

# 面向配电网的 AI 驱动自适应自动恢复决策算法及验证

高振宇 马婷婷 刘洋

青岛城市学院机电工程学院 青岛 266106

DOI: 10.32629/ems.v8i2.18509

**[摘要]** 配电网故障后的快速自动恢复是提升供电可靠性的关键技术之一,传统的恢复决策算法存在适应性欠佳、求解速度迟缓、难以应对复杂运行场景等状况,鉴于此现状,提出一种 AI 驱动的自适应自动恢复决策算法,首先构建配电网故障恢复多目标优化模型,综合考虑供电恢复率、网损最小化、负荷均衡度以及操作次数约束等,其次设计基于改进深度强化学习的决策框架,借助环境建模、状态表征与奖励机制优化,达成复杂场景下的快速自适应决策,最后借助理论分析与典型场景推演验证算法的可行性与优越性。研究表明,该算法可有效适配配电网拓扑变化、负荷波动以及多重故障等复杂工况,在决策速度与恢复效果方面比传统算法更具优势,为配电网故障恢复提供了新的技术路径。

**[关键词]** 配电网; AI 驱动; 自适应决策; 深度强化学习; 多目标优化

## 1 引言

配电网作为电力系统和用户直接相连的关键部分,其运行的可靠性会直接对社会生产以及居民生活产生影响,随着分布式电源渗透率不断提高、电网拓扑变得日益复杂,并且负荷特性也呈现出多元化,传统配电网故障恢复面临着许多挑战,一方面,故障场景有随机性和多样性的特点,单一的恢复策略很难适应不同的拓扑结构以及运行状态。另一方面,传统基于规则或者数学规划的恢复算法存在求解维度高以及实时性不足等问题,难以契合配电网快速恢复的实际需要。

AI 技术依靠其强大的非线性拟合能力以及自适应学习特性,为复杂配电网决策问题的解决给予了新的思路,当下机器学习、强化学习等方法已在配电网故障定位、状态估计等领域开始有了初步的应用,然而在故障恢复决策方面依旧存在关键技术瓶颈,具体包括怎样构建符合实际运行情况的决策模型、怎样达成复杂约束条件下的快速寻优以及怎样提高算法对动态工况的适应性。鉴于此,AI 驱动的自适应自动恢复决策算法,借助多目标优化建模以及改进深度强化学习框架设计,达成配电网故障后的高效且自适应的恢复,为配电网智能化运维提供技术支持。

## 2 配电网故障恢复多目标优化模型

### 2.1 目标函数设计

故障恢复的核心目标是在满足安全约束的前提下,最大化供电恢复效果并优化运行经济性,本文构建以下多目标函

数:

(1) 供电恢复率最大化: 以故障后停电负荷总量为基准,最大化恢复供电的负荷占比,表达式为:

$$f_1 = \frac{\sum_{i \in \Omega_{restored}} P_{Li}}{\sum_{i \in \Omega_{outage}} P_{Li}}$$

其中,  $\Omega_{restored}$  为恢复供电的负荷节点集合,  $\Omega_{outage}$  为故障导致停电的负荷节点集合,  $P_{Li}$  为节点  $i$  的额定负荷功率。

(2) 网损最小化: 考虑配电网运行经济性,以网络有功功率损耗最小为目标:

$$f_2 = \min \sum_{(i,j) \in E} \frac{P_{ij}^2 + Q_{ij}^2}{U_i^2} R_{ij}$$

其中,  $E$  为配电网支路集合,  $P_{ij}$ 、 $Q_{ij}$  分别为支路  $ij$  的有功、无功功率,  $U_i$  为节点  $i$  的电压幅值,  $R_{ij}$  为支路  $ij$  的电阻值。

(3) 负荷均衡度优化: 避免恢复后部分线路过载,以各支路负荷率方差最小为目标,提升电网运行稳定性:

$$f_3 = \min \sqrt{\frac{1}{|E|} \sum_{(i,j) \in E} \left( \frac{S_{ij}}{S_{ij,max}} - \bar{S} \right)^2}$$

其中,  $S_{ij}$  为支路  $ij$  的实际视在功率,  $S_{ij,max}$  为支路额定视在功率,  $\bar{S}$  为所有支路的平均负荷率。

