失电负荷可以通过主网和 DG 协同配合供电进行转供, 并且 DG 可以有效提升末端部分节点电压, DG 的接入使得配电网的运行方式发生了较大的改变。因此, 研究有源配电网的故障恢复方法是相当有必要的。

目前不少专家对配电网故障恢复开展了大量研究工作, 主要分为人工智能方法<sup>[1-6]</sup>、数学优化方法<sup>[7-10]</sup>和启发式算法<sup>[11-12]</sup>。然而数学优化方法在建立显式模型时会产生大量的决策变量, 当其应用于大规模系统时容易遇到“维度灾难”问题使得结果不收敛, 导致其可扩展性较差<sup>[13]</sup>。启发式算法虽然以其在处理大规模复杂问题时的有效性而受到青睐, 但是求解效果严重依赖于规则的制订以及参数初值的选取, 容易陷入局部最优。上述两种传统算法都需要耗费大量时间进行寻优迭代, 导致求解效率低下, 难以满足电网的实时运行调度需求。

基于深度强化学习 (deep reinforcement learning, DRL) 的无模型算法通过离线训练的方式不断与环境进行端到端的交互学习<sup>[5]</sup>, 实现经验的逐渐积累和策略的趋优更新, 避免了基于模型的算法可能存在的病态无解和局部最优问题<sup>[14]</sup>, 训练收敛后的智能体可以根据环境信息进行在线决策, 能够快速地对动态耦合变化的配电网系统做出实时响应<sup>[15]</sup>。目前, 已有部分研究将 DRL 算法应用于配电网故障恢复领域进行初步性探索。文献[1]提出了基于深度 Q 网络 (deep Q network, DQN) 算法的配电网负荷转供方法, 相较于传统强化学习和启发式算法, 在配电网发生故障时能够即时给出综合最优的转供控制方案。文献[2]将配电网划分成多个微网, 采用多智能体对各微网的供电恢复进行分布式协同控制。文献[3]提出基于改进双智能体竞争双深度 Q 网络 (dueling double deep Q network, D3QN) 的城市电网负荷转供方法, 通过设置双智能体将负荷转供划分为多个子环节, 有效降低了复杂转供问题的维度。然而, 上述方法的智能体架构通常为普通的神经网络, 完全通过对环境的学习进行决策, 忽略了重要的拓扑结构信息, 无法充分发挥 DRL 算法潜在的决策能力, 难以适用于拓扑频繁变动的场景。文献[4-6]利用图神经网络构建起电网拓扑结构与供电恢复进行耦合的桥梁, 通过基于策略梯度的 DRL 算法来学习故障恢复过程的复杂机制, 以获取恢复效果最佳的动作序列。综上所述, DRL 算

法在解决配电网故障恢复问题上有着广阔的应用前景, 但仍存在以下问题: 1) 利用图神经网络对智能体网络架构的改进复杂, 对非法动作给予高惩罚约束容易导致模型的收敛性变差、输出不良动作。2) 基于值函数的 DRL 算法固定的策略探索机制一定程度上限制了智能体的参数寻优效果和泛化能力, 输出得到高质量故障恢复效果的稳定性有待提高。3) 考虑负荷或 DG 的出力形式固定单一, 对运行状态复杂时变的有源配电网的拓展能力有限。

基于此, 本文将图注意力网络 (graph attention network, GAT) 嵌入柔性策略-评价 (soft actor-critic, SAC) 算法来提高智能体对环境的状态感知能力, 提出了一种基于图深度强化学习的有源配电网故障恢复方法, 充分考虑负荷时变性和风电、光伏 DG 的出力波动特性, 建立面向日内多时段尺度故障恢复的图深度强化学习模型, 通过引入无效动作掩盖机制来排除无效或重复动作, 动态支撑配电网在复杂运行场景下的供电恢复。在 IEEE33 节点和 148 节点仿真系统上的测试结果表明, 本文所提方法能够给出提升系统整体运行水平的高效故障恢复方案, 相较于其他基线方法, 其故障恢复效果最佳以及应对拓扑变动新场景的泛化能力更强。

## 1 基于 GAT-SAC 算法的有源配电网故障恢复框架

### 1.1 GAT 算法

相较于 GCN, GAT 在图卷积运算的基础上, 通过引入注意力机制来差异化地为邻域节点分配权重, 极大提高了对空间相关性信息的捕捉能力<sup>[16]</sup>。图 1 展示了 GAT 的节点特征更新原理, 在注意力系数计算过程中, GAT 利用可学习的权重参数矩阵来学习节点与邻域节点的相关度, 节点相关度经过归一化处理得到节点之间的注意力系数  $\alpha_{ij}$ :

$$\alpha_{ij} = \frac{\exp(\sigma(\mathbf{a}^T [\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_j]))}{\sum_{g \in N(i)} \exp(\sigma(\mathbf{a}^T [\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_g]))} \quad (1)$$

式中:  $g \in N(i)$  表示节点  $i$  的邻域节点  $g$ ;  $\mathbf{x}_i \in \mathbb{R}^F$  为节点  $i$  的特征;  $\mathbf{a} \in \mathbb{R}^{2F}$  表示可学习的线性变换权重向量;  $\mathbf{T}$  表示转置操作;  $\mathbf{W} \in \mathbb{R}^{F \times F}$  为权重参数矩阵; “ $\parallel$ ” 表示拼接操作, 即将源节点的特征向量  $\mathbf{W}\mathbf{x}_i$  和邻域节点的特征向量  $\mathbf{W}\mathbf{x}_j$  连接成维度为  $2F$  的特征向量, 这样的特征组合保留了节点间的方向性和特征完整性;  $\sigma(\cdot)$  为非线性激活函数。

在图 1 的节点特征聚合过程中, 反映了在集成 Heads=2 的多头注意力机制的条件下引入注意力系




图1 GAT的节点特征更新原理

Fig. 1 Node feature updating principle of GAT

数,使得重要的邻域节点特征在后续计算中占据更大的权重,将特征向量采取拼接或平均的方式进行加权求和。为增强对节点特征的整体表达能力,第一层 GAT 采取拼接操作,得到包含节点自身以及融合所有邻域节点信息的完整线性组合特征<sup>[16]</sup>,有效避免了特征信息在整合过程中的潜在损失:

$$\mathbf{x}'_i = \left\| \sigma \left( \sum_{j \in N(i)} \alpha_{ij}^k \mathbf{W}^k \mathbf{x}_j \right) \right. \quad (2)$$

第一层 GAT 的拼接操作可以保留多种信息,供后续的 GAT 层灵活利用上层信息,使得模型能够更好地学习到复杂的图结构和节点间的关系。第二层 GAT 采用取平均操作,将多个节点的特征向量整合成统一的表示,可以减少特征维度,提高输出的稳定性,以完成对节点特征的更新:

$$\mathbf{x}'_i = \sigma \left( \frac{1}{K} \sum_{j \in N(i)} \alpha_{ij}^k \mathbf{W}^k \mathbf{x}_j \right) \quad (3)$$

式中: \$\alpha\_{ij}^k\$ 和 \$\mathbf{W}^k\$ 分别为第 \$k\$ 个注意力机制下的注意力系数和权重参数矩阵。

## 1.2 SAC 算法

与传统基于策略梯度的 DRL 算法不同, SAC 算法面对随机改变时融入了最大熵鼓励机制,增强智能体对任何有利动作的探索性以防陷入局部最优,从而提升算法的鲁棒性和泛化能力<sup>[14,17]</sup>。SAC 算法在最大熵机制下获得的累计期望表示为

$$\pi^* = \arg \max_{\pi} \mathbb{E}_{(s_t, a_t) \sim \rho_{\pi}} \left\{ \sum_t r(s_t, a_t) + \alpha H[\pi(\cdot | s_t)] \right\} \quad (4)$$

式中: \$\pi\$ 和 \$\pi^\*\$ 分别为智能体的当前策略和最优策略; \$a\_t\$ 为智能体在状态 \$s\_t\$ 下执行的动作, \$r(s\_t, a\_t)\$ 为智能体获得的奖励; \$(s\_t, a\_t) \sim \rho\_{\pi}\$ 为策略 \$\pi\$ 形成的状态-动作轨迹分布; \$\pi(\cdot | s\_t)\$ 为从当前状态空间 \$s\_t\$ 映射到动作空间上的分布策略; \$H\$ 为在策略 \$\pi(\cdot | s\_t)\$ 下采取的动作熵,熵值越大意味着对环境的探索就越多,避免策略收敛至局部最优; \$\alpha\$ 为动作熵的温度系数,用来决定熵与奖励的权重占比。

基于熵值改进的 \$Q\$ 值函数定义如下:

$$Q(s_t, a_t) = \gamma \mathbb{E}_{s_{t+1}, a_{t+1}} [V(s_{t+1})] + r(s_t, a_t) \quad (5)$$

式中: \$\mathbb{E}\_{s\_{t+1}, a\_{t+1}}\$ 表示对状态 \$s\_{t+1}\$ 和动作 \$a\_{t+1}\$ 的联合期望函数; \$\gamma\$ 为奖励折扣因子; \$V(s\_t)\$ 为状态价值函数,

