

基于多智能体深度强化学习的随机事件驱动故障恢复策略

王冲¹,石大奋¹,万灿²,陈霞³,吴峰¹,鞠平¹

(1. 河海大学 电气与动力工程学院,江苏 南京 211100;2. 浙江大学 电气工程学院,浙江 杭州 310027;
3. 华中科技大学 电气与电子工程学院,湖北 武汉 430074)

摘要:为了减少配电网故障引起的失负荷,提升配电网弹性,提出一种基于多智能体深度强化学习的随机事件驱动故障恢复策略:提出了在电力交通耦合网故障恢复中的随机事件驱动问题,将该问题描述为半马尔可夫随机决策过程问题;综合考虑系统故障恢复优化目标,构建基于半马尔可夫的随机事件驱动故障恢复模型;利用多智能体深度强化学习算法对所构建的随机事件驱动模型进行求解。在IEEE 33节点配电网与Sioux Falls市交通网形成的电力交通耦合系统中进行算例验证,结果表明所提模型和方法在电力交通耦合网故障恢复中有着较好的应用效果,可实时调控由随机事件(故障维修和交通行驶)导致的故障恢复变化。

关键词:随机事件驱动;故障恢复;深度强化学习;电力交通耦合网;多智能体

中图分类号:TM732

文献标志码:A

DOI:10.16081/j.epae.202501003

0 引言

近年来,随着全球气候变化的加剧,由台风等极端事件导致的电网线路断线事故发生频率日益增加,由线路断线导致的停电事件不仅给人民的生活、工作带来不便,也严重影响了正常的社会生产。配电网作为连接输电系统与用户之间的纽带,是电力系统保供运行的重要环节,当极端灾害发生时,配电网不仅要尽量减少供电损失,更要在灾后以最快的速度对故障线路进行修复,恢复正常供电。因此,综合考虑城市配电网各方面信息,制定高效可靠的恢复策略至关重要。

对于提升配电网应对极端灾害的弹性^[1]而言,充分利用电网各组成部分增强负荷恢复方面已有较多研究,文献[2]针对含智能软开关的配电网负荷恢复问题,提出一种重要负荷两步式恢复方法,利用智能软开关的有功无功调控能力提升重要负荷恢复效果;文献[3]考虑配电网中分布式新能源出力不确定性的影响,通过动态划分微电网实现负荷恢复;文献[4]将网络重构与孤岛构建相结合,通过一种完全分散的多智能体自动化系统实现负荷恢复优化;文献[5]通过建立混合整数线性规划模型综合协调故障隔离、网络重构、分布式电源重调及机组/资源调配对负荷恢复的影响;文献[6]考虑分布式电源在停电后对负荷的恢复作用,以负荷供电时间最大及网损最小为目标,提出多源协同的配电网恢复决策方法;文献[7]同样采用多源协同供电恢复方案,在路-电

耦合背景下考虑移动储能的优化调度,通过两阶段优化制定孤岛运行策略;文献[8]综合考虑配电网恢复方案与移动储能行驶路径,在灾后恢复中实现移动储能路径的动态引导;文献[9]针对故障后的负荷转供,将其建模为马尔可夫决策过程,并通过深度强化学习算法进行求解;文献[10]将馈线开关状态表示为马尔可夫状态,通过马尔可夫决策过程优化系统重构策略,减少潜在负荷损失;文献[11]考虑车辆并网后电动汽车的反向供电,在有效评估电动汽车响应潜力的基础上实现供电恢复经济调度;文献[12]将电动汽车反向供电与配电网重构相结合制定灾后负荷恢复方案。以上研究充分利用配电网已有资源,有效解决了配电网线路受损下的负荷恢复问题。

故障后,对受损线路进行高效抢修也是弹性提升重要一环^[13],文献[14]提出一种极端天气下配电系统运行与维修人员检修路径协同优化方法,通过两阶段优化策略减小配电网故障恢复时间;文献[15]在研究抢修小队故障维修策略的同时考虑应急发电车的负荷供电作用,综合故障点位置及通信情况动态抢修配电网;文献[16]考虑通信系统对故障恢复的影响,将修复电力和通信故障所带来的负荷恢复价值进行统一折算,综合考虑负荷恢复价值及故障恢复时间确定抢修方案;文献[17]考虑了交通网和配电网的耦合信息,综合协调多种资源实现故障抢修;文献[18]提出一种考虑路网中移动电源及线路运维班组协同调度的配电网关键负荷恢复策略;文献[19]同样采用移动储能及运维人员协同优化的方法来减小故障恢复时间并在极端事件发生前对应急站的位置进行预分配;文献[20]考虑故障发生的不确定性,在灾前对维修队进行预调度,并在灾后协同调度维修队、分布式发电机、储能等灵活性资源。由上述可知,当前已有较多研究在配电网故障

收稿日期:2024-04-23;修回日期:2024-12-23

在线出版日期:2025-01-07

基金项目:国家自然科学基金资助项目(52277088)

Project supported by the National Natural Science Foundation of China(52277088)

抢修中考虑交通路网影响,然而,上述文献中对于交通时间、故障维修时间的处理大多通过历史数据预测或设为恒定值,并未考虑其随机性对运维决策点带来的影响,在实际故障恢复中,交通时间及故障维修时间的变化将实时影响运维班组的故障维修决策。

基于上述分析,本文聚焦极端灾害发生后的故障恢复过程,将实际故障抢修过程中的随机交通时间及维修时间纳入考量,依据交通事件及维修事件进行情况对线路运维班组采取实时调控。同时,由于交通行驶及故障维修为交替进行,具有序贯性,故整个灾后抢修可描述为一个随机事件驱动过程。本文根据随机事件驱动的特征将该问题转化为半马尔可夫随机决策过程问题,构建基于半马尔可夫随机事件驱动的故障恢复模型,并针对半马尔可夫决策过程(semi-Markov decision process, SMDP)的模型特点,采用多智能体深度强化学习方法进行求解。最后,通过 IEEE 33 节点配电网与 Sioux Falls 交通网耦合系统进行算例验证,结果表明所提方法可有效解决故障维修的随机事件驱动问题,动态调控运维班组的维修路径。

1 电力交通耦合网随机事件驱动问题

1.1 随机事件驱动问题描述

对于电力交通耦合网故障恢复而言,当配电网多处存在故障时,合理分配运维班组的维修任务,对故障点进行高效抢修至关重要。实际情况下,由于运维班组交通时间及故障维修时间的不确定性,下一步维修目标的选择往往由过去积累的维修经验、当前维修完成后各故障点的状态及其他运维班组所处的位置综合决定,本质上是一种由随机事件驱动的决策问题^[21],仅通过优化模型求解得到的运维路径并不能完全满足实际维修需求。本文所考虑的维修情形即为线路运维班组根据当前维修情况实时选择运维路径问题。为此,建立电力交通耦合网随机事件驱动故障恢复模型。

电力交通耦合网随机事件驱动故障恢复模型如图 1 所示,对于故障节点数大于线路运维班组数的情况,运维班组从运维站出发,经过道路行驶到达故障点,完成故障点维修后,根据当前配电网仍然存在的故障点及其他线路运维班组的维修情况选择本队伍下一步的维修目标。