采用加权求和法将多目标转化为单目标优化问题, 权重系数通过层次分析法 (AHP) 结合专家经验确定, 确保目标间的协调优化。

## 2.2 约束条件

(1) 功率平衡约束: 各节点的注入功率与流出功率满足功率平衡关系:

$$P_{Gi} + P_{DG,i} - P_{Li} - \sum_{j \in N_i} P_{ij} = 0$$

$$Q_{Gi} + Q_{DG,i} - Q_{Li} - \sum_{j \in N_i} Q_{ij} = 0$$

其中,  $P_{Gi}$ 、 $Q_{Gi}$  分别为节点  $i$  主网注入的有功、无功功率,  $P_{DG,i}$ 、 $Q_{DG,i}$  分别为分布式电源的有功、无功出力,  $N_i$  为节点  $i$  的相邻节点集合。

(2) 电压约束: 节点电压幅值需在允许范围内波动, 即  $U_{min} \leq U_i \leq U_{max}$ , 其中  $U_{min}$ 、 $U_{max}$  分别为节点电压的下限与上限。

(3) 支路容量约束: 支路传输功率不得超过额定容量,  $S_{ij} \leq S_{ij,max}$ 。

(4) 拓扑约束: 配电网恢复后需保持辐射状结构, 无环网运行, 且故障区域与非故障区域有效隔离。

(5) 操作次数约束: 考虑开关设备使用寿命, 单次故障恢复的开关操作次数需小于设定阈值  $K_{max}$ 。

## 3 AI 驱动自适应决策算法设计

### 3.1 算法框架

本文构建了一种基于改进深度确定性策略梯度 (DDPG) 的自适应决策框架, 其核心思路在将故障恢复过程塑造为马尔可夫决策过程 (MDP), 借助智能体与配电网环境的相互作用来学习最优恢复策略, 该框架主要囊括环境建模、状态表征、动作空间设计以及奖励机制优化这四个部分。

### 3.2 环境建模与状态表征

配电网故障恢复所处的环境呈现出动态变化以及不确定的特性, 需要对电网运行状态以及故障信息进行全面分析, 在此基础上, 状态向量  $s$  被定义如下:

$$s = [U_1, U_2, \dots, U_n; P_{L1}, P_{L2}, \dots, P_{Ln}; P_{DG1}, \dots, P_{DGm}; S_1, \dots, S_l; F]$$

其中,  $U_1, U_2, \dots, U_n$  为节点电压向量,  $P_{L1}, P_{L2}, \dots, P_{Ln}$  为

负荷功率向量,  $P_{DG1}, \dots, P_{DGm}$  为分布式电源出力向量,  $S_1, \dots, S_l$  为支路功率向量,  $F$  为故障位置与类型编码。通过标准化处理将状态向量映射至  $[0, 1]$  区间, 提升模型训练稳定性。

### 3.3 动作空间设计

动作空间所对应的是配电网开关操作集合, 其中囊括了分段开关以及联络开关的分合操作, 鉴于开关操作存在物理约束, 故而采用离散动作编码方式, 每一个动作都对应着一组合法的开关操作序列, 为了降低动作空间的维度, 借助拓扑分析对无效操作进行预先筛选, 只保留可行动作集合, 以此提升决策效率。

### 3.4 奖励机制优化

奖励机制对于强化学习模型的收敛起着关键作用, 在实际应用中需要同时考虑即时奖励与长期奖励两个方面, 以此来引导智能体去学习最优恢复策略, 总奖励  $r$  的定义如下:

$$r = \alpha r_1 + \beta r_2 + \gamma r_3 - \delta r_4$$

其中:

$r_1$  为供电恢复率奖励, 与目标函数  $f_1$  正相关, 恢复率越高奖励越大;

$r_2$  为网损优化奖励, 与目标函数  $f_2$  负相关, 网损越小奖励越大;

$r_3$  为负荷均衡奖励, 与目标函数  $f_3$  负相关, 负荷均衡度越好奖励越大;

$r_4$  为开关操作惩罚, 操作次数越多惩罚越大, 避免不必要的操作;

$\alpha, \beta, \gamma, \delta$  为权重系数, 通过试错法确定最优值 (本文取值分别为 0.4、0.2、0.2、0.2)。

引入终端奖励机制, 在恢复过程契满足终止条件时, 即供电恢复率达到 95% 以上或者达到最大迭代次数时, 给予额外的终端奖励, 以此来加速模型的收敛。

### 3.5 模型训练与优化

运用改进的 DDPG 算法来开展模型训练: 借助经验回放机制把智能体与环境交互所产生的数据进行存储, 以此防止因样本相关性而引发的训练震荡现象, 引入目标网络以及策略网络的软更新策略, 提升模型的稳定性, 采用自适应学习率调整机制, 在训练初期使用较大的学习率来加速收敛, 到