其计算表达式为

$$V(s_t) = \mathbb{E}_{a_t \sim \pi} [Q(s_t, a_t) - \alpha \ln \pi(a_t | s_t)] \quad (6)$$

将贝尔曼算子与当前 \$Q\$ 值函数相结合进行迭代更新:

$$Q^{k+1} = T^{\pi} Q^k \quad (7)$$

式中: \$T^{\pi}\$ 为策略 \$\pi\$ 下的贝尔曼算子; \$Q^k\$ 为第 \$k\$ 次迭代的值函数,最终 \$Q\$ 会收敛到固定策略 \$\pi\$ 下的柔性 \$Q\$ 值(soft \$Q\$ value)函数。

采用最小化 KL 散度(K-L divergence)的形式来实现智能体策略的更新<sup>[18]</sup>:

$$\pi_{\text{new}} = \arg \min_{\pi \in \Pi} D_{\text{KL}} \left\{ \pi(\cdot | s_t) \parallel \frac{\exp \left[ \frac{1}{\alpha} Q^{\pi_{\text{old}}} (s_t, \cdot) \right]}{Z^{\pi_{\text{old}}} (s_t)} \right\} \quad (8)$$

式中: \$D\_{\text{KL}}\$ 为 KL 散度; \$\Pi\$ 为策略分布的集合; \$Q^{\pi\_{\text{old}}}(s\_t, \cdot)\$ 为旧策略 \$\pi\_{\text{old}}\$ 下的 \$Q\$ 值函数; \$Z^{\pi\_{\text{old}}}(s\_t)\$ 为归一化因子常数。

在 SAC 算法中,用神经网络来拟合 \$Q\$ 值函数和策略函数,通过均方差的形式来最小化贝尔曼残差,以实现 \$Q\$ 值网络参数的更新:

$$J_Q(\theta) = \mathbb{E}_{(s_t, a_t) \sim D, a_t \sim \pi_{\phi}} \left[ \frac{1}{2} [Q_{\theta}(s_t, a_t) - r(s_t, a_t) - \gamma V_{\bar{\theta}}(s_{t+1})]^2 \right] \quad (9)$$

式中: \$\theta\$ 为 \$Q\$ 值网络的参数; \$\bar{\theta}\$ 为目标 \$Q\$ 值网络的参数; \$\phi\$ 为策略网络的参数; \$Q\_{\theta}\$、\$V\_{\bar{\theta}}\$ 和 \$\pi\_{\phi}\$ 为更新后的函数; \$(s\_t, a\_t) \sim D\$ 为从经验池 \$D\$ 中采样得到的状态和动作; \$a\_t \sim \pi\_{\phi}\$ 为由当前策略 \$\pi\_{\phi}\$ 生成的动作。

将式(8)进行相应变换得到策略网络的参数更新表达式为

$$J_{\pi}(\phi) = \mathbb{E}_{s_t \sim D, a_t \sim \pi_{\phi}} [\alpha \ln(\pi_{\phi}(a_t | s_t)) - Q_{\theta}(s_t, a_t)] \quad (10)$$

策略网络中会输出动作熵,其中温度系数 \$\alpha\$ 通过最小化 \$J(\alpha)\$ 的方式在训练过程中进行自适应更新<sup>[18]</sup>:

$$J(\alpha) = \mathbb{E}_{a_t \sim \pi, s_t \sim D} [-\alpha \ln \pi(a_t | s_t) - \alpha H_0] \quad (11)$$

式中: \$H\_0\$ 为策略网络输出动作的维数。

## 1.3 GAT-SAC 算法

对于拓扑复杂多变的配电网,拓扑结构是故障恢复中的重要决策依据, SAC 算法的神经网络对空间维度的特征提取或拟合能力有限,无法充分发挥智能体潜在的决策能力<sup>[5]</sup>。GAT 具备对图空间信息相关性的强大捕捉能力,因此本文将 GAT 与 SAC 算法进行耦合,以更好地发挥 SAC 算法的决策性能。GAT-SAC 算法的原理如图 2 所示,其智能体中的神经网络由 GAT 和全连接网络(fully-connected network, FCN)构成, GAT 作为前置网络来聚合节点电压特征和拓扑空间特征, FCN 作为后置网络来

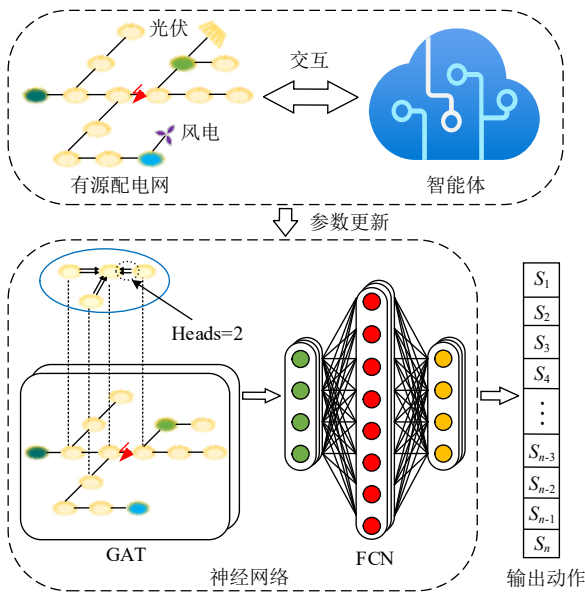


图 2 GAT-SAC 算法原理  
Fig. 2 GAT-SAC algorithm principle

学习故障特征实现对最优开关动作的降维映射。基于有源配电网的仿真环境，运行状态信息不断与智能体进行交互。与此同时，智能体中的神经网络参数同步进行更新，以调整改进自己的动作策略。随着策略的更新迭代，智能体逐渐学习到适应配电网在不同运行状态下的最佳故障恢复控制动作。

### 1.4 基于 GAT-SAC 算法的有源配电网故障恢复方法

#### 1.4.1 有源配电网故障恢复方法的整体框架

本文采用基于 GAT-SAC 算法的图深度强化学习进行有源配电网的故障恢复，其整体框架如附录 A 图 A1 所示。GAT-SAC 算法属于 Actor-Critic 框架的 DRL 算法，其智能体包含一个策略(Actor)网络、一组孪生的评价(Critic)网络和目标-评价(Target-Critic)网络。Actor 网络用于拟合策略函数，输出给定状态下的动作概率分布；Critic 网络用于拟合  $Q$  值函数，以评估 Actor 网络输出动作的质量；Target-Critic 网络用于计算目标值，以软更新的方式逐步逼近 Critic 网络，在各网络模型中嵌入 GAT 以拓宽智能体对空间维度特征的感受域。

对于  $t$  时段的训练过程，根据当前的源荷水平和网络拓扑，智能体通过获取当前基于 OpenDSS 平台的仿真环境的运行状态  $s_t$  (包含节点电压  $U$  和邻接矩阵  $X$ )，经过由 GAT 和 FCN 层构成的 Actor 网络进行特征提取和降维映射，从而生成动作的概率分布，采用无效动作掩盖机制对无效或重复动作进行排除，从而输出合理的恢复控制动作  $a_t$ 。然后，根据当前状态在仿真平台中计算得到电压、电流等电气分布，按照一定的奖励函数制定规则，以获取

当前环境运行状态下的动作奖励  $r_t(s_t, a_t)$ <sup>[18]</sup>。考虑日内 24 个时段的时间尺度，同一时段内的负荷水平和 DG 出力是固定的，所以下一阶段的运行场景仅需按照网络拓扑的改变进行状态转移，过渡到新的运行状态  $s_{t+1}$ ，并将经验样本  $(s_t, a_t, r_t, s_{t+1})$  存储至经验池中。随着训练的持续进行，当经验样本储存一定容量后，从经验池中取出批量采样集合进行网络参数更新。

在策略更新阶段，Critic 网络利用取出的经验集合通过最小化预测的  $Q$  值与基于 Target-Critic 网络计算的目标  $Q$  值的误差来实现参数自更新。经验集合经过孪生 Critic 网络后分别输出  $Q_1$  和  $Q_2$ ，Actor 网络则依赖其中较小的  $Q$  值来评估动作质量。在策略优化过程中，Actor 网络通过双重机制实现参数更新：一方面需要最大化策略收益，即选择能使 Critic 网络输出  $Q$  值最大的动作；另一方面还需最小化策略的熵正则化损失，通过鼓励动作多样性避免过早收敛。Target-Critic 网络延迟复制 Critic 网络的参数，平滑地跟随 Critic 网络的变化，确保目标  $Q$  值的稳定性<sup>[19]</sup>。上述具有链式联系的更新过程在于利用 Critic 网络评估动作价值指导 Actor 网络优化策略，而 Target-Critic 网络参数的软更新则为目标值计算提供稳定性<sup>[20]</sup>。

#### 1.4.2 有源配电网故障恢复方法的应用流程

基于 GAT-SAC 算法的有源配电网故障恢复模型包括离线训练和在线决策这两个阶段，其离线流程如附录 A 图 A2 所示，具体过程如下：

1) 模型的整体训练过程包括 3 层嵌套循环：  
①在一个时段内，进行的多次开关倒闸操作组成完整的故障恢复回合，当恢复动作满足故障恢复结束条件（恢复失电负荷供电和满足正常运行约束）或探索完整动作空间时，则跳出当前循环。  
②在日时间尺度下的 24 个时段内，每个时段的故障恢复回合动态支撑日时间尺度下的供电恢复。  
③在总训练周期内，智能体所执行的每轮故障恢复策略，作为模型经历一次训练周期所取得的成效。

2) 在每一次故障恢复动作过程中，通过制定奖励机制引导智能体在尽量满足系统正常运行约束的条件下，采取无效动作掩盖机制来避免智能体执行无效或重复动作，然后进行开关倒闸操作，以重新建立失电负荷与主网电源或 DG 的连接关系，最大限度地恢复失电负荷的供电。

3) 如果该轮故障恢复回合在满足正常运行约束的条件下恢复所有失电负荷供电，则对每回合动作给予稀疏奖励，然后将每轮恢复回合所蕴含的信

息存储至经验池，池中的信息作为数据基础，供智能体中的各神经网络进行参数更新。

基于 GAT-SAC 算法的有源配电网故障恢复模型的在线决策流程如附录 A 图 A3 所示。当出现故障后，需要立即对故障进行隔离，然后智能体根据环境当前运行状态  $s_t$  来输出动作的分布情况，并采取无效动作掩盖机制排除无效或重复动作。随后智能体执行合理的开关倒闸操作  $a_t$ ，当前环境运行状态转移至  $s_{t+1}$ 。考虑在线决策阶段可能出现切负荷或违背运行约束的情况，判断此时系统是否满足保留一定裕度的故障恢复条件，满足即停止转供，完成故障恢复；反之则继续进行故障恢复任务。

## 2 面向有源配电网故障恢复的图深度强化学习模型

### 2.1 智能体与动作空间

在配电网故障恢复过程中，智能体扮演着电网

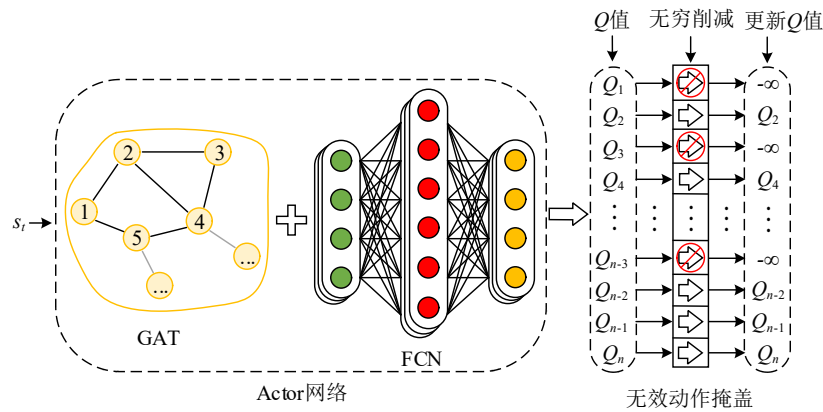


图3 智能体动作输出过程

Fig. 3 Agent action output process

针对智能体采取无效或重复动作的情况，传统做法大多是给予一个高惩罚约束，警告智能体不能采取该类动作<sup>[1,3]</sup>。这种方法存在的较大缺陷在于智能体需要花费大量的时间去学习，迭代训练的收敛性难以得到保证，并且容易因动作探索空间过大而遇到“开关动作组合爆炸”的问题。为此，本文采用无效动作掩盖机制对智能体输出的非法动作进行强制规避，其具体示意如图3所示。环境状态信息  $s_t$  输入至 Actor 网络后生成动作的  $Q$  值分布，对无效或重复动作所对应的  $Q$  值进行大幅削减，使之数值接近于负无穷，更新后的  $Q$  值分布中只含有可行动作的集合。

### 2.2 状态空间

配电网的电气运行状态和拓扑结构表征了智能体所能感知到的环境信息，本文选取配电网拓扑结构和节点电压信息组成状态空间。根据状态空间

调度员的角色，在考虑满足正常运行约束的同时，对分段开关和联络开关进行倒闸操作，以重新建立电源和失电负荷的连接关系，完成故障恢复。智能体的 Actor 网络架构如图3所示，考虑到 FCN 只能对欧式空间的数据进行特征学习，忽略了网络拓扑在故障恢复过程中所蕴含的重要价值信息，因此本文将 GAT 嵌入到智能体的前置神经网络中来增强智能体对空间特征的挖掘能力，使其具备更强的状态变化感知能力。

系统中各线路开关可执行的投切状态组成智能体的动作空间，考虑动作空间设计的合理性，对故障线路开关采取动作则视作无效、对已执行投切操作后的开关再次操作则记为重复动作。因此，本文动作空间的设计如下：

$$A = \{a_{i,\text{open}}, \dots, a_{j,\text{close}}\} \quad i, j \notin N \quad (12)$$

式中： $a_{i,\text{open}}$  为第  $i$  个可断开的开关； $a_{j,\text{close}}$  为第  $j$  个可闭合的开关； $N$  为无效和重复动作的开关集合。

的变化，引导智能体不断学习捕捉配电网中不同节点之间的电力传输和连接关系。状态空间的数学表达式可描述为

$$\begin{cases} S = [X, U] \\ U = [u_1, u_2, \dots, u_i, \dots, u_n] \end{cases} \quad (13)$$

式中： $U$  为配电网的节点电压，其中  $u_i$  为节点  $i$  的电压值， $n$  为节点数量； $X$  为表征配电网拓扑结构的邻接矩阵。

### 2.3 奖励函数

强化学习的目标是使智能体通过不断试错学习的方式以最大化给定环境下的预期奖励<sup>[17]</sup>，环境反馈给智能体的奖励包括奖励和惩罚部分。

#### 2.3.1 奖励部分

故障恢复的首要任务就是要尽可能多地恢复失电负荷的供电，在每一轮故障恢复回合过程中包含多次单步开关动作，其中第  $i$  次开关动作奖励部

分  $R_i$  的数学表达式为

$$R_i = \frac{(P_{\text{load,loss}} - P_{\text{loss},i}) / P_{\text{load,loss}} + \Delta P_{\text{loss},i}}{i\delta} + R_{\text{sparse},i} \quad (14)$$

$$\Delta P_{\text{loss},i} = \frac{P_{\text{loss},i-1} - P_{\text{loss},i}}{P_{\text{load,loss}}} \quad (15)$$

$$R_{\text{sparse},i} = \begin{cases} \frac{n-i}{\sum_{i=1}^n i}, & P_{\text{rate}} = 100\% \text{ 且满足运行约束} \\ 0, & P_{\text{rate}} \neq 100\% \text{ 或不满足运行约束} \end{cases} \quad (16)$$

$$P_{\text{rate}} = \frac{P_{\text{Load}} - P_{\text{loss},n}}{P_{\text{Load}}} \times 100\% \quad (17)$$

式中： $P_{\text{load,loss}}$  为系统发生故障时的负荷总损失量， $P_{\text{loss},i}$  为第  $i$  步开关动作的失负荷量； $\Delta P_{\text{loss},i}$  为动作差额奖励，用于判断前后开关动作对负荷恢复的影响好坏，引导智能体尽量往恢复失电负荷的方向探索； $\delta$  为调节系数，用于调整恢复负荷供电操作在奖励函数中的权重； $R_{\text{sparse},i}$  为第  $i$  步开关动作的稀疏奖励值，当该轮故障恢复回合能够恢复所有负荷供电，即  $P_{\text{rate}} = 100\%$ ，并且满足运行约束条件时，则给予每次动作稀疏奖励； $n$  为故障恢复的开关动作总次数； $P_{\text{rate}}$  为负荷供电率； $P_{\text{Load}}$  为系统总负荷量； $P_{\text{loss},n}$  为第  $n$  次开关动作后系统的失负荷量。

### 2.3.2 惩罚部分

若配电网拓扑出现环网结构，在发生短路故障时容易造成短路电流过大从而出现安全隐患问题，因此，环网可以作为短时过渡状态，但不允许长期存在，环网约束惩罚  $P_{\text{loop}}$  的数学表达式如下：

$$P_{\text{loop}} = \begin{cases} P_{\text{loop}}, & g \in G \\ 0, & g \notin G \end{cases} \quad (18)$$

式中： $g$  为当前配电网运行的拓扑结构； $G$  为配电网辐射状运行拓扑结构集合。

电压和电流水平维持在正常范围内是保证配电网正常运行的基本要求。因此，当智能体执行会产生电压或电流越限的动作时，需要对其给予惩罚，电压越限惩罚  $P_{\text{voltage}}$  的数学表达式为

$$P_{\text{voltage}} = \begin{cases} P_U, & U_m \geq U_{\text{max}}, U_m \leq U_{\text{min}} \\ 0, & U_{\text{min}} \leq U_m \leq U_{\text{max}} \end{cases} \quad (19)$$

式中： $P_U$  为电压越限的惩罚值； $U_{\text{max}}$  和  $U_{\text{min}}$  分别为电压上下限； $U_m$  为节点  $m$  的电压；考虑负荷峰平谷差异，对故障恢复后的电压水平提出不同要求，电压上限取 1.06pu，早高峰时段电压下限取 0.945pu，晚高峰时段电压下限取 0.94pu，平段和谷段的电压下限取 0.95pu。

电流越限惩罚  $P_{\text{current}}$  的数学表达式为

$$P_{\text{current}} = \begin{cases} P_I, & I_{ab} \geq I_{ab,\text{max}} \\ 0, & I_{ab} < I_{ab,\text{max}} \end{cases} \quad (20)$$

式中： $P_I$  为电流越限的惩罚值； $I_{ab}$  为支路  $a-b$  上流过的电流值； $I_{ab,\text{max}}$  为支路  $a-b$  允许的最大传输电流值。

网损率是评估配电网整体运行水平的重要指标之一，因此网损率是衡量故障恢复动作好坏的重要依据，网损率惩罚的计算方法如下：

$$P_{\text{net}} = \frac{P_{\text{net,loss}}}{P_{\text{Load}}} \quad (21)$$

式中： $P_{\text{net,loss}}$  为网络损耗功率。

## 3 算例分析

### 3.1 模型效果评估

为验证本文所提方法的有效性，采用风电和光伏 DG 接入的 IEEE33 节点系统进行仿真验证，总负荷为 3715+j2300kVA，包含 32 个分段开关，5 个联络开关，其拓扑结构如附录 A 图 A1 所示。日负荷水平和风电、光伏的出力曲线如附录 A 图 A4 所示，各 DG 接入位置和容量见附录 C 表 C1 所示，渗透率为 53.84%<sup>[21]</sup>。

为了验证本文所提图深度强化学习模型开展有源配电网故障恢复任务时的有效性，将 SAC 算法作为基线与本文所提 GAT-SAC 算法进行对比，并将 DQN 和 D3QN 作为基础 DRL 算法进行补充比较，根据在训练过程中的累计奖励值来衡量模型的稳定性和有效性。在多条线路上设置单重故障以模拟不同的故障场景，以 10 轮日时间尺度下的故障恢复回合作为各 DRL 模型训练获得一次累计奖励的周期，图 4 列出了各 DRL 模型离线训练时所获得累计奖励的收敛过程。考虑 DRL 算法的随机性，本文使用不同的随机种子对每个算法进行 5 次仿真

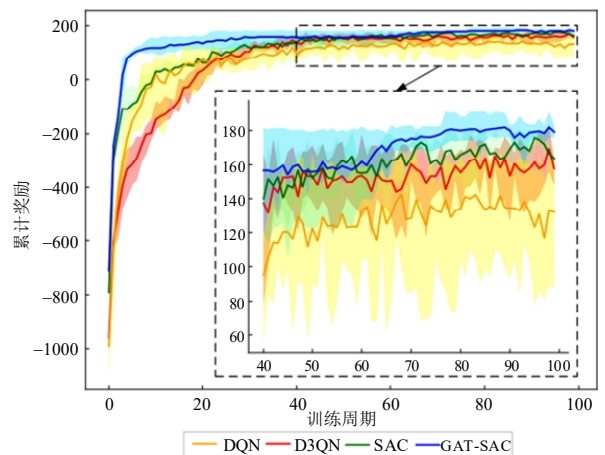


图 4 各 DRL 算法的累计奖励  
Fig. 4 Cumulative rewards for each DRL algorithm

实验, 训练结果的平均值和误差界在图 4 中分别以实线和填充区的形式进行呈现<sup>[22]</sup>。

从图 4 中可以看出, 在训练初期, GAT-SAC 模型训练所获得的累计奖励上升速度最快, 智能体的探索学习能力最强<sup>[23]</sup>。在训练中后期, 本文所提出的 GAT-SAC 算法所获得的累计奖励值在所有测试算法中最大, 并且累计奖励曲线收敛更加稳定。由此可见, 相较于其他 DRL 基线算法, GAT-SAC 算法可以快速学习到最佳故障恢复效果的自适应趋优决策方案, 具有更优越的泛化性能<sup>[24]</sup>。

### 3.2 故障恢复方案

#### 3.2.1 GAT-SAC 算法的故障恢复方案

本文选取配电网系统中 8-9、13-14、26-27 这 3 条线路发生故障的恢复方案作为部分展示结果。考虑每条线路在 09:00、14:00、19:00 这 3 个典型日负荷时段发生故障, 并对本文所提 GAT-SAC 算法进行测试, 得到智能体所执行的故障恢复方案如附录 C 表 C2 所示。在 09:00 时段, 对于线路 26-27, 通过闭合联络开关  $S_{36}$  即可恢复所有失电负荷供电, 并且满足所有运行约束。线路 8-9 和线路 13-14 的故障恢复方案类似, 以线路 8-9 发生故障后的恢复方案为例, 系统在故障恢复过程中的节点电压变迁情况如图 5 所示。由图 5 和附录 A 图 A4 可知, 其中 09:00 处于负荷早高峰时段, 系统的电压水平较低; 另外, 风电和光伏均有部分出力, 即 DG 可以提供一定的电源支撑能力。线路 8-9 发生故障后, 首先通过闭合联络开关  $S_{34}$  来恢复失电负荷供电, 供电恢复后节点 31 和 32 存在电压越下限的情况。再通过闭合联络开关  $S_{32}$  将部分负荷转移到含风电 DG 的支路 18-21 上进行供电, 以缓解重载线路上的负载压力; 最后断开分段开关  $S_6$  来消除环网, 以




图 5 节点电压变迁过程(09:00)

Fig. 5 Node voltage transition process at 09:00

满足系统拓扑的运行约束, 系统各节点的电压水平均大幅提升到了允许范围内, 完成故障恢复。

在 14:00 时段, 线路 26-27 仅需通过闭合联络开关  $S_{36}$  便可完成故障恢复。对于线路 8-9, 闭合联络开关  $S_{34}$  后, 需再次通过闭合联络开关  $S_{35}$ , 并断开分段开关  $S_{31}$  以消除环网后实现负荷转供。对于线路 13-14, 系统在故障恢复过程中的节点电压变迁情况如图 6 所示。从图 6 和附录 A 图 A4 中可以看出, 14:00 处于午间负荷平段, 此时风电和光伏综合出力基本达到峰值水平, DG 可以发挥良好的辅助电源支撑作用。线路 13-14 发生故障后, 首先通过闭合联络开关  $S_{33}$  来恢复故障下游失电负荷的供电, 此时系统末端部分节点电压越限, 为了提升电压水平, 依次闭合联络开关  $S_{36}$  和断开分段开关  $S_{25}$ , 实现将 25-32 支路的多数负荷转移至含分布式光伏所在的轻载支路 22-24 上。完成负荷转移后末端节点 31—32 的电压出现轻微越下限的现象, 此时智能体通过断开分段开关  $S_{31}$  来切除节点 32 上的非失电负荷, 以提升系统末端节点的电压水平, 最终满足复电条件。由上述恢复过程可知, 在配电网发生故障后本文方法可以通过合理布局主网电源和 DG 与负荷的连接关系, 在最大限度恢复所有负荷供电的前提下, 将系统电压提升到较高水平。




图 6 节点电压变迁过程(14:00)

Fig. 6 Node voltage transition process at 14:00

在 19:00 时段, 智能体对各线路执行的故障恢复方案原理类似, 以线路 26-27 为例, 其在故障恢复过程中系统的节点电压变迁情况如图 7 所示。从图 7 和附录 A 图 A4 中可以看出, 19:00 为负荷晚高峰段, 此时系统电压位于日最低水平; 另一方面, 此时光伏出力为零, 仅有风电提供少量出力, DG 能够起到的电源支撑能力微弱, 更多的需要依赖主网电源与失电负荷重新建立连接关系才能有效恢复供电。对于线路 26-27 的故障恢复方法, 智能体




图 7 节点电压变迁过程(19:00)(1)

Fig. 7 Node voltage transition process at 19:00(1)

首先通过闭合联络开关  $S_{36}$ ，将下游失电负荷与上游主网电源进行连接以恢复供电。但此时节点 12—17 和节点 30—32 存在电压越限的情况，因此再次闭合联络开关  $S_{34}$ ，并随后断开分段开关  $S_{10}$  以消除环网，实现将主干线路上节点 11—17 的负荷转移至轻载支路 18-21 上。经过上述操作后，节点 12—17 的电压水平得到了大幅的提升，但节点 30—32 的电压水平仍处于越限状态。为解决这一问题，通过闭合联络开关  $S_{35}$  以重新调整线路负载情况，此时各节点的电压均未出现越限的情况，但系统的拓扑结构中存在环网。最后，断开分段开关  $S_{31}$  以切除环网，完成故障恢复。

综上所述，不同线路在不同时段发生故障时，智能体执行的故障恢复控制策略包括具体的开关动作位置和步骤，能够恢复所有失电负荷的正常供电，并且满足节点电压和支路电流均不越限以及单辐射状的拓扑约束。另外，相较于系统正常运行时的状态，故障恢复后系统的网损率得到了降低，从各个时段的节点电压变迁过程可知，故障恢复后明显改善系统电压水平。由此可见，本文所提 GAT-SAC 算法能够给出有效提升系统整体运行水平的可行性故障恢复方案。

### 3.2.2 各 DRL 算法的恢复方案对比

为了进一步验证本文所提 GAT-SAC 算法的优越性，考虑在线路 8-9 上发生故障的情况下，与其他 DRL 基线算法进行对比分析，附录 C 表 C3 展示了各 DRL 算法在不同时段的恢复方案及其效果。由附录 C 表 C3 可知，在早高峰时段，DQN 通过多次调整线路负载率仍未满足故障恢复条件，最终通过采取切负荷操作来实现故障恢复，D3QN 的故障恢复效果略优于 DQN 算法，不过仍需切除部分负荷来消除电压越限。SAC 和 GAT-SAC 算法的故障

恢复方案均能恢复所有失电负荷的供电，但 GAT-SAC 算法仅通过 3 次开关倒闸操作便可完成故障恢复，并且网损率最小。在午间平段，各 DRL 算法都能实现满足各种运行约束条件的故障恢复。其中，D3QN、SAC 和 GAT-SAC 算法执行相似的恢复策略，相较于 DQN 算法，所需的动作次数更少，网损率更低。

在晚高峰时段，DQN、D3QN 和 SAC 算法经过多次恢复后都无法满足电压越限约束，最终采取切负荷操作，DQN 算法需多次切除负荷，D3QN 算法切除负荷以后仍存在轻微电压越限。以 SAC 算法所给出的故障恢复方案为例，在故障恢复过程中系统的节点电压变迁情况如图 8 所示。从图 8 中可以看出，智能体首先通过闭合联络开关  $S_{34}$  来恢复所有失电负荷的供电。但此时由于支路 25-31 的负载率相对较高，下游末端节点 29—32 存在电压越限的情况，选择再次闭合联络开关  $S_{32}$  以调整线路负载率。在断开分段开关  $S_6$  后，末端节点的电压水平得到了提升，但节点 30—32 仍未满足电压越限的运行约束。因此，继续执行依次闭合联络开关和断开分段开关的操作，即先合上  $S_{35}$  并随后断开  $S_{31}$ ，实现将节点 32 上的负荷转供至线路 9-21。此时，节点 16、17 和 32 仍存在电压越限，但总体越限量得到了减少。随着动作次数的增加，智能体执行切负荷操作获得的反馈要优于调整线路负载率，所以最后选择切除了 9 号节点上的负荷，系统整体的电压水平改善到了允许范围内，成功恢复了系统的正常运行。相较于 SAC 算法在断开分段开关  $S_6$  后执行的负荷调整策略，GAT-SAC 算法选择依次闭合联络开关  $S_{36}$  和断开分段开关  $S_{27}$ ，将重载线路的多数负荷转移至轻载支路上，上述策略既能避免切负荷，也能满足各种运行约束条件。

总体而言，面对复杂故障场景，4 种 DRL 算法

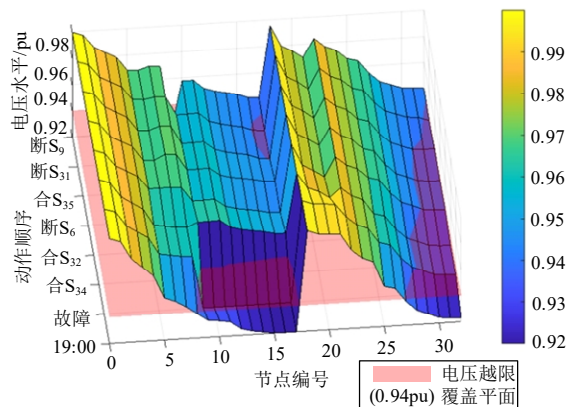


图 8 节点电压变迁过程(19:00)(2)

Fig. 8 Node voltage transition process at 19:00(2)

均能在有限动作次数内给出行之有效的恢复方案。但 GAT-SAC 算法给出控制策略的负荷恢复效率最高且网损率几乎最低，能够得到最佳的故障恢复效果。由此可见，本文所提方法能够基本实现执行最优故障恢复方案。

### 3.3 故障恢复效率对比

为进一步比较本文方法与其他方法的故障恢复效率，从负荷供电率、训练成本和决策用时三方面构建起故障恢复效率评估体系，采用 SAC 基线算法和灰狼算法<sup>[12]</sup>与本文所提方法进行对比。在多条线路上设置单重故障进行测试，不同方法的故障恢复效率如表 1 所示(以下各项指标均为平均值)。

方法	负荷供电率/%	训练成本/min	决策用时/s
灰狼算法	91.83	—	17
SAC	95.67	15	0.13
GAT-SAC	97.92	24	0.08

从表 1 可以看出，灰狼算法的决策用时最长，原因在于启发式算法寻优迭代的计算方式造成其求解过程的耗时较长；两种 DRL 算法的决策用时极短，可以很好地满足电网的实时运行调度需求。另一方面，与启发式算法和基线算法相比，本文方法的负荷供电率最大，说明其所执行的故障恢复决策总是能得到全局最优结果。从训练成本来看，本文方法以牺牲更小的运算量换来了更好的故障恢复效果，图卷积运算的扩充明显提升了求解动作的质量。总的来说，在不计训练成本的前提下，相较于其他方法，本文所提方法的故障恢复效率更高。

### 3.4 拓扑变动下的故障恢复效果

配电网会因计划停电、故障检修等不可控因素而导致拓扑频繁变动<sup>[25]</sup>，因此 DRL 模型应对拓扑变动的可扩展性是评估其泛化性能的关键指标。考虑 DG 和负荷水平时变性的多个运行状态，在删减节点数量和改变连接关系这两种拓扑变动方式的复杂场景下对 DRL 模型进行测试：

1) 删减节点数量。断开分段开关  $S_{30}$ 。

2) 改变连接关系。断开分段开关  $S_9$ ，闭合联络开关  $S_{34}$ ；断开分段开关  $S_{27}$ ，闭合联络开关  $S_{36}$ 。

本文所提方法与 SAC 基线算法的负荷供电率对比效果如附录 B 图 B1 所示。对于 24 个时段内的负荷供电率，相较于基线算法，GAT-SAC 算法在情况(a)下平均提高了 4.1%、在情况(b)下平均提高了 4.6%。总之，无论是在配电网系统节点数量减少，或者连接关系发生变化的情况下，本文方法都能大幅提升负荷供电率水平，减少切负荷量，尤其是在

日负荷峰段的提升效果更加明显，充分体现了 GAT 嵌入 SAC 算法后所带来的拓扑泛化优势。由此可知 GAT 作为本文所提图深度强化学习模型的前置网络，拓宽了智能体对空间维度特征的感受域，使之能够更敏锐地捕捉到拓扑变化信息<sup>[16]</sup>。

### 3.5 大规模系统下的故障恢复效果

为了验证本文方法在大规模系统上的有效性，采用修改后的 148 节点系统进行测试<sup>[26]</sup>，其拓扑结构如附录 B 图 B2 所示，负荷水平和 DG 出力保持与附录 A 图 A4 情况一致。相较于 IEEE33 节点系统，148 节点系统中的负荷数量和联络开关的数量更多，无疑增加了智能体对动作空间的探索难度。

不同 DRL 算法在训练过程中所获得的累计奖励和模型收敛时测试得到的负荷供电率如附录 B 图 B3 所示。从累计奖励评估指标的变化曲线可以看出，本文所提的 GAT-SAC 算法在 80 轮左右便率先达到了累计奖励的平稳阶段，而其他算法至少需要花费 100 轮的训练成本才能实现收敛，其中基于策略梯度的 DQN 算法的收敛稳定性较差，难以维持平稳水平。在收敛阶段，本文方法的负荷供电率和所获得的累计奖励值相对最高，在该两项指标方面与其他 DRL 方法的差额明显。上述结果表明本文方法在大规模系统下的收敛速度和故障恢复效果具有更显著的优势。

## 4 结论

本文提出了一种基于图深度强化学习的有源配电网故障恢复方法，结合在 IEEE33 节点和 148 节点仿真系统上的恢复策略分析以及与多种基线方法的对比测试，得到如下结论：

1) 创新性地引入了无效动作掩盖机制，缩小了动作探索空间，使得智能体能够有效避免执行无效或重复动作。

2) 相较于多种基线方法，在复杂运行场景下，本文所提算法能够给出更加高效优越的可行性故障恢复方案，并且可以改善系统电压水平和降低网损率，提升配电网整体运行水平。

3) 在不同规模算例系统中的测试结果表明，本文所提方法能够有效融合 GAT 强大的空间特征提取优势，大幅提高了图深度强化学习模型的学习效率和面对新场景的泛化能力，在大规模系统中的适用效果更加显著。

本文尚未考虑储能与 DG 形成的光储或风储系统，所以故障恢复方案中不涉及孤岛供电的形式，后续将研究多智能体 DRL 算法来支撑主网和孤岛

联合供电形式的故障恢复控制策略。此外,随着柔性配电技术的快速发展,柔性软开关(soft open point, SOP)逐步替代传统的联络开关<sup>[27]</sup>,未来研究将进一步探索含 SOP 的柔性配电网故障恢复方法,结合 SOP 能够灵活调节配电网的潮流分布和电压水平的控制特性,进一步优化基于图深度强化学习的故障恢复策略,探索 SOP 与 DG、储能的协同控制机制,以实现更加灵活、高效的配电网故障恢复。

附录见本刊网络版(<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

## 参考文献

- [1] 王光华, 李晓影, 宋秉睿, 等. 基于深度强化学习的配电网负荷转供控制方法[J]. 电力自动化设备, 2022, 42(7): 253-260. WANG Guanghua, LI Xiaoying, SONG Bingrui, et al. Load transfer control method of distribution network based on deep reinforcement learning[J]. Electric Power Automation Equipment, 2022, 42(7): 253-260(in Chinese).
- [2] VU L, VU T, VU T L, et al. Multi-agent deep reinforcement learning for distributed load restoration[J]. IEEE Transactions on Smart Grid, 2024, 15(2): 1749-1760.
- [3] 安军, 黎梓聪, 周毅博, 等. 基于改进双智能体 D3QN 的电网 N-1 新增风险防控策略[J]. 中国电机工程学报, 2025, 45(3): 858-869. AN Jun, LI Zicong, ZHOU Yibo, et al. N-1 new risk prevention and control strategy for power grid based on improved double agent D3QN algorithm[J]. Proceedings of the CSEE, 2025, 45(3): 858-869 (in Chinese).
- [4] 张沛, 陈玉鑫, 王光华, 等. 基于图强化学习的配电网故障恢复决策[J]. 电力系统自动化, 2024, 48(2): 151-158. ZHENG Pei, CHEN Yuxing, WANG Guanghua, et al. Fault recovery decision of distribution network based on graph reinforcement learning[J]. Automation of Electric Power Systems, 2024, 48(2): 151-158(in Chinese).
- [5] 范邦稷, 刘兴华, 丁涛, 等. 基于图注意力网络与深度确定性策略梯度的三相主动配电网供电恢复方法[J]. 中国电机工程学报, 2023, 43(21): 8193-8205. FAN Bangji, LIU Xinghua, DING Tao, et al. A GAT-DDPG based approach for three-phase active distribution system restoration[J]. Proceedings of the CSEE, 2023, 43(21): 8193-8205(in Chinese).
- [6] ZHAO Tianqiao, WANG Jianhui. Learning sequential distribution system restoration via graph-reinforcement learning[J]. IEEE Transactions on Power Systems, 2022, 37(2): 1601-1611.
- [7] 文娟, 谭阳红, 何怡刚, 等. 含分布式电源的复杂配电网多阶段故障恢复方法[J]. 电工技术学报, 2018, 33(14): 3332-3341. WEN Juan, TAN Yanghong, HE Yigang, et al. A multi-stage service restoration method for complex distribution networks with distributed generators[J]. Transactions of China Electrotechnical Society, 2018, 33(14): 3332-3341(in Chinese).
- [8] 汪涛, 武涛涛, 随权, 等. 计及故障维修与网络重构的灾后配电网综合调度策略[J]. 中国电机工程学报, 2024, 44(5): 1764-1776. WANG Tao, WU Chuantao, SUI Quan, et al. Integrated dispatching strategy for post-disaster distribution networks with fault repair and network reconfiguration[J]. Proceedings of the CSEE, 2024, 44(5): 1764-1776(in Chinese).
- [9] ARIF A, CUI Bai, WANG Zhaoyu. Switching device-cognizant sequential distribution system restoration[J]. IEEE Transactions on Power Systems, 2022, 37(1): 317-329.
- [10] 叶学顺, 李昭, 刘科研, 等. 信息物理并发故障下的配电网供电恢复方法[J]. 电力信息与通信技术, 2024, 22(9): 18-25. YE Xueshun, LI Zhao, LIU Keyan, et al. Distribution network power restoration under cyber-physical concurrent faults[J]. Electric Power Information and Communication Technology, 2024, 22(9): 18-25(in Chinese).
- [11] 徐岩, 张荟, 马天祥, 等. 含分布式电源的配电网故障紧急恢复与抢修协调优化策略[J]. 电力系统自动化, 2021, 45(22): 38-46. XU Yan, ZHANG Hui, MA Tianxiang, et al. Coordinated optimization strategy of fault emergency recovery and repair for distribution network with distributed generators[J]. Automation of Electric Power Systems, 2021, 45(22): 38-46(in Chinese).
- [12] 王红君, 陈智晴, 赵辉, 等. 考虑风光荷不确定性的配电网故障恢复策略[J]. 电网技术, 2022, 46(11): 4356-4364. WANG Hongjun, CHEN Zhiqing, ZHAO Hui, et al. Reconstruction strategies for fault recovery of active distribution network with distributed generation uncertainties[J]. Power System Technology, 2022, 46(11): 4356-4364(in Chinese).
- [13] 王子晗, 高红均, 高艺文, 等. 基于深度强化学习的城市配电网多级动态重构优化运行方法[J]. 电力系统保护与控制, 2022, 50(24): 60-70. WANG Zihan, GAO Hongjun, GAO Yiwen, et al. Multi-level dynamic reconfiguration and operation optimization method for an urban distribution network based on deep reinforcement learning[J]. Power System Protection and Control, 2022, 50(24): 60-70(in Chinese).
- [14] 陈嘉琛, 陈中, 李冰融, 等. 基于二阶随机动力学的多虚拟电厂自趋优能量管理策略[J]. 中国电机工程学报, 2024, 44(16): 6294-6306. CHEN Jiachen, CHEN Zhong, LI Bingrong, et al. Energy management strategy for multi-virtual power plants with self-optimization based on second-order stochastic dynamics[J]. Proceedings of the CSEE, 2024, 44(16): 6294-6306(in Chinese).
- [15] 袁红霞, 张俊, 许沛东, 等. 基于图强化学习的电力交通耦合网络快速充电需求引导研究[J]. 电网技术, 2021, 45(3): 979-986. YUAN Hongxia, ZHANG Jun, XU Peidong, et al. Fast charging demand guidance in coupled power-transportation networks based on graph reinforcement learning[J]. Power System Technology, 2021, 45(3): 979-986(in Chinese).
- [16] 何小龙, 高红均, 黄媛, 等. 基于一维卷积和图神经网络的配电网故障区段定位方法[J]. 电力系统保护与控制, 2024, 52(17): 27-39. HE Xiaolong, GAO Hongjun, HUANG Yuan, et al. Fault section location for a distribution network based on one-dimensional convolution and graph neural networks[J]. Power System Protection and Control, 2024, 52(17): 27-39(in Chinese).
- [17] 罗文健, 张靖, 何宇, 等. 基于优势柔性策略-评价算法和迁移学习的区域综合能源系统优化调度[J]. 电网技术, 2023, 47(4): 1601-1611. LUO Wenjian, ZHANG Jing, HE Yu, et al. Optimal scheduling of regional integrated energy system based on advantage learning soft actor-critic algorithm and transfer learning[J]. Power System Technology, 2023, 47(4): 1601-1611(in Chinese).
- [18] 乔骥, 王新迎, 张擎, 等. 基于柔性行动器-评判器深度强化学习的电气综合能源系统优化调度[J]. 中国电机工程学报, 2021, 41(3): 819-832. QIAO Ji, WANG Xinying, ZHANG Qing, et al. Optimal dispatch of integrated electricity-gas system with soft actor-critic deep reinforcement learning[J]. Proceedings of the CSEE, 2021, 41(3): 819-832(in Chinese).

- [19] 翟宏睿, 罗亮, 杨萌, 等. 基于最大熵强化学习的自主船舶航迹跟踪研究[J]. 舰船科学技术, 2023, 45(23): 78-84.  
ZHAI Hongrui, LUO Liang, YANG Meng, et al. Research on autonomous ship track tracking based on maximum entropy reinforcement learning[J]. Ship Science and Technology, 2023, 45(23): 78-84(in Chinese).
- [20] 李达, 尚涛, 高雪芹, 等. 基于深度强化学习的电力 CPS 联合防御方案[J]. 电力信息与通信技术, 2023, 21(9): 23-29.  
LI Da, SHANG Tao, GAO Xueqin, et al. Power CPS joint defense scheme based on deep reinforcement learning[J]. Electric Power Information and Communication Technology, 2023, 21(9): 23-29(in Chinese).
- [21] 肖峻, 王传奇. 配电网分布式发电渗透率极限值定义与计算方法[J]. 电网技术, 2024, 48(1): 352-360.  
XIAO Jun, WANG Chuanqi. Definition and calculation method of dg penetration limit values of distribution network[J]. Power System Technology, 2024, 48(1): 352-360(in Chinese).
- [22] 朱涛, 海迪, 李文云, 等. 基于图神经网络与强化学习的配电网电压与无功功率优化方法[J]. 南方电网技术, 2024, 18(11): 67-78.  
ZHU Tao, HAI Di, LI Wenyun, et al. Voltage and reactive power optimization method for distribution networks based on graph neural network and reinforcement learning[J]. Southern Power System Technology, 2024, 18(11): 67-78(in Chinese).
- [23] 朱振山, 陈哲盛, 盛明鼎. 基于柔性行动器-评判器的园区综合能源系统运行优化[J]. 高电压技术, 2022, 48(12): 4949-4958.  
ZHU Zhenshan, CHEN Zhesheng, SHENG Mingding. Operation optimization of park-level integrated energy system based on soft actor-critic[J]. High Voltage Engineering, 2022, 48(12): 4949-4958(in Chinese).
- [24] 罗龙波, 陈明辉, 王仁浚, 等. 基于相邻分区可用转供能力的配电网分区间互济运行优化方法[J/OL]. 南方电网技术, 2024: 1-11[2024-08-28]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20240626.1518.007.html>.  
LUO Longbo, CHEN Minghui, WANG Renjun, et al. Inter-Sub-District operation optimization method in distribution network based on available transfer capacity of adjacent zones[J/OL]. Southern Power System Technology, 2024: 1-11[2024-08-28]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20240626.1518.007.html>(in Chinese).
- [25] 鲍若愚, 宣羿, 赵健, 等. 基于线损贡献度的同源低压配电台区拓扑数据治理方法[J/OL]. 电网技术, 2024: 1-15[2025-03-30]. <https://doi.org/10.13335/j.1000-3673.pst.2024.07.1343>  
BAO Ruoyu, XUAN Yi, ZHAO Jian, et al. Topological data governance method of homologous low-voltage distribution area based on line loss contribution degree[J/OL]. Power System Technology, 2024: 1-15[2025-03-30]. <https://doi.org/10.13335/j.1000-3673.pst.2024.07.1343>(in Chinese).
- [26] 石铨, 高红均, 罗龙波, 等. 极端高温场景下计及需求响应的配电网动态重构[J]. 电网技术, 2025, 49(1): 136-145.  
SHI Cheng, GAO Hongjun, LUO Longbo, et al. Distribution network reconfiguration considering demand response in extreme heat scenarios[J]. Power System Technology, 2025, 49(1): 136-145(in Chinese).
- [27] 郑涛, 沈文韬, 吕文轩, 等. 基于智能软开关的柔性互联配电网相间短路故障定位方法[J]. 电网技术, 2024, 48(12): 5118-5128.  
ZHENG Tao, SHEN Wentao, LYU Wenxuan, et al. Fault location method for phase-to-phase short circuit in flexible interconnected distribution network based on SOP[J]. Power System Technology, 2024, 48(12): 5118-5128(in Chinese).



何小龙

在线出版日期: 2025-04-03。

收稿日期: 2024-12-23。

作者简介:

何小龙(1999), 男, 硕士研究生, 研究方向为人工智能在配电网故障定位与恢复中的应用, E-mail: 787438918@qq.com;

高红均(1989), 男, 副教授, 博士生导师, 研究方向为配电网自动化、配电网规划运行、综合能源系统优化与市场交易等, E-mail: gaohongjun@scu.edu.cn;

王仁浚(1997), 男, 博士研究生, 通信作者, 研究方向为配电网运行优化、人工智能, E-mail: 1328860755@qq.com。

(责任编辑 徐梅)

附录 A

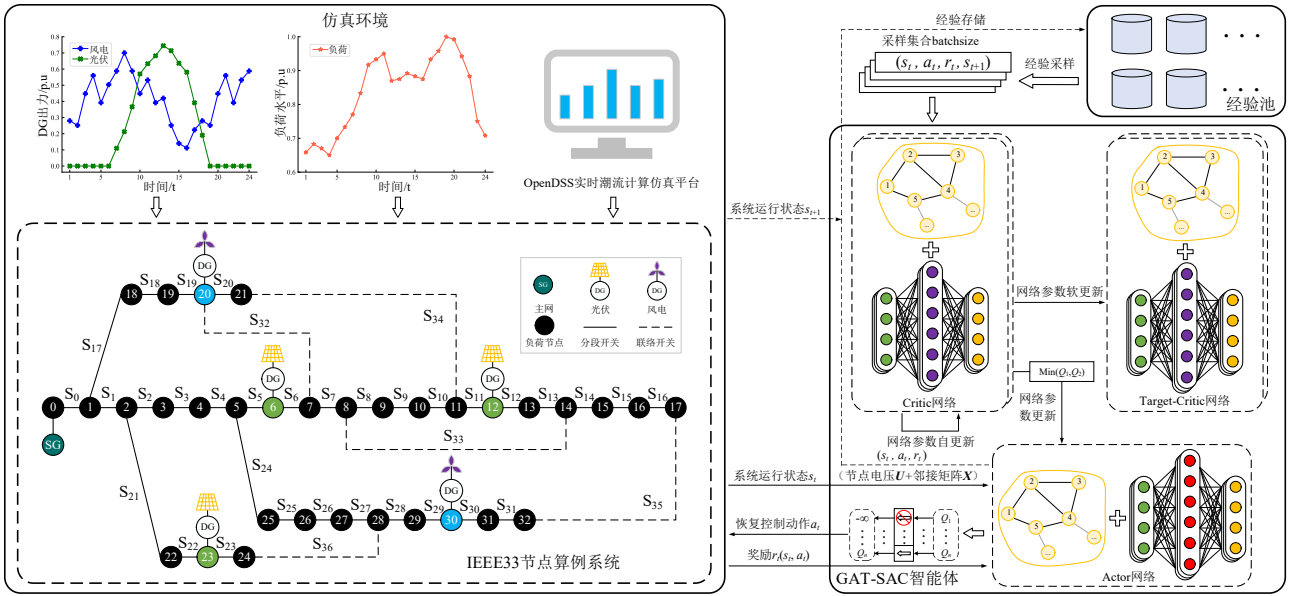


图 A1 基于 GAT-SAC 算法的有源配电网故障恢复框架

Fig. A1 Fault recovery framework of active distribution network based on GAT-SAC algorithm

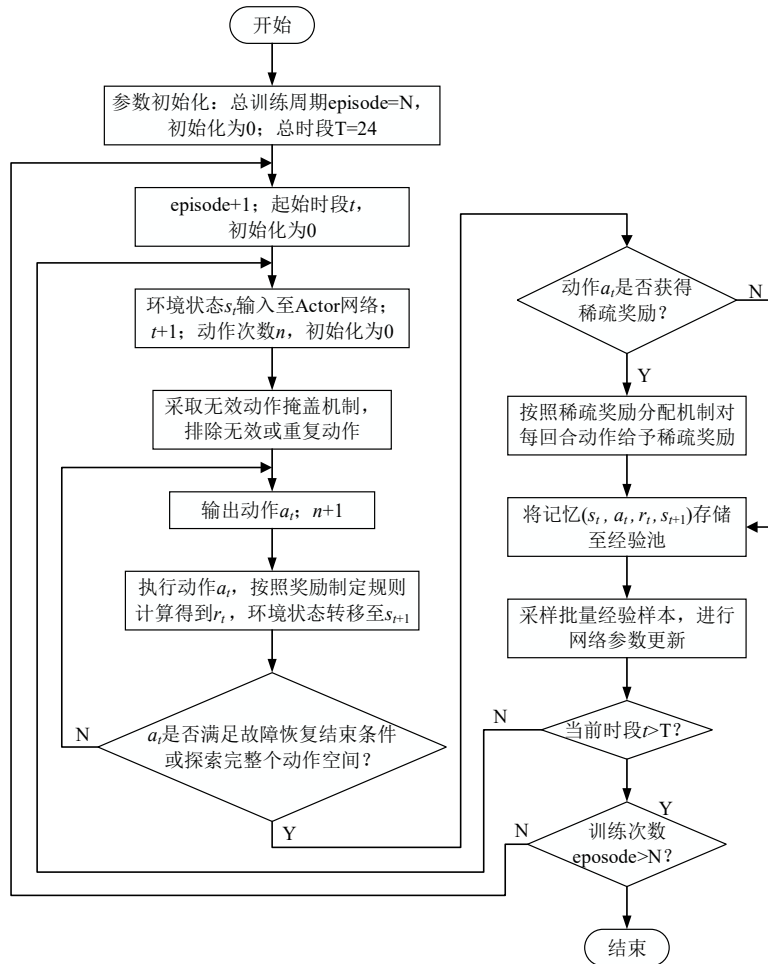


图 A2 有源配电网故障恢复模型的离线训练流程图

Fig. A2 Off-line training flow chart of active distribution network fault recovery model

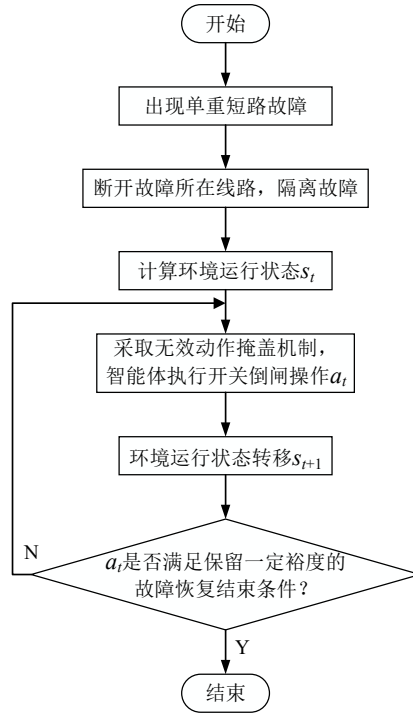


图 A3 有源配电网故障恢复模型的在线决策流程图

Fig. A3 Online decision flow chart of active distribution network fault recovery model





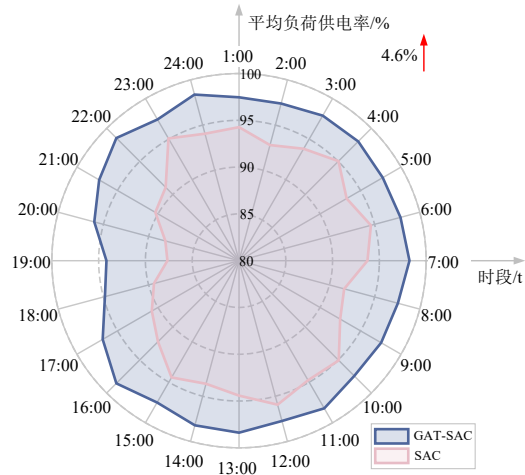
图 A4 负荷及 DG 出力

Fig. A4 Load and DG output

附录 B



(a) 删减节点数量



(b) 改变连接关系

图 B1 24 时段的平均负荷供电率

Fig. B1 24-hour average load power supply rate

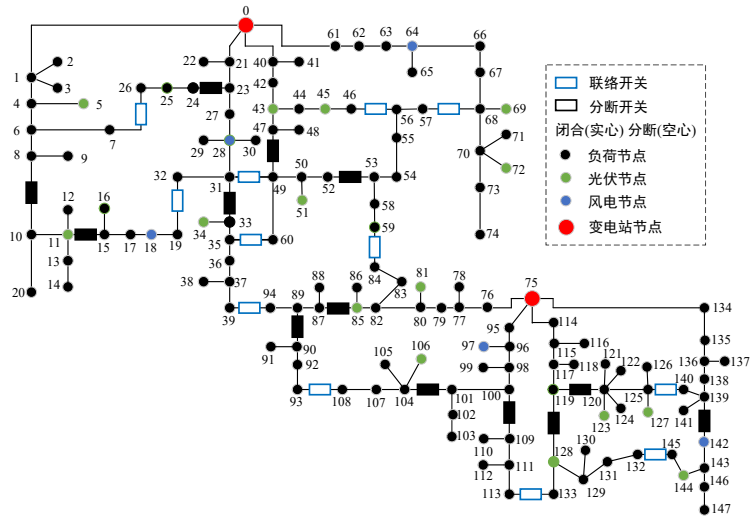


图 B2 148 节点系统拓扑

Fig. B2 Topology of the 148-bus system

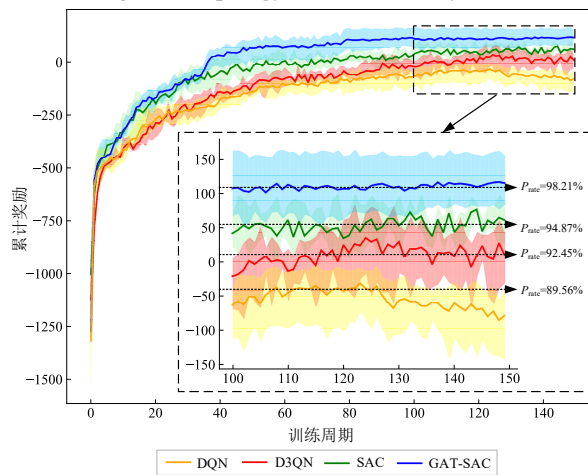


图 B3 训练过程中的各项指标

Fig. B3 Various indicators in the training process

附录 C

表 C1 分布式电源参数

Table C1 Distribution generator parameters

DG 类型	节点编号	额定容量/kW
光伏	6	500
	12	500
	23	500
风电	20	200
	30	300

表 C2 GAT-SAC 算法的故障恢复方案

Table C2 Fault recovery scheme of GAT-SAC algorithm

故障线路	故障发生时刻	故障恢复方案	负荷供电率 $P_{rate}$ (%)	网损率/%
8-9	09:00	合 S <sub>34</sub> →合 S <sub>32</sub> →断 S <sub>6</sub>	100	2.48
	14:00	合 S <sub>34</sub> →合 S <sub>36</sub> →断 S <sub>27</sub>	100	2.08
	19:00	合 S <sub>34</sub> →合 S <sub>32</sub> →断 S <sub>6</sub> →合 S <sub>36</sub> →断 S <sub>27</sub>	100	3.56
13-14	09:00	合 S <sub>33</sub> →合 S <sub>36</sub> →断 S <sub>25</sub>	100	2.94(原 3.25)
	14:00	合 S <sub>33</sub> →合 S <sub>36</sub> →断 S <sub>25</sub> →断 S <sub>31</sub>	98.38	2.28(原 2.59)
	19:00	合 S <sub>33</sub> →合 S <sub>32</sub> →断 S <sub>6</sub> →合 S <sub>36</sub> →断 S <sub>27</sub>	100	3.72(原 4.70)
26-27	09:00	合 S <sub>36</sub>	100	2.95
	14:00	合 S <sub>36</sub>	100	2.34
	19:00	合 S <sub>36</sub> →合 S <sub>34</sub> →断 S <sub>10</sub> →合 S <sub>35</sub> →断 S <sub>31</sub>	100	3.59

表 C3 各类 DRL 算法的故障恢复方案

Table C3 Fault reconstruction schemes for various DRL algorithms

DRL 算法	故障发生时刻	故障恢复方案	负荷供电率 $P_{rate}$ (%)	网损率/%	开关动作次数	电压/电流越限	环网
DQN	09:00	合 S <sub>33</sub> →合 S <sub>36</sub> →断 S <sub>24</sub> →合 S <sub>34</sub> →断 S <sub>12</sub> →断 S <sub>31</sub>	98.38	2.82	6	无	无
	14:00	合 S <sub>33</sub> →合 S <sub>34</sub> →断 S <sub>11</sub> →合 S <sub>36</sub> →断 S <sub>26</sub>	100	2.19	5	无	无
	19:00	合 S <sub>34</sub> →合 S <sub>32</sub> →断 S <sub>6</sub> →合 S <sub>33</sub> →断 S <sub>7</sub> →断 S <sub>9</sub> →断 S <sub>31</sub>	96.77	3.42	7	无	无
D3QN	09:00	合 S <sub>34</sub> →合 S <sub>33</sub> →断 S <sub>7</sub> →断 S <sub>31</sub>	98.38	2.50	4	无	无
	14:00	合 S <sub>34</sub> →合 S <sub>35</sub> →断 S <sub>31</sub>	100	2.12	3	无	无
	19:00	合 S <sub>34</sub> →合 S <sub>36</sub> →断 S <sub>26</sub> →合 S <sub>33</sub> →断 S <sub>7</sub> →断 S <sub>27</sub>	98.38	3.62	6	电压越下限	无
SAC	09:00	合 S <sub>34</sub> →合 S <sub>33</sub> →断 S <sub>13</sub> →合 S <sub>36</sub> →断 S <sub>25</sub>	100	2.72	5	无	无
	14:00	合 S <sub>34</sub> →合 S <sub>36</sub> →断 S <sub>27</sub>	100	2.08	3	无	无
	19:00	合 S <sub>34</sub> →合 S <sub>32</sub> →断 S <sub>6</sub> →合 S <sub>35</sub> →断 S <sub>31</sub> →断 S <sub>9</sub>	98.38	3.47	6	无	无
GAT-SAC	09:00	合 S <sub>34</sub> →合 S <sub>32</sub> →断 S <sub>6</sub>	100	2.48	3	无	无
	14:00	合 S <sub>34</sub> →合 S <sub>36</sub> →断 S <sub>27</sub>	100	2.08	3	无	无
	19:00	合 S <sub>34</sub> →合 S <sub>32</sub> →断 S <sub>6</sub> →合 S <sub>36</sub> →断 S <sub>27</sub>	100	3.56	5	无	无