对于图 1(a)所示交通网中存在的由配电网耦合导致的故障点 3、7、10、13,线路运维班组 1、2 分别自运维站到达节点 3、10 进行故障维修,考虑到故障损伤程度及维修人员操作速度的影响,对于两线路运维班组的维修时间并不能做到准确预测,此时可能出现以下 3 种情形。

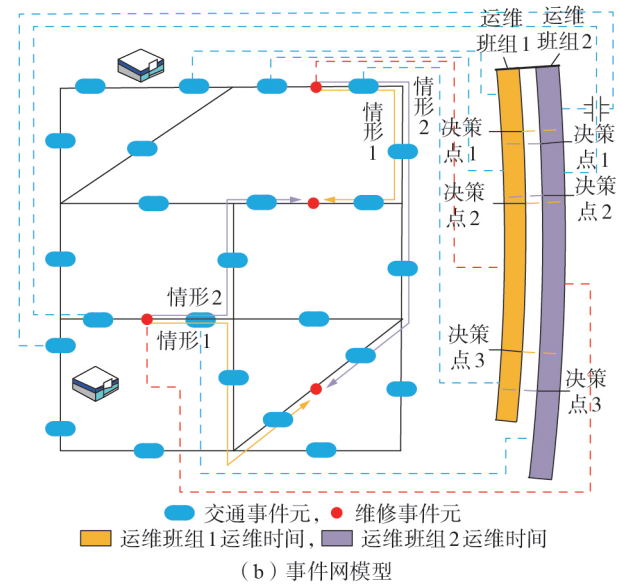
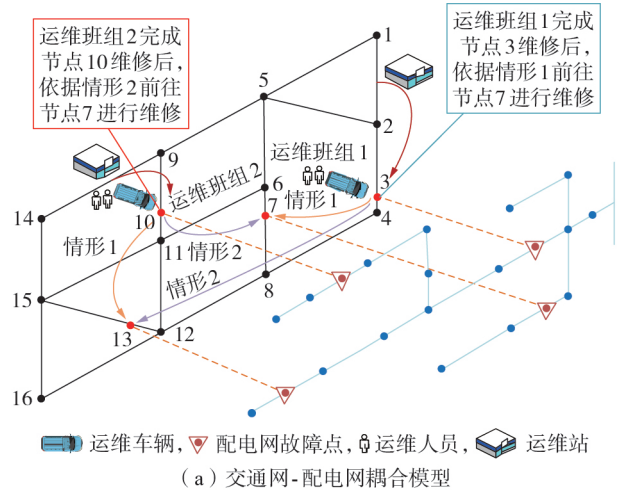


图 1 电力交通耦合网随机事件驱动故障恢复模型

Fig.1 Uncertain event-driven fault recovery model of power traffic coupling network

情形 1:线路运维班组 1 率先完成对节点 3 的故障维修,此时线路运维班组 2 仍在维修节点 10 的故障,考虑到配电网负荷恢复效率,线路运维班组 1 接下来驱车前往节点 7 进行故障维修,在其到达节点 7 后,线路运维班组 2 完成节点 10 维修并前往节点 13 进行故障维修。

情形 2:线路运维班组 2 率先完成对节点 10 的故障维修,接下来驱车前往节点 7 进行故障维修,到达节点 7 后,线路运维班组 1 完成节点 3 的故障维修,前往节点 13 进行故障维修。

情形 3:线路运维班组 1 率先完成对节点 3 的故障维修,在驱车前往故障节点 7 的路途中,运维班组 2 完成对节点 10 的故障维修且提前到达节点 7,运维班组 1 在下一个路口节点改变方向前往节点 13 进行故障维修。

上述均为实际故障维修中可能出现的情形,由

于各运维班组的路径选择皆取决于故障维修完成时间及交通到达时间,如图1(b)所示,可将故障维修过程及交通过程以事件元的形式表示,只有将单个事件元的任务完成才能选择下一个事件,线路运维班组在事件网中经多个交通事件元到达维修事件元,当全部维修事件元任务均被完成后,故障恢复结束。而交通事件元及维修事件元的完成时间都具有随机性,故本问题可描述为由随机事件驱动的电力交通耦合网故障恢复问题。即使如图1所示的简单系统也可能存在多种难以枚举的情况,而实际维修中更加复杂的交通网-配电网耦合系统则需要采用更合适的方法解决此类问题。

1.2 随机事件驱动问题分析

获取灾害导致的故障点信息后,多个线路运维班组从运维站出发,前往其各自分配的故障点进行维修。由图1(b)可见,由于线路运维班组完成交通事件元及维修事件元的时间具有随机性,而各决策时间点皆在事件完成之后,故各运维班组下一步的路径选择仅与当前决策时刻状态有关。上述问题对于线路运维班组本质上是一种半马尔可夫决策过程问题^[22]。以图1为例,以线路运维班组为智能体,其所处电力交通耦合网为强化学习环境,则上述问题可进一步描述为深度强化学习多智能体训练问题,对半马尔可夫决策过程的要素 $\mathcal{M}=\{S, A, R, P\}$ 的具体解释如下。

S: 状态集合,在本问题中状态包括各运维班组位置及故障点维修情况。

A: 动作集合,在本问题中为线路运维班组所处交通网节点所能选择的路径集合。

R: 动作奖励,在本问题中包括负荷损失惩罚、道路交通成本以及维修奖励。

P: 状态转移概率函数,在本问题中,线路运维班组动作后的下一步状态是确定的,故当前时刻状态至下一步状态之间的转移概率为1。

总体决策过程描述为:在某一决策时刻,智能体根据当前观察到的环境状态 s , 从可供智能体选择的有限动作集中选取动作 a , 智能体所处环境在动作 a 的作用下,于下一步到达状态 s' 并获得奖励 r , 智能体在下一决策时刻根据状态 s' 再次选择动作 a' , 如此循环。系统下一步的状态 s' 仅与当前时刻状态 s 及动作 a 有关,与之前的状态或动作无关,而决策时间具有随机性,环境的状态具有半马尔可夫性。由于交通到达时间及维修时间的随机性,各线路运维班组理论上不存在同时决策的可能。

2 随机事件驱动故障恢复问题建模

2.1 故障恢复模型

2.1.1 目标函数

为了量化电力交通耦合网的弹性恢复能力,本

文采用最小化加权负荷损失与总负荷的比值作为目标函数 f , 如式(1)所示。

$$f = \frac{\int_0^T \sum_{i=1}^N \omega_i P_{i,t}^{\text{loss}} dt}{W^{\text{all}}} \quad (1)$$

$$W^{\text{all}} = \int_0^T \sum_{i=1}^N \omega_i P_{i,t}^{\text{all}} dt \quad (2)$$

式中: T 为故障抢修限定完成时间; N 为配电网节点数; ω_i 为节点 i 负荷权重; $P_{i,t}^{\text{loss}}$ 为节点 i 在 t 时刻的负荷损失; W^{all} 为故障抢修限定时间内各节点在非故障情况下的负荷总量,在优化过程中为固定值; $P_{i,t}^{\text{all}}$ 为节点 i 在 t 时刻的正常负荷。

2.1.2 约束条件

考虑到配电网故障恢复特性及负荷特性,本文模型所考虑的约束条件包括电力传输约束、节点通电约束、冷负荷恢复(cold load pickup, CLPU)^[23]约束、维修时间约束和道路交通时间约束,具体表达式见附录A式(A1)~(A8)。

2.1.3 随机事件驱动的半马尔可夫决策过程模型

本文所要解决的问题为由随机事件驱动的半马尔可夫决策过程问题,该决策模型的收益函数为即时收益和与状态驻留时间相关的累积收益之和,结合事件驱动特点,当前状态下的期望收益定义为:

$$V_f(s_k, a_k) = G(s_k, a_k) + \sum_{s'_k} P_{s'_k}^{a_k} \left(\int_{t_b}^{t_e} \Delta P^{\text{loss}} dt + V_f(s'_k, a'_k) \right) \quad (3)$$

式中: $V_f(s_k, a_k)$ 为智能体在状态 s_k 下选择动作 a_k 的未来期望收益; s'_k 为下一步状态; $P_{s'_k}^{a_k}$ 为动作 a_k 下的状态转移概率,由于本文道路选择后下一步状态是确定的,故 $P_{s'_k}^{a_k}$ 的值为1; $G(s_k, a_k)$ 为当前状态采取动作后获得的即时收益; t_b 和 t_e 分别为状态 s'_k 的起始和结束时刻,皆具有随机性; ΔP^{loss} 为负荷缺额; $\int_{t_b}^{t_e} \Delta P^{\text{loss}} dt$ 为状态 s'_k 驻留时间内的负荷损失。

对于智能体动作后的即时收益,本文中仅包括线路运维班组道路行驶的交通成本,在动作确定的情况下有:

$$G(s_k, a_k) = C_{l_{tr}} \quad l_{tr} \in \mathcal{L}_{tr} \quad (4)$$

式中: l_{tr} 为智能体采取动作 a_k 后运维班组在实际交通网中行驶的道路; \mathcal{L}_{tr} 为交通网道路集合; $C_{l_{tr}}$ 为道路 l_{tr} 的交通成本。

本文所要达到的目标为负荷损失最小,反映到半马尔可夫决策过程模型中为期望收益最大,而式(3)中等号右侧的元素皆为损失量,故智能体在当前状态的最优期望收益为:

$$Q(s_k) = \operatorname{argmin}_{a_k \in A} V_f(s_k, a_k) \quad (5)$$

式中: $Q(s_k)$ 为智能体在 s_k 下的最优期望收益。由于

$V_i(s_k, a_k)$ 表示收益期望值而非实际值,故式(5)仅表示收益期望最大。

2.2 随机事件驱动多智能体深度强化学习算法

本文对于电力交通耦合网随机事件驱动故障恢复问题采用多智能体深度强化学习算法进行求解,各智能体间为完全合作关系,强化学习算法采用近端策略优化(proximal policy optimization, PPO)算法,实现架构为中心化训练+中心化决策,完全中心化可获得较好的决策效果,虽然该架构存在决策通信延迟,但对于运维班组路径决策而言,短时间的延迟并不会产生较大影响。

2.2.1 多智能体完全合作关系

对于存在 m 个智能体的深度强化学习系统,各智能体间共享环境,彼此相互影响。在本文的完全合作关系设定下, m 个智能体之间存在以下特性^[24]:

$$\begin{cases} R_1 = R_2 = \dots = R_g = \dots = R_m \\ S_1 = S_2 = \dots = S_g = \dots = S_m \\ A_1 = A_2 = \dots = A_g = \dots = A_m \end{cases} \quad g=1, 2, \dots, m \quad (6)$$

式中: R_g 为智能体 g 的奖励函数; S_g 为智能体 g 的状态空间; A_g 为智能体 g 的动作空间。

式(6)表明,对于本文完全合作关系下的多智能体系统,各智能体之间共享奖励函数,面向同一个训练目标,具有相同的状态空间及动作空间。

2.2.2 PPO 算法

PPO 算法是 OpenAI 在 2017 年提出的一种基于策略梯度的强化学习算法^[25],是当前应用较为广泛的算法之一。

PPO 算法为演员-评论家(actor-critic, AC)结构算法的一种,其包含一个参数为 θ 的策略网络 $\pi(a|s; \theta)$,相当于演员(actor),用于控制智能体动作;一个参数为 ω 的价值网络 $v(s; \omega)$,相当于评论家(critic),其评分帮助策略网络(演员)改进动作选择。

相较于传统 AC 算法, PPO 算法在收敛速度及样本利用率上具有优势。当前, PPO 算法已经多次被应用于路径规划相关的研究中,在船舶驾驶^[26]、机器人路径寻优^[27]等方面均展现出了较好的控制效果。本文研究极端灾害发生后基于随机事件驱动的电力交通耦合网恢复路径规划方法,通过 PPO 算法进行求解十分有效。

2.2.3 观察空间

智能体观察空间指智能体在环境中探索时所能观察到的状态,并依据该观察量决定下一步的动作选择。对于线路运维班组而言,其只能根据未维修故障点位置、自身位置以及其他线路运维班组位置做出决策,故将各智能体观察空间定义为:

$$S_{\text{ob}} = \{L_{i_1}^{\text{fall}}, L_j^{\text{self}}, L_j^{\text{part}}\} \quad (7)$$

式中: S_{ob} 为智能体观察空间; $L_{i_1}^{\text{fall}}$ 为未维修故障点 i_1 的位置; L_j^{self} 为线路运维班组 j 自身所处位置; L_j^{part} 为该运维班组除自身以外其他线路运维班组所处位置。在训练完成后的实际决策中,智能体依据以上观察空间中的 3 个确定性信息进行动作选择。

2.2.4 动作空间

智能体动作空间指智能体在当前决策时刻所处状态下所能选择的动作集合,在本文中为智能体所处交通节点下所能选择的路径方向,将各个路径方向进行编号,得到的动作空间定义为:

$$A_{\text{act}} = \{A_d^1, A_d^2, \dots, A_d^{N_d}\} \quad (8)$$

式中: A_{act} 为智能体动作空间; $A_d^1 - A_d^{N_d}$ 为智能体在交通节点 d 所能选择的动作方向, N_d 为智能体在交通节点 d 所能选择的动作方向个数,编号规则为将与节点 d 相连的节点按从小到大的顺序进行编号。

2.2.5 奖励函数

本文训练模型的奖励函数主要包括由负荷恢复时间及恢复量的变化带来的奖励函数、由道路交通成本带来的训练惩罚、对故障点修复及节点通电给予维修激励 3 个部分,如式(9)~(12)所示。

$$R' = - \sum_{e=1}^N \omega_e \int_{t_e^c}^{t_e} \lambda_e P_{e,t}^{\text{loss}} dt \quad (9)$$

$$R'' = -C_{t_e} \quad (10)$$

$$R''' = R_{\text{fix}} + R'_{\text{fix}} \quad (11)$$

$$R_{\text{re}} = R' + R'' + R''' \quad (12)$$

式中: R' 为负荷损失部分的奖励函数; R'' 为交通部分的奖励函数,主要包括交通成本惩罚; R''' 为维修奖励; R_{fix} 为故障点修复奖励; R'_{fix} 为节点恢复通电奖励; R_{re} 为总奖励函数; ω_e 为配电网节点 e 负荷权重; t_k 为当前状态时刻; λ_e 为配电网节点 e 失负荷状态变化标示量,若失负荷状态发生变化,则 $\lambda_e=1$,否则 $\lambda_e=0$; t_e^c 为节点上一失负荷状态起始时刻。对于不含冷负荷的失负荷节点,当节点恢复通电时,节点失负荷状态发生改变,对应地,其原有失负荷状态起始时间为系统维修过程起始时间;对于含冷负荷的配电网失负荷节点,自节点恢复负荷起,以智能体上一决策时刻为上一失负荷状态起始时间,当 $\lambda_e=1$ 时,更新 t_e^c 。交通时间及维修时间的随机性会对配电网节点失负荷状态改变产生影响。本文对于负荷损失以惩罚的形式展开,通过缩短故障维修时间可以减少负荷损失的惩罚量,而道路交通成本及维修奖励则是为了避免智能体在某个决策点附近徘徊的情况,以此激励强化学习智能体迅速遍历故障点。由于本文中多智能体之间为完全合作关系,故只存在 1 个奖励函数。

2.2.6 神经网络模型

本文所采用的智能体神经网络结构如附录 B 图

B1所示,各智能体神经网络结构相同,策略网络及价值网络皆由1个输入层、3个隐藏层及1个输出层组成。策略网络输入为观测状态 s ,包括未维修故障点位置、自身位置及其他智能体位置,输出为动作概率分布。价值网络的输入与策略网络相同,输出为状态价值。本文采用ReLU函数作为神经网络激活函数。

2.2.7 算法训练流程

本文的多智能体PPO算法训练流程框架如附录B图B2所示,由于采用完全中心化架构,故各智能体具有相同的价值网络,对于智能体的每个训练周期,训练流程如下。

1)初始化:对策略网络及价值网络的参数进行初始化操作。

2)数据采集:根据智能体 g 所观察环境中当前时间步状态 $s_{g,t}$ 及策略网络选择的动作 $a_{g,t}$ 获取下一时间步的状态 $s'_{g,t}$ 及从环境获得的奖励 $r_{g,t}$,并将一组状态-动作数据 $(s_{g,t}, a_{g,t}, s'_{g,t}, r_{g,t})$ 存入经验缓冲区直至存满。

3)优势估计计算:通过价值网络对经验缓冲区中的每一组状态-动作数据进行价值计算,得到对应的优势函数 $A_g^{adv}(s, a)$ 。

4)网络参数更新:通过优势函数计算策略网络损失 A_g^{loss} 与价值网络损失 C^{loss} ,并更新网络参数。

5)循环训练:重复步骤2)—4),直至训练满足预定停止条件或达到最大训练回合数时结束训练。

3 算例分析

为验证本文所提基于深度强化学习的电力交通耦合网随机事件驱动故障恢复策略的有效性,将其应用于基于Sioux Falls市交通网^[28]与IEEE 33节点配电网^[29]形成的交通网-配电网耦合系统,系统拓扑图如附录B图B3所示。模型求解工具为MATLAB R2022b的RL强化学习工具箱。

3.1 算例系统

算例系统如图B3所示,其中交通网节点记为 $X_1—X_{35}$,配电网节点记为 $Y_1—Y_{33}$ 。电力交通耦合网中:节点 $X_1—X_{24}$ 为交通网原有交通节点;节点 $X_{25}—X_{27}$ 为运维站所处交通网位置,也是3个线路运维班组的起始位置;节点 $X_{28}—X_{35}$ 为配电网故障点在交通网上的映射位置。

3.2 事件驱动下三运维班组训练结果分析

本模型以每回合300步进行训练,经10000次训练所得回合奖励曲线如图2所示。

对于本文所采用PPO算法的多智能体训练,其奖励函数约在第4000回合开始收敛,经10000次训练得到的期望奖励值为41145。而在多次训练之后




图2 三运维班组10000次训练奖励曲线

Fig.2 10000 training reward curves for three line operation and maintenance teams

仍存在部分回合奖励值偏低的情况,这主要是因为智能体在多次训练过程中仍将对动作策略进行调整,而所调整的策略有误的情况下便会导致训练奖励下降。由于负荷损失奖励为负值,考虑到强化学习算法的寻优目标为奖励函数值最大,若所有奖励皆为负奖励,智能体会选择避开故障点来避免奖励函数的减小。故在实际奖励函数设置中,为使多智能体尽快覆盖全部故障点,对故障修复及负荷节点通电给予额外的固定修复奖励。本文模型的智能体训练奖励曲线如附录B图B4所示。

本文模型的三智能体5000次训练奖励曲线如附录B图B4(a)所示。由图可知,5000次训练的奖励收敛值要小于10000次,且在训练回合数到达10000次附近时,奖励曲线变化已经相当缓和,考虑到训练效果及训练效率,本算例采用10000次训练结果作为分析对象。

某几次随机时间情形下,各线路运维班组对于故障点的选择及运维完成时间如附录B图B5所示。由图中数据可知,由于维修时间及交通时间的不确定性,由随机事件驱动导致的故障修复顺序存在差异,由此导致各线路运维班组对于故障点的选择也随事件驱动产生变化,在故障发生后,3个线路运维班组开始的路径选择基本确定,而在到达某一交通节点或完成某一故障点维修后,其路径选择开始受随机事件影响,所以由随机事件驱动导致的运维路径变化主要存在于后续路径的选择。

为进一步体现随机事件驱动对故障维修决策的影响,表1列出了某两运维班组处于几种不同事件元情况下对另一运维班组路径选择的影响,由于受到训练次数的限制且智能体训练的环境相对固定,智能体仅对当前算例环境下可能发生的情形做出反应。对于非决策班组,以D、E代指其序号,由于决策点皆为交通节点,故表中仅以数字表示交通节点。

由表1中决策1、2的数据可知:当班组A位于同一决策点时,由于班组B、C所处事件元不同,班组A的选择也不尽相同,对于故障点 X_{29} 未维修的情况,班组A在到达 X_8 后会率先进往 X_{29} 进行故障维修;而

表1 不同事件元对线路运维班组决策的影响

Table1 Influence of different event elements on line operation and maintenance teams' decisions

决策	当前决策班组	决策班组位置	班组选择	D事件元	E事件元	已维修/正维修故障点	未维修故障点
1	A	8	前往16	维修30	维修29	28—30,35	31—34
2	A	8	维修29	维修30	维修33	28,30,33,35	29,31,32,34
3	B	30	前往12	维修31	维修32	28—33,35	34
4	B	30	前往11	维修29	维修35	28—30,35	31—34
5	C	15	前往22	维修29	维修32	28—33,35	34
6	C	15	维修32	维修29	维修31	28—31,33,35	32,34

当 X_{29} 正在被维修时,班组A便会改变策略,经由 X_{16} 朝着其他未维修故障点移动,使负荷更快恢复。由表1中决策3、4的数据可知:当运维班组B完成故障点 X_{30} 的维修时,若 X_{31} 尚未被维修,则班组B经由节点 X_{11} 前往故障 X_{31} 进行维修;而当 X_{31} 、 X_{32} 正在被维修时,班组B转而经 X_{12} 前往 X_{34} 进行故障维修,决策5、6同理。由表1中决策3、5的班组移动方向可知,当仅剩1个故障点尚未维修时,当前未在维修的班组都会以最后的故障点为维修目标。

3.3 事件驱动下两运维班组故障恢复情况分析

以上算例测试为电力交通耦合网含三运维班组情况下由随机事件驱动导致的故障恢复变化,为分析不同运维班组数量下故障维修任务的变化受随机事件驱动影响,将算例削减为只含A、C两运维班组的情况进行分析,所得训练奖励曲线如附录B图B4(b)所示。不同随机情形下故障恢复情况如附录B表B1所示,其中,各随机情形与三运维班组时相同。

经比较各情形可知,对于仅含A、C两运维班组的算例系统,随机事件驱动对其故障维修情况的影响相较于三运维班组时要小,对于故障维修时间及交通时间变化差距较小的情形,各班组运维路径的变化也较小。在相同故障维修点情况下,三运维班组相较于两运维班组在随机事件驱动下的运维路径更具灵活性。

3.4 事件驱动下不同运维班组数负荷恢复曲线分析

为进一步比较电力交通耦合网不同运维班组数对故障恢复的影响,对三运维班组和二运维班组情况下的故障恢复曲线进行分析,结果如图3所示。

由图3可知,对于同一算例下不同运维班组数的情况,两运维班组与三运维班组在各情形下的负荷恢复趋势相近似,区别在于当班组数较少时,各故障点的故障维修时间会相对延后。这说明在同一算例下训练得到的运维班组在故障点的选择上具有相似的优先级,当由随机事件驱动导致的故障恢复时间变化时,运维班组下一步故障点决策也会随之动态变化。

3.5 不考虑随机事件下故障恢复情况分析

为验证本文所提随机事件驱动故障恢复策略相较于不考虑随机事件的固定路径故障恢复策略的优

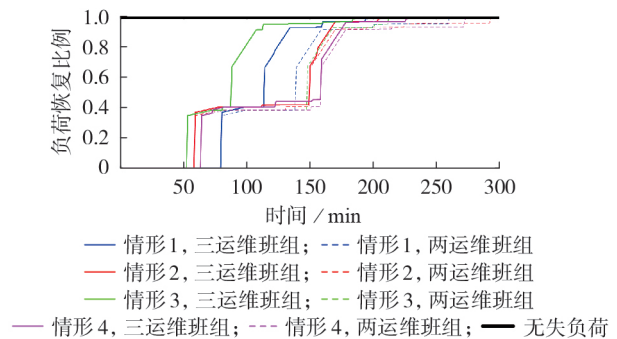


图3 不同运维班组数下负荷恢复曲线

Fig.3 Load recovery curves with different number of line operation and maintenance teams

势,对智能体训练环境中的路径交通时间及故障维修时间取固定值处理,统一设定为其正态分布期望值,所得训练奖励曲线如附录B图B4(c)所示。此时班组A的运维路径为 $X_{28}-X_2-X_6-X_8-X_{29}-X_8-X_{16}-X_{17}-X_{31}$,班组B为 $X_{11}-X_{30}-X_{12}-X_{13}-X_{34}$,班组C为 $X_{20}-X_{35}-X_{20}-X_{19}-X_{33}-X_{15}-X_{32}$ 。包括情形1—4在内的10种随机情形下由随机事件驱动恢复策略与固定运维路径恢复策略导致的系统负荷恢复曲线如附录B图B6所示。由图可知:2种策略下负荷恢复曲线的主要区别在于其后半段的恢复趋势变化;由于2种策略下各运维班组的初始路径选择相同,故在约175 min前,其恢复曲线几乎重合,而在负荷恢复后半段,2种策略的区别开始显现。以情形1、2、4为例,随机事件驱动下,故障点 X_{32} 可由三运维班组根据故障维修时间动态选择,而固定路径下仅由班组C对 X_{32} 进行维修,若班组C对前2个故障点维修所消耗的时间较短,则 X_{32} 会在较短时间内修复;若班组C对前2个故障点维修所消耗的时间过长,则 X_{32} 的修复时间也会随之大幅延长。故图B6中,随机事件驱动恢复策略的总负荷恢复时间往往短于固定运维路径恢复策略,本文策略可以实现对由于交通时间及维修时间随机变化导致的负荷恢复波动的有效抑制。

4 结论

本文考虑电力交通耦合网故障恢复中交通时间及维修时间的不确定性导致的线路运维班组决策点

随机变化问题,提出一种基于多智能体深度强化学习的电力交通耦合网随机事件驱动故障恢复策略。经算例仿真,所得结论如下:

1)极端灾害下配电网多运维班组决策点随机变化问题可通过半马尔可夫决策过程进行描述,充分体现电网故障恢复的随机事件驱动特征;

2)通过多智能体深度强化学习算法进行建模可有效考虑交通时间及故障维修时间的随机性,实现多运维班组的实时决策,对于不同运维班组数都具有较好的适用性;

3)经电力交通耦合网算例对是否考虑随机事件驱动的故障恢复情况进行分析,本文所提随机事件驱动恢复方法相较于传统优化恢复方法在负荷恢复上更具灵活性,可有效抑制系统随机时间变化导致的负荷恢复波动。

本文研究受制于训练时间及算例复杂度的影响,在较少运维班组时其随机事件驱动特征表现得不是特别明显,在后续研究中,笔者将考虑在本文模型基础上引入其他可能随机事件,进一步增强方法实用性。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 鞠平,王冲,辛焕海,等. 电力系统的柔性、弹性与韧性研究[J]. 电力自动化设备,2019,39(11):1-7.
JU Ping, WANG Chong, XIN Huanhai, et al. Flexibility, resilience and toughness of power system[J]. Electric Power Automation Equipment, 2019, 39(11): 1-7.
- [2] 王颖,马佳骏,王小君,等. 含智能软开关的配电网重要负荷恢复方法[J]. 电力系统自动化,2021,45(8):104-111.
WANG Ying, MA Jiajun, WANG Xiaojun, et al. Critical load restoration method for distribution network with soft open point[J]. Automation of Electric Power Systems, 2021, 45(8): 104-111.
- [3] 刘菲,林超凡,陈晨,等. 考虑分布式新能源动态不确定性的配电网灾后时序负荷恢复方法[J]. 电力自动化设备,2022,42(7):159-167.
LIU Fei, LIN Chaofan, CHEN Chen, et al. Post-disaster time-series load restoration method for distribution network considering dynamic uncertainty of distributed renewable energy[J]. Electric Power Automation Equipment, 2022, 42(7): 159-167.
- [4] LI Wenguo, LI Yong, CHEN Chun, et al. A full decentralized multi-agent service restoration for distribution network with DGs[J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1100-1111.
- [5] ARIF A, WANG Zhaoyu, CHEN Chen, et al. Repair and resource scheduling in unbalanced distribution systems using neighborhood search[J]. IEEE Transactions on Smart Grid, 2020, 11(1): 673-685.
- [6] 许寅,王颖,和敬涵,等. 多源协同的配电网多时段负荷恢复优化决策方法[J]. 电力系统自动化,2020,44(2):123-131.
XU Yin, WANG Ying, HE Jinghan, et al. Optimal decision-making method for multi-period load restoration in distribution network with coordination of multiple sources[J]. Automation of Electric Power Systems, 2020, 44(2): 123-131.
- [7] 王育飞,李可铭,薛花,等. 考虑移动式储能调度的配电网灾后多源协同孤岛运行策略[J]. 电力系统自动化,2024,48(3):62-72.
WANG Yufei, LI Keming, XUE Hua, et al. Post-disaster multi-source cooperative islanding operation strategy for distribution network considering mobile energy storage system dispatching[J]. Automation of Electric Power Systems, 2024, 48(3): 62-72.
- [8] 李一璞,周云,冯冬涵,等. 考虑移动储能动态路径引导的配电网协同恢复策略[J/OL]. 电力自动化设备. (2024-04-22) [2024-09-17]. <https://doi.org/10.16081/j.epae.202404005>.
- [9] 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.
- [10] WANG Chong, JU Ping, LEI Shunbo, et al. Markov decision process-based resilience enhancement for distribution systems: an approximate dynamic programming approach[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2498-2510.
- [11] 刘俊琳,朱振山,温步瀛. 基于V2G潜力模糊评估与移动储能协调调度的灾后供电恢复策略[J]. 电力自动化设备,2024,44(9):89-97.
LIU Junlin, ZHU Zhenshan, WEN Buying. Post-disaster power supply restoration strategy based on V2G potential fuzzy evaluation and mobile energy storage coordinated scheduling[J]. Electric Power Automation Equipment, 2024, 44(9): 89-97.
- [12] 杨祺铭,李更丰,别朝红,等. 台风灾害下基于V2G的城市配电网弹性提升策略[J]. 电力系统自动化,2022,46(12):130-139.
YANG Qiming, LI Gengfeng, BIE Zhaozhong, et al. Vehicle-to-grid based resilience promotion strategy for urban distribution network under typhoon disaster[J]. Automation of Electric Power Systems, 2022, 46(12): 130-139.
- [13] 唐文虎,杨毅豪,李雅晶,等. 极端气象灾害下输电系统的弹性评估及其提升措施研究[J]. 中国电机工程学报,2020,40(7):2244-2254,2403.
TANG Wenhui, YANG Yihao, LI Yajing, et al. Investigation on resilience assessment and enhancement for power transmission systems under extreme meteorological disasters[J]. Proceedings of the CSEE, 2020, 40(7): 2244-2254, 2403.
- [14] ARIF A, MA Shanshan, WANG Zhaoyu, et al. Optimizing service restoration in distribution systems with uncertain repair time and demand[J]. IEEE Transactions on Power Systems, 2018, 33(6): 6828-6838.
- [15] 李学平,卢志刚,刘照拯,等. 含分布式电源的配电网多故障抢修的多代理策略研究[J]. 电工技术学报,2013,28(8):48-55.
LI Xueping, LU Zhigang, LIU Zhaozheng, et al. Multi-agent strategy of distribution networks multi-faults rush-repair with distributed generators[J]. Transactions of China Electrotechnical Society, 2013, 28(8): 48-55.
- [16] 彭寒梅,王维首,苏永新,等. 基于负荷恢复价值折算的主动配电网电力-通信故障统一修复策略[J]. 电力自动化设备,2023,43(4):135-142.
PENG Hanmei, WANG Weishou, SU Yongxin, et al. Power-communication faults unified repair strategy for active distribution network based on load recovery value conversion[J]. Electric Power Automation Equipment, 2023, 43(4): 135-142.
- [17] 郁琛,李尚轩,谢云云,等. 考虑交通网与配电网信息融合的台风后配电网抢修策略优化[J]. 电力系统自动化,2022,46(4):15-24.
YU Chen, LI Shangxuan, XIE Yunyun, et al. Optimization of post-typhoon rush repair strategy for distribution network con-

- sidering information integration of traffic network and distribution network[J]. Automation of Electric Power Systems, 2022, 46(4):15-24.
- [18] XU Yin, WANG Ying, HE Jinghan, et al. Resilience-oriented distribution system restoration considering mobile emergency resource dispatch in transportation system[J]. IEEE Access, 2019, 7:73899-73912.
- [19] LI Zepeng, TANG Wenhui, LIAN Xianglong, et al. A resilience-oriented two-stage recovery method for power distribution system considering transportation network[J]. International Journal of Electrical Power & Energy Systems, 2022, 135:107497.
- [20] 祝昊, 付炜, 谢海鹏, 等. 考虑元件故障位置不确定性的维修队预调度与灾后派遣方法[J]. 电力自动化设备, 2024, 44(6):161-168.
- ZHU Hao, FU Wei, XIE Haipeng, et al. Repair crew pre-scheduling and post-disaster dispatch method considering uncertainty of component fault location[J]. Electric Power Automation Equipment, 2024, 44(6):161-168.
- [21] 王冲, 王秀丽, 鞠平, 等. 电力系统随机分析方法研究综述[J]. 电力系统自动化, 2022, 46(3):184-199.
- WANG Chong, WANG Xiuli, JU Ping, et al. Review of research on power system stochastic analysis methods[J]. Automation of Electric Power Systems, 2022, 46(3):184-199.
- [22] BARBU V S, D'AMICO G, MAKRIDES A. A continuous-time semi-Markov system governed by stepwise transitions[J]. Mathematics, 2022, 10(15), 2745:1-12.
- [23] HACHMANN C, BECKER H, BRAUN M. Cold load pickup model adequacy for power system restoration studies[J]. Energies, 2022, 15(20):1-18.
- [24] 王树森, 黎彧君, 张志华. 深度强化学习[M]. 北京:人民邮电出版社, 2022:207-209.
- [25] SCHULMAN J, WOLSKI F, DHARIWAL P, et al. Proximal policy optimization algorithms[EB/OL]. (2017-08-28)[2024-04-03]. <https://arxiv.org/abs/1707.06347>.
- [26] 宋大雷, 吕昆岭, 陈小平, 等. 基于深度强化学习的无人船全覆盖路径规划[J]. 现代电子技术, 2022, 45(22):1-7.
- SONG Dalei, LÜ Kunling, CHEN Xiaoping, et al. USV coverage path planning based on deep reinforcement learning[J]. Modern Electronics Technique, 2022, 45(22):1-7.
- [27] 刘国名, 李彩虹, 李永迪, 等. 基于改进PPO算法的机器人局部路径规划[J]. 计算机工程, 2023, 49(2):119-126, 135.
- LIU Guoming, LI Caihong, LI Yongdi, et al. Local path planning of robot based on improved PPO algorithm[J]. Computer Engineering, 2023, 49(2):119-126, 135.
- [28] STABLER B. Transportation networks for research[DB/OL]. (2021-10-22)[2024-04-03]. <https://github.com/bstabler/TransportationNetworks>.
- [29] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. IEEE Transactions on Power Delivery, 1989, 4(2):1401-1407.

作者简介:

王冲(1988—),男,教授,博士,主要研究方向为综合能源电力系统建模和优化、电力系统弹性/韧性、电力系统不确定性分析与控制(**E-mail**: chongwang@hhu.edu.cn);

石大奔(2000—),男,硕士研究生,主要研究方向为电力系统弹性分析及控制、综合能源电力系统建模及优化(**E-mail**: 221306080027@hhu.edu.cn);

万灿(1986—),男,教授,博士,主要研究方向为新能源电力系统不确定性预测、分析与控制(**E-mail**: canwan@zju.edu.cn)。

(编辑 任思思)

Uncertain event-driven fault recovery strategy based on multi-agent deep reinforcement learning

WANG Chong¹, SHI Dahang¹, WAN Can², CHEN Xia³, WU Feng¹, JU Ping¹

(1. School of Electrical and Power Engineering, Hohai University, Nanjing 211100, China;

2. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China;

3. School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: In order to reduce the load loss caused by distribution network faults and improve the resilience of distribution network, an uncertain event-driven fault recovery strategy based on multi-agent deep reinforcement learning is proposed. The uncertain event-driven problem in the fault recovery power-traffic coupling network is presented, which is described as a semi-Markov random decision process problem. An uncertain event-driven fault recovery model based on semi-Markov is constructed by considering the optimization objective of system fault recovery comprehensively. Then, the multi-agent deep reinforcement learning algorithm is used to solve the uncertain event-driven model. A case study is carried out in the power-traffic coupling system formed by IEEE 33-bus distribution network and Sioux Falls traffic network. The results show that the proposed model and method have good application effects in the fault recovery of power-traffic coupling network, and can adjust the fault recovery changes caused by uncertain events (fault maintenance and traffic travel) in real time.

Key words: uncertain event-driven; fault recovery; deep reinforcement learning; power-traffic coupling network; multi-agent

附录 A

1) 电力传输约束。

$$b_{ij,t} + b_{ji,t} = c_{l,t} \quad i, j \in \mathcal{N}, l \in \mathcal{L}, t \in [0, T] \quad (A1)$$

$$\sum_{j \in \mathcal{N}} b_{ij,t} \leq 1 \quad i, j \in \mathcal{N}, t \in [0, T] \quad (A2)$$

$$0 \leq c_{l,t} \leq 1 \quad l \in \mathcal{L}, t \in [0, T] \quad (A3)$$

式中： \mathcal{N} 为配电网节点集合； \mathcal{L} 为配电网线路集合； l 为连接节点 i 、 j 的线路； $b_{ij,t}$ 为 t 时刻节点 i 、 j 间的潮流方向，当线路中电流由节点 i 流向节点 j 时， $b_{ij,t}=1$ ，否则 $b_{ij,t}=0$ ； $c_{l,t}$ 表示线路通电状态，式(A3)中，当线路断开或不通电时， $c_{l,t}=0$ ，否则 $c_{l,t}=1$ 。

上式表明，对于配电网中单一节点，其至多只存在 1 个父节点并仅能从该节点获取电能，在任一时刻，潮流在线路中单向流动。

2) 节点通电约束。

由于电力传输约束的存在，故障后配电网节点通电状态由其父节点状态及连接线路状态共同决定。

$$K_{j,t} = K_{i,t} F_{l,t} \quad i, j \in \mathcal{N}, l \in \mathcal{L}, t \in [0, T] \quad (A4)$$

式中：配电网节点 i 为节点 j 的父节点； $K_{i,t}$ 表示节点 i 在 t 时刻的通电状态，正常通电时 $K_{i,t}=1$ ，否则 $K_{i,t}=0$ ； $F_{l,t}$ 为表示连接节点 i 、 j 之间的线路 l 在 t 时刻能否正常通电的状态量，可正常通电时 $F_{l,t}=1$ ，否则 $F_{l,t}=0$ 。本文重点研究配电网故障抢修中的随机事件驱动过程，故对于节点通电暂不考虑网络重构及线路运行约束。

3) 冷负荷恢复约束。

考虑到节点负荷多样性，本模型对负荷恢复中的冷负荷作用加以研究。冷负荷与常规负荷不同，故障维修完成后，冷负荷设备并不能直接恢复至正常负荷量，而是在达到峰值后缓慢恢复至正常负荷，其特性为：

$$P_t^{\text{CLPU}} = \begin{cases} P_0 \left[\delta - \frac{\delta-1}{\Delta T} (t-t_0) \right] & t_0 \leq t < t_0 + \Delta T \\ P_0 & t_0 + \Delta T \leq t \end{cases} \quad (A5)$$

式中： P_t^{CLPU} 为 t 时刻冷负荷量； P_0 为冷负荷恢复稳态时的负荷量； t_0 为冷负荷通电时间； ΔT 为冷负荷自通电至恢复稳态所需时间； δ 为冷负荷通电时的最大负荷量与稳态负荷量的比值。冷负荷恢复特性曲线图如附录 A 图 A1 所示。




图 A1 冷负荷恢复特性曲线

Fig.A1 Cooling load recovery characteristic curve

由于冷负荷恢复时峰值的存在，考虑到变电站负荷恢复能力及线路承受能力，节点通电后冷负荷并不能同时投入运行，而只能采用部分冷负荷分时段投切的方式恢复负荷。

冷负荷恢复约束为：

$$P_i^{\text{CL}} = \begin{cases} P_0^{\text{CL}} + (t - t_f) \frac{P_{\text{all}}^{\text{CL}} - P_0^{\text{CL}}}{\Delta T^{\text{CL}}} & t_f \leq t < t_f + \Delta T^{\text{CL}} \\ P_{\text{all}}^{\text{CL}} & t_f + \Delta T^{\text{CL}} \leq t \end{cases} \quad (\text{A6})$$

式中： P_i^{CL} 为含冷负荷节点在 t 时刻已投切的冷负荷量； P_0^{CL} 为节点通电时投切的初始冷负荷量； t_f 为故障修复后节点通电时间； $P_{\text{all}}^{\text{CL}}$ 为冷负荷总量； ΔT^{CL} 为冷负荷恢复持续时间。

4) 维修时间约束。

线路运维班组在每个节点的维修时间具有随机性，本文将该时间视为服从正态分布处理。假设线路运维班组在故障节点 i 的维修时间 t_i^{fix} 的数学期望为 $E(t_i^{\text{fix}}) = \mu_i^{\text{fix}}$ ，方差为 σ_i^{fix} ，则维修时间的概率分布表达式为：

$$f_i = \frac{1}{\sqrt{2\pi}\sigma_i^{\text{fix}}} \exp \left[-\frac{(t_i^{\text{fix}} - \mu_i^{\text{fix}})^2}{2(\sigma_i^{\text{fix}})^2} \right] \quad (\text{A7})$$


考虑到实际维修过程中维修时间不可能低于某一正值，故维修时间还需满足以下约束：

$$t_i^{\text{fix}} > T_{\text{min}}^{\text{fix}} \quad (\text{A8})$$


式中： $T_{\text{min}}^{\text{fix}}$ 为故障点最短维修时间。

由于道路交通时间同样满足正态分布且不可能小于最小交通时间，故道路交通时间同样满足与式(A7)、(A8)相似的约束。

附录 B



(a) 策略网络结构



(b) 价值网络结构

图 B1 智能体神经网络结构

Fig.B1 Agent neural network structures

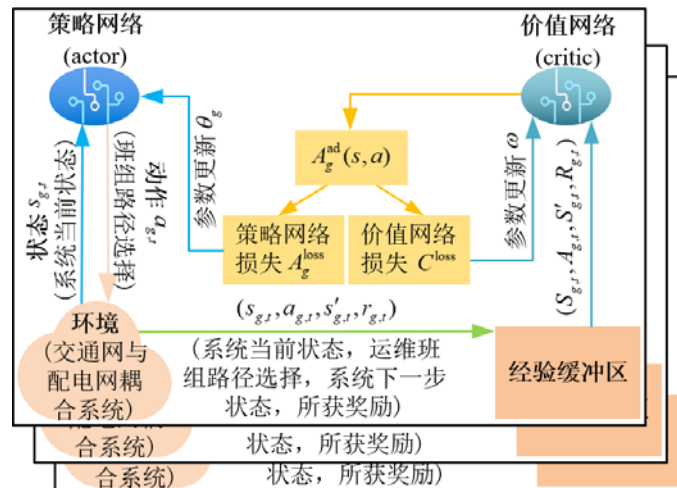


图 B2 多智能体 PPO 算法训练流程框架

Fig.B2 Multi-agent PPO algorithm training process framework

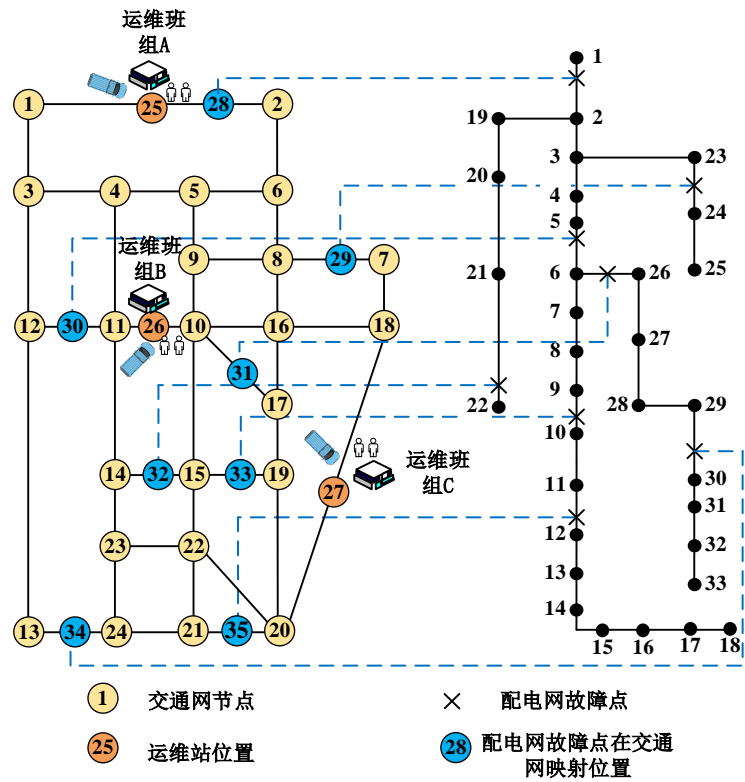


图 B3 Sioux Falls 交通网与 IEEE 33 节点配电网耦合系统

Fig.B3 Sioux Falls traffic network and IEEE 33-bus distribution network coupling system





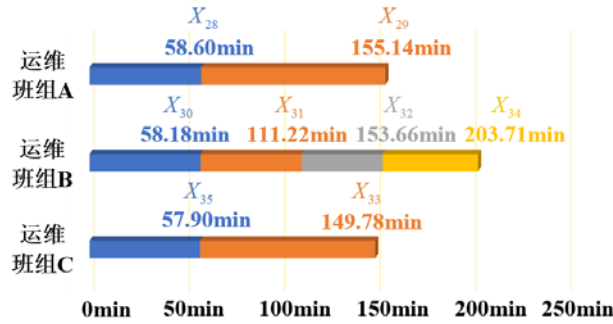


图 B4 智能体训练奖励曲线


Fig.B4 Agents training reward curves



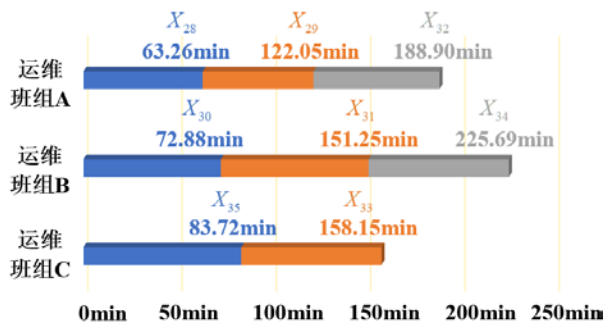
(a) 情形 1



(b) 情形 2



(c) 情形 3



(d) 情形 4

图 B5 随机事件驱动下电力交通耦合网故障恢复情况

Fig.B5 Uncertain event-driven fault recovery of power traffic coupling network

比较图 B5 中情形 1 与情形 2 可知，在运维班组 B 完成故障点 X_{31} 的维修后，若此时班组 C 已完成 X_{33} 的维修并前往 X_{32} ，则班组 B 选择前往 X_{34} 进行维修；若此时班组 C 尚未完成 X_{33} 的维修，则班组 B 选择前往较近节点 X_{32} 进行维修，并在完成维修后继续前往 X_{34} 进行维修。比较情形 1 与情形 3 可知，当班组 C 完成 X_{32} 的维修后，班组 B 尚未完成 X_{31} 维修，班组 C 继续前往 X_{34} 进行维修，而班组 A 虽然较早完成 X_{29} 的维修，却因距离较远落后到达。比较情形 1 与情形 4 可知，当 X_{31} 的维修完成时间晚于

或稍早于 X_{33} 时，维修 X_{32} 的班组由班组 A 与 C 各自完成其第 2 个故障点的维修时间决定。

表 B1 两运维班组故障恢复情况
Table B1 Fault recovery of two line operation and maintenance teams

情形	班 组	故 障 点	维 修 完 成 时 间/min	班 组	故 障 点	维 修 完 成 时 间/min
1	A	28	79.47	C	35	51.12
	A	30	138.62	C	33	113.81
	A	34	199.37	C	31	172.35
	A	32	260.07	C	29	259.80
2	A	28	58.60	C	35	57.90
	A	30	130.66	C	33	149.78
	A	32	173.79	C	31	194.91
	A	34	224.10	C	29	292.32
3	A	28	52.44	C	35	38.78
	A	30	147.87	C	33	87.37
	A	34	200.57	C	31	146.14
	A	32	265.34	C	29	211.51
4	A	28	63.26	C	31	83.72
	A	30	150.12	C	33	158.15
	A	32	204.66	C	31	214.64
	A	34	272.54	C	29	271.26

由表 B1 中数据可知，情形 1、3 与情形 2、4 中，运维班组 A 和 C 的运维路径相同。4 种情形下运维路径的区别主要在于运维班组 A 完成故障点 X_{30} 的维修后对下一故障点的选择， X_{30} 维修完成后，若此时 X_{31} 正在被维修或已维修完成，由于 X_{34} 所连节点为 X_{31} 所连节点的下级节点，故 X_{34} 维修完成后有较大概率可直接通电，此时班组 A 前往 X_{34} 进行维修；反之，若 X_{33} 尚未维修完成，则 X_{31} 维修时间较为靠后，此时班组 A 选择先维修 X_{32} 令 Y_{22} 先通电。




图 B6 多种随机情形下负荷恢复曲线
Fig.B6 Load recovery curves under various random conditions