了后期则降低学习率以优化收敛精度。在训练进程中,利用早停法来避免出现过拟合情况,当验证集奖励值连续 100 轮都没有提升的时候就停止训练。

#### 4 算法理论验证与适应性分析

##### 4.1 理论可行性验证

从数学方面对算法的收敛性以及最优性展开验证:配电网故障恢复 MDP 环境有马尔可夫性,也就是说下一状态仅仅和当前状态以及动作存在关联,和历史状态并无关系,并且动作空间以及状态空间都是有限集,依据马尔可夫决策过程理论,可得出存在最优平稳策略,改进的 DDPG 算法借助策略梯度上升来使累积奖励最大化,同时结合经验回放以及软更新机制,以此保证模型可以收敛到最优策略,多目标优化模型的目标函数以及约束条件都契合连续性与凸性,经过加权求和法转化而成的单目标函数存在唯一最优解,为算法寻优奠定理论基础。

##### 4.2 复杂场景适应性分析

针对配电网常见的复杂工况,分析算法的自适应能力:

(1) 拓扑变化场景:在配电网开展线路扩容、新增分支或者调整联络开关布局的情况下,算法可凭借状态表征自行识别拓扑变化,并不需要重新训练模型,仅仅借助少量的在线学习便可以适配新拓扑,呈现出不错的拓扑适应性。

(2) 负荷波动场景:充分考虑负荷所有的时变性特点,例如高峰负荷以及低谷负荷等情况,同时兼顾其随机性,分布式负荷接入这种状况,在此场景下,算法借助实时更新负荷功率状态向量的方式,对恢复策略进行动态调整,即便处于负荷波动范围之内,依旧可维持较高的恢复效果以及运行经济性。

(3) 多重故障场景:一旦配电网出现多区域以及多类型故障,该算法可凭借故障编码精确识别故障分布情况,会优先对关键负荷区域展开恢复工作,借助分步决策达成全局最优恢复效果,以此避免单一故障恢复策略所存在的局限性。

(4) 分布式电源不确定性场景:分布式电源输出功率有随机性,这有可能对恢复策略的安全性产生影响,算法会实时收集分布式电源的出力数据,并把这些数据纳入状态向量之中,动态调整功率平衡约束,以此保证在恢复过程里电网电压以及支路功率可符合安全要求。

#### 5 结论

本文提出一种 AI 驱动的配电网自适应自动恢复决策算法,借助构建多目标优化模型以及改进深度强化学习框架,达成复杂场景里的快速且高效的故障恢复,理论分析显示,此算法有良好的收敛性与适应性,可切实应对配电网拓扑变化、负荷波动、多重故障等复杂工况,在提高供电恢复率的同时优化运行经济性。

未来的研究方向可涉及以下几个方面:其一,引入迁移学习技术,把已经训练好的模型迁移到有不同拓扑结构的配电网当中,以此来降低训练所需的成本,其二,考虑如极端天气等不确定性因素,提升算法在恶劣工况条件下的鲁棒性,其三,结合数字孪生技术,构建出虚实融合的决策环境,提升决策的精度以及实时性。

#### [参考文献]

[1]魏然,何岩岩,陆啸天,付丽伟.基于自适应 SA-DE 算法的含新能源配电网拓扑优化方法[J].能源与环保,2025,47(11):274-280.

[2]宫以阁.基于自适应权重粒子群算法的配电网无功优化配置分析[J].电力设备管理,2025,(19):184-186.

[3]孙亮,沈骏杰,党翠,张宗振,刘书宁.数据驱动下最小闭包椭圆集面向承载力提升的配电网鲁棒优化调度[J].电网技术,1-14.

[4]沈颖,孙继欣,陈炜琦.面向有源配电网的业务驱动的数字孪生数据质量模型研究[J].东华大学学报(自然科学版),2024,50(02):144-152.

[5]路小俊,吴在军,李培帅,沈嘉伟,胡敏强.面向光伏集群的配电网模型-数据联合驱动无功/电压控制[J].电力系统自动化,2024,48(09):97-106.

[6]陈楚昭,孙云莲.基于自适应 NSGA-II 算法的配电网多故障抢修优化决策[J].电力工程技术,2022,41(03):125-132.

[7]陆怀谷,刘绍东,张渊,张伟,张华成,严以臻,李亚杰,薛镭刚,陈静.基于自适应粒子群算法的增量配电网电源博弈规划[J].南京理工大学学报,2021,45(02):150-157.

[8]柴雁欣,向月,刘俊勇.面向可靠性提升的关联规则驱动下配电网投资规划优选模型与方法[J].电力自动化设备,2020,40(03):85-92.