引用格式：刘颂凯，艾宇坤，苏攀，等.基于深度强化学习的电网薄弱线路时序故障辨识策略[J].电力科学与技术学报,2025,40(6):54-66.
Citation: LIU Songkai, AI Yukun, SU Pan, et al. Timing fault identification strategy for weak lines in power grid based on deep reinforcement learning[J]. Journal of Electric Power Science and Technology,2025,40(6):54-66.

基于深度强化学习的电网薄弱线路时序故障辨识策略

刘颂凯[1,2]，艾宇坤[1,2]，苏　攀[1,2]，李彦彰[3]，吴宇恒[1,2]，丁文沛[1,2]
（1.三峡大学电气与新能源学院，湖北 宜昌 443002；2.新能源微电网湖北省协同创新中心，湖北 宜昌 443002；
3.国网湖北省电力有限公司武汉市供电公司，湖北 武汉 430010）

摘　要：为有效预防线路时序故障导致的电网连锁故障，提出一种融合深度强化学习(deep reinforcement learning，DRL)与暂态稳定约束的辨识方法。该方法核心在于将辨识任务形式化为一个马尔可夫决策过程(Markov decision process，MDP)问题，使DRL智能体能够通过与暂态仿真环境的交互学习，高效筛选出导致系统失稳的关键故障路径。其先引入一种结合Q值与时序累积效应的薄弱度指标，实现对薄弱线路的精准定位；再结合电网时域暂态仿真计算，筛选易导致电网失稳的关键故障；然后，结合时序故障累积效应与Q学习，提出线路薄弱度指标，计算得到时序故障累积效应情况下考虑暂态稳定约束的电网薄弱线路；最后，使用IEEE 5节点、IEEE 39节点和IEEE 300节点系统作为测试案例，进行仿真，其仿真结果均验证了所提方法在学习效率和识别电网薄弱环节方面的适用性。研究结果表明，该DRL方法在Q学习的基础上结合乐观的初始猜测和贪心算法，可实现对关键故障的选择，并能评估在不同线路故障情况下的学习效率，其稳定性和训练速度均较好。

关　键　词：线路时序故障；深度强化学习；暂态稳定；电网薄弱线路辨识；Q学习
DOI：10.19781/j.issn.1673-9140.2025.06.006　　**中图分类号**：TM712　　**文章编号**：1673-9140(2025)06-0054-13

Timing fault identification strategy for weak lines in power grid based on deep reinforcement learning

LIU Songkai[1,2], AI Yukun[1,2], SU Pan[1,2], LI Yanzhang[3], WU Yuheng[1,2], DING Wenpei[1,2]
(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 2. Hubei Collaborative Innovation Center for New Energy Microgrid, Yichang 443002, China; 3. Wuhan Power Supply Company, State Grid Hubei Electric Power Co., Ltd., Wuhan 430010, China)

Abstract: To effectively prevent cascading faults of the power grid caused by line timing faults, an identification method that integrates deep reinforcement learning (DRL) and transient stability constraints is proposed. The core of this method lies in formalizing the identification task as a Markov decision process (MDP) problem, enabling the DRL agent to efficiently screen out the key fault paths that cause system instability through interactive learning with the transient simulation environment. Firstly, a vulnerability index combining Q value and timing cumulative effect is introduced, achieving precise positioning of weak lines. By combining the time-domain transient simulation calculation of the power grid, the key faults that are prone to cause power grid instability are screened out. Then, the line weakness index is proposed through Q learning combined with the cumulative effect of timing faults, and the weak lines in the power grid considering the transient stability constraint under the cumulative effect of timing faults are calculated and obtained. Finally, IEEE 5 node, IEEE 39 node, and IEEE 300 node systems are used to simulate as test cases. The

收稿日期：2024-12-26；**修回日期**：2025-01-27
基金项目：国家自然科学基金(52407118)；梯级水电站运行与控制湖北省重点实验室(三峡大学)开放基金课题(2023KJX06)；电力系统智能运行与安全防御宜昌市重点实验室(三峡大学)开放基金课题(2020DLXY06)
通信作者：苏　攀(1985—)，男，硕士研究生，主要从事输电线路工程方面的研究；E-mail：2512400720@qq.com

simulation results all verify the applicability of the proposed method in terms of learning efficiency and weak link identification in the power grid. Research results show that the proposed DRL method, based on Q learning, combines optimistic initial guessing and greedy algorithm to achieve selection for critical faults and evaluate the learning efficiency under different line fault conditions, with favorable stability and fast training speed.

Key words: line timing fault; deep reinforcement learning; transient stability; identification of weak lines in power grid; Q learning

新能源并网与区域电网的互联[1]，不仅能有效利用可再生能源资源，还能实现资源优化配置。在现代电力系统的发展过程中，提升供电的可靠性和经济性是其发展的关键方向之一。在高度互联的电网环境下，若重要输电线路出现故障并被切除，就有可能导致系统暂态稳定性问题的发生[2-4]，此类故障常常导致电力潮流在网络中大规模转移。若这类事故无法得到及时控制，将引发一系列连锁故障，最终甚至可能演变为电网崩溃或大范围停电等重大安全事故[5]。为避免此类事故，提前识别电网中对暂态稳定性影响较大的薄弱线路并对其进行必要的加固，就显得尤为重要。通过对薄弱线路的有效识别，电网的规划、运行与调度人员可以有针对性地加强潜在薄弱环节，提高电网在极端工况或突发事件下的稳定性[6]。这不仅保障了电网的安全可靠运行，还为区域电网的高效调度提供了数据支撑和决策依据，对现代电力系统的可持续发展具有深远的意义。

目前，通常假设多支路故障是同时发生的。这一假设忽略了故障的时间特性，无法反映故障逐步演化的真实情况[7-8]。在实际系统中，多个故障往往依次发生，即这些故障应为时序故障。时序故障筛查一般须在不同的时间节点对系统的运行状态进行鲁棒性评估，从中筛选出一个关键节点或支路，并通过移除该节点或支路来模拟线路故障的动态过程[9-12]。文献[13]提出，时序故障能造成比相同强度的并发故障更严重的损害。电力系统的动态特性可能使一些连续发生的线路中断影响延迟显现，且连续线路中断也会使这些动态效应叠加，甚至引起比故障同时发生更严重的系统停电事故。因此，本文从电网故障的动态演化视角出发，探讨如何按照对电网稳定性造成影响程度的强弱次序制定最优故障序列，从而识别出潜在的脆弱线路。构建有效的故障筛选与评估方法，精确定位系统中薄弱线路的位置和特性。

在实际电网运行方式的制定中，庞大的节点与线路规模使得采用穷举法进行全面的暂态稳定仿真校验面临困难[14-16]。故而，工程实践普遍依赖由经验确定的预想故障集，以此实现对电网薄弱线路的初步甄别，维护供电安全。然而，经验设定的方法在电网结构复杂性增加、运行条件多变的情况下易出现失误或遗漏。文献[17]基于风险指标与非支配故障筛选理论，对潜在故障集进行了脆弱性评估。文献[18]则引入了能量熵测度，以此辨识在连锁故障中易受大能量冲击的关键元件。文献[19]结合随机矩阵与熵理论，通过分析暂态仿真数据的关联特性来定位系统薄弱环节。这些方法高度依赖数据经验，当电网的网架结构或运行方式发生显著变化时，预设的故障集可能无法覆盖新形势下的脆弱线路，这增加了运行决策中的不确定性。

鉴于此，现代电力系统亟待发展一种基于数据驱动和智能算法的电网薄弱线路辨识方法，该方法能在复杂、动态的电网条件下提供更具适应性的分析结果[20-21]。近年来，人工智能算法的革新与计算能力的突破，推动了机器学习、深度学习与强化学习等方法在电力系统中的深入应用，这些方法尤其在电网稳定性分析领域取得了重要进展[22]。相关研究已将深度学习应用于暂态稳定评估[23]和短期负荷预测[24]中，将强化学习应用于电网紧急控制[25]和自动发电控制中[26]。尽管如此，现有的应用多集中在稳态潮流计算模型上；在电网薄弱环节辨识方面，将人工智能引入这一领域的研究鲜见。文献[27]提出了一种基于Q学习算法的电网脆弱性评估与关键线路识别方法，其主要针对电网中序列拓扑调整下的薄弱线路。但该研究未充分考虑故障动态特性及其对电网暂态稳定性的影响，仅在稳态条件下进行分析，可能无法全面捕捉在实际运行过程中薄弱线路的复杂动态行为。

针对这些研究的不足，本文提出一种基于深度强化学习（deep reinforcement learning，DRL）的Q学习算法的电网薄弱线路辨识方法，该方法结合了DRL的自学习能力与电网动态响应特性，能在暂态仿真反馈的基础上，通过反复迭代、动态调整故障模拟和线路状态更新，实现对关键薄弱线路的辨识。具体而言，所提方法将薄弱线路辨识建模为马尔可夫决策过程（Markov decision process，MDP），并

利用结合时域暂态仿真的DRL技术来评估线路的脆弱性，通过学习过程动态更新故障方法，实现对导致系统失稳的线路组合的精准筛选。与传统的能量函数、熵测度等方法不同，该方法不仅突破了传统稳态模型忽视暂态故障的局限，还减少了对人工经验的依赖，提升了识别精度。

本文通过对IEEE 5节点、IEEE 39节点和IEEE 300节点系统的仿真结果分析，验证了所提方法在较少仿真次数的情况下成功识别对电网暂态安全性有显著影响的薄弱线路。这一研究可为电网规划和运行，特别是在针对复杂故障条件的运行控制与资源分配，提供精准的指导。同时，本文所提方法在不同负荷水平和复杂故障条件下比传统方法展现出了更好的识别效果，可为电网调度和防御方案提供科学依据与理论指导。

1 电网薄弱线路辨识

1.1 考虑系统的动态特性的薄弱线路辨识

系统的动态特性意味着电网重要线路的短路或断线故障可能直接引发电网暂态失稳，直接威胁电网的安全与稳定运行。鉴于系统动态特性引发的暂态失稳风险，薄弱线路辨识应结合暂态运行状态来制定控制措施，并对失稳故障集所揭示的关键线路实施针对性监控。

考虑系统动态特性的电网薄弱线路辨识过程如图1所示。

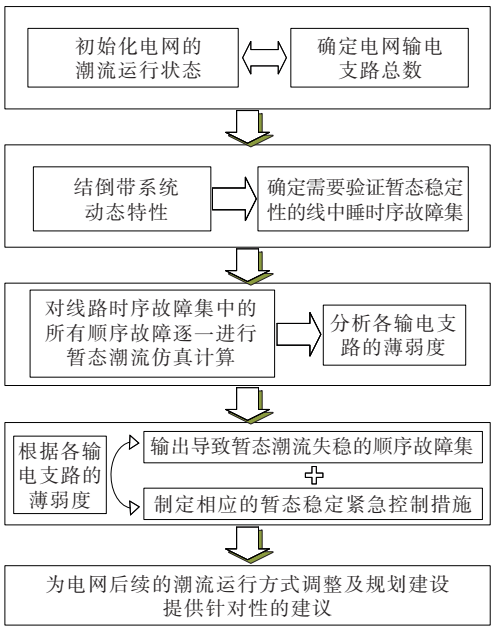

图1 考虑系统动态特性的电网薄弱线路辨识过程

Figure 1 Identification process of weak lines in power grid considering dynamic characteristics of system

1.2 制定线路时序故障集

电网故障在时间与空间上的随机性，显著提升了暂态稳定分析的复杂性。本文将一个线路时序故障定义为一个含二元数组的集合，即

$$A=\{a_1,a_2,\cdots,a_n\},\ n\leqslant N' \tag{1}$$

$$T=\{t_1,t_2,\cdots,t_n\},\ n\leqslant N' \tag{2}$$

$$S=\{(A,T)\}=\{(a_1,t_1),(a_2,t_2),\cdots,(a_n,t_n)\}\quad n\leqslant N \tag{3}$$

式中，A为故障情况集；T为故障时间集；S为线路时序故障集；N'为电网非故障输电支路总数；$a_i(i=1,2,\cdots,n)$为目标线路上电网的第i次故障；$t_i(i=1,2,\cdots,n)$为第i次故障的故障时间；n为单次仿真计算中故障线路的总数量。

根据对线路时序故障的定义可知，故障时间集T对应故障情况集A中的任意元素都是非负且单调递减的。本文采用的简化数学定义，其核心目的是便于仿真计算，从而更清晰地揭示计及暂态稳定性的薄弱线路辨识流程。即便后续引入更复杂的故障模型导致结果变化，本文方法的普适性依然成立。

据此可知，当采用穷举搜索法时，线路时序故障的搜索空间将扩大至$C_{N^*}^{n}$。其中，N^*为电网输电支路总数，当$n=1$时，该故障为N－1故障，其搜索空间大小为N^*；当$n=2$时，该故障为N－2故障，其搜索空间大小为$N^*\times(N^*-1)$。依此类推，搜索空间大小为$A_{N^*}^{n}$。由此可见，当系统规模较大且采用穷举搜索法对所有可能线路时序故障进行仿真时，将消耗大量的时间、计算资源和处理能力。

2 基于深度强化学习的薄弱线路辨识

电网薄弱线路的识别问题可以建模为一个复杂的决策问题，电网的状态、线路的故障情况以及可能的操作动作都会影响系统的稳定性。为突破在薄弱线路辨识过程中的电网运行数据对制定预想故障集的局限，减少计算时间以及资源消耗，有效识别影响电网暂态稳定性的关键线路或线路组合。本文引入了MDP，并以此为基础，提出基于DRL的薄弱线路辨识方法。DRL作为一种通过智能体与环境交互不断优化决策的算法，能在这种动态环境中表现出良好的学习能力。其中，Q学习作为一种经典的DRL算法，特别适合离散的状态和动作空间。在电网薄弱线路识别的场景下，Q学习能

够通过逐步探索和学习，构建一张状态-动作表（Q表），并通过更新Q值来识别出对系统稳定性影响最大的线路或线路组合。

2.1　马尔可夫决策过程

根据帕累托法则，80%的电网暂态失稳可能由20%的关键线路或线路组合故障引发。因此，攻击者的目标并不是攻击大量线路，而是集中精力找出那些对电网暂态稳定性影响最大的少数薄弱线路，通过最少的攻击行动实现对系统的最大破坏。也就是说，攻击者希望通过精准识别和攻击这些关键线路或线路组合来造成电网的暂态失稳，提高攻击的效率，降低攻击难度。为评估电网系统中各线路的薄弱程度，该问题可以简述为一个MDP决策过程。在这个过程中，系统状态即为电网当前运行状况，动作为对不同线路的干扰或攻击选择，转移概率为电网在受到干扰后从一个状态转移到另一个状态的可能性，奖励函数则衡量了电网暂态失稳的程度。这一过程系统化地评估每条线路对电网稳定性的影响，能识别出最易导致暂态失稳的薄弱线路或线路组合。薄弱线路MDP流程如图2所示。

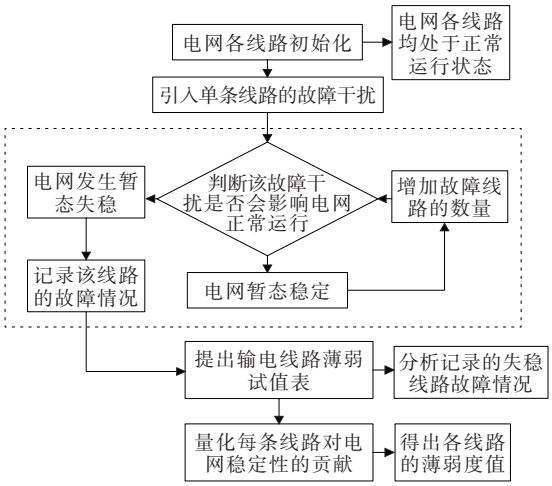

图2　薄弱线路MDP流程

Figure 2　MDP of weak line

2.2　Q学习算法

Q学习是一种无模型的强化学习算法，属于DRL的范畴。DRL学习框架如图3所示。从图3中可以看出，在实现最终目标的过程中，智能体会通过交互环境提供的反馈（即“奖励”）来不断自适应调整其行为，逐步优化决策策略。

Q学习可解决MDP问题。Q学习算法机制如图4所示。定义以下关键元素：

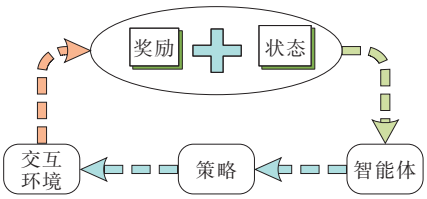

图3　DRL学习框架

Figure 3　DRL framework

1）状态s_t：当前t时刻的电网的状态（各线路的运行状况）。

2）动作a_t：对t时刻的电网中的某条线路进行干扰（即单切线或多切线故障）。

3）奖励r_t：根据t时刻的电网的暂态稳定性反馈给予的即时奖励（如果识别出薄弱线路并导致暂态失稳，则给出较高的奖励；反之，则不给出奖励）。

4）反馈$Q(s_t, a_t^*)$：在当前t时刻的系统状态s_t下，采取最佳动作a_t^*后计算得出的Q值。

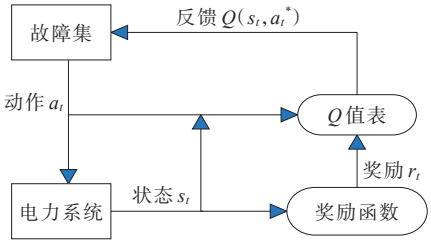

图4　Q学习算法机制

Figure 4　Q learning algorithm mechanism

一般来说，在当前电网状态s_t下采取行动a_t时，通过反馈的即时奖励r_t来进行累积函数计算，从而得到期望总奖励Q，即

$$Q=\sum_{t=1}^{n}\gamma^{t-1}r_t(s_t, a_t) \tag{4}$$

式中，Q为期望累积回报函数；γ为折扣因子，通常将γ的值设为略小于1，以便于学习过程中Q值的收敛；s_t为当前t时刻的电网的状态；a_t为对t时刻的电网中的某条线路进行的干扰动作。

虽然Q^*的真正最优值在实际应用中通常是未知的，但可通过Q学习算法不断迭代，逼近真正最优值。Q学习是一种非策略的、时间差分的DRL算法，其通过蒙特卡罗模拟不断逼近最优Q值。

在Q学习中，所有Q值经过初始化后都设置为0。利用算法迭代，Q值先被分配给每个相应的状态-动作(s, a)，且Q、s和a构成的每个3元组都将同时更新。再观察当前电网状态s_t，并从故障情况集A_t中搜索一组可用动作a_t，确定在该处的最佳动作a_t^*为

$$a_t^* = \arg\max Q(s_t, a_t) \quad a_t \in A_t \tag{5}$$

式中，a_t^*为时刻的导致电网故障的最佳动作。

$$Q(s_t, a_t) \leftarrow (1-\alpha)Q(s_t, a_t) + \alpha\left\{r_{t+1}(s_t, a_t) + \gamma \max Q(s_t, a_t)\right\} \quad a_t \in A_t \tag{6}$$

式中，α为控制学习积极性的学习率；$r_{t+1}(s_t, a_t)$为基于当前系统状态s_t下采取动作a_t的收到的即时奖励。

如果在选取最佳动作a_t^*时存在多个可用动作，则将随机选择一个可用动作。为实现长期最优性，可以通过式(6)得到期望累积回报Q的最大值，而不是反馈的即时奖励r_t。

在寻找最优期望累积回报策略的过程中，通过随机试验不断更新Q值，不断改进可用动作序列的选择和组合。

在薄弱线路识别中，当α设为1时，智能体聚焦即时故障反馈与未来状态预测，忽视历史经验，这可能引发策略波动；当α设为0时，则过分保守，固守初始估计，无法适应电网变化或无法从新故障中学习。因此，在实践中，α常采用逐步衰减的动态策略，即

$$\alpha = \alpha_0 D_{\text{rate}}^{\ t/D_{\text{steps}}} \tag{7}$$

式中，α_0为初始学习率；D_{rate}为衰减率；D_{steps}为衰减步长；t为时间。

该逐步衰减的动态策略可使智能体既能依据即时反馈迅速调整，又能有效利用历史数据，精准识别电网关键薄弱线路。

在薄弱线路识别中，更新的Q值存储于Q表，供未来决策参考。在智能体初期，可能选择非最优选择，导致评估偏差，但通过持续学习故障反馈，策略会逐步得到优化；最终，算法收敛，精准识别最脆弱线路组合，优化系统回报，确保决策最优。

2.3 Q学习算法对电网薄弱线路识别的初期探索

在电网薄弱线路识别过程中，Q学习可能对初始设置和局部最优解问题较敏感。这可能导致智能体在识别薄弱线路时耗费更多的学习时间。因此，在实际应用中，探索策略通常被用于DRL，以避免智能体陷入局部最优解。本文采用乐观的初始猜测和贪心算法进行探索，提高智能体在不同线路故障情况下的学习效率，帮助Q学习算法快速识别电网中的关键薄弱线路。

乐观的初始猜测能有效克服Q学习在薄弱线路识别中的初始阶段可能遇到的探索不足问题。该方法思想是将初始状态s_0的所有有效动作的Q值设为一个较高的初始值，鼓励智能体在初期优先探索更多线路组合，从而避免因早期探索不足而遗漏关键的薄弱线路。在这个过程中，智能体逐步调整Q值估计，获得实际的长期奖励。

在此学习过程中，为解决局部最优问题，本文采用了贪心算法。当智能体从Q表中查询当前状态s_t的最佳动作时，贪心策略允许其偶尔采取非最佳动作，避免过早陷入局部最优。这意味着智能体可能以较小概率选择次优线路，而不是始终选择当前Q值最大的动作。智能体采取最优行动的概率为

$$P(a_t = a_t^* | s_t) = 1 - \varepsilon,\ 0 < \varepsilon < 1 \tag{8}$$

式中，ε为探索的概率；$P(a_t = a_t^* | s_t)$为系统在当前状态s_t下采取的最佳动作a_t^*的条件概率。

传统算法一般采用一种简单的方式来选择一个固定的ε值。为保持探索与利用之间的平衡，本文提出了一种逐渐衰减的机制来优化探索过程。先在训练初期设置较高的探索概率，智能体能广泛尝试不同的状态-动作组合，确保充分了解所处的环境；然后，随着学习的深入，探索概率逐渐降低，此时的智能体能更多地利用已学到的最优策略，加快收敛速度，提升决策效率。这种动态调整的机制有效避免了固定ε可能导致的算法陷入局部最优解与收敛速度缓慢的问题。该动态ε衰减式为

$$\varepsilon = \varepsilon_{\min} + (\varepsilon_{\max} - \varepsilon_{\min})\mathrm{e}^{-\lambda\beta} \tag{9}$$

式中，$\varepsilon_{\min}$为最小探索概率；$\varepsilon_{\max}$为初始探索概率；λ为衰减率；β为时间步长。

2.4 线路状态

首先，将电力系统中薄弱支路的运行状态定义为线路状态s_t，并以集合的形式加以描述。其次，通过时序上的故障事件对线路状态的影响进行建模，描述薄弱支路在不同时间点的状态变化。每条线路的状态可用一个二进制变量来表征，即

$$\hat{S}_t = \left\{s_t(1), s_t(2), \cdots, s_t(M)\right\} \tag{10}$$

$$f(l, t) = s_t(l) = \begin{cases} 0, & \text{线路}l\text{正常运行} \\ 1, & \text{线路}l\text{发生故障} \end{cases} \tag{11}$$

式中，$\hat{S}_t$为当前t时刻下系统发生故障时电网的各线路状态集合；$s_t(i), i = 1, 2, \cdots, M$为系统当前时刻$t$下各支路的状态(若$s_t(i) = 1$，则线路正常运行，若$s_t(i) = 0$，则线路发生故障)；$M$为电网输电支路总数。

在第一次发生序故障策略前，所有线路都处于

正常运行状态。

2.5　奖励函数设计

奖励函数 $r_t(s_t, a_t)$ 是 DRL 中的一个关键函数，其直接影响智能体在学习过程中选择的动作。本文的目标是识别电网中的薄弱支路，分析其运行稳定性被削弱所导致的系统出现严重故障的风险，故提出采用奖励函数来评估每条线路对系统稳定性的影响程度。

在每次操作后，系统根据线路状态来反馈奖励值 $r_t(s_t, a_t)$。如果切断某条线路导致电网暂态失稳，则给出高额正奖励，这说明该线路对电网稳定性至关重要，即该线路薄弱；反之，如果切断线路后系统仍维持稳定，则给出低或负奖励，这说明该线路对电网整体稳定性影响较小。该奖励函数为

$$r_{t+1}(s_t, a_t)=\begin{cases}+F(t), & N_0 \geqslant N_\theta \text{且} k < N_\theta \\ -F(t), & N_0 \geqslant N_\theta \text{且} k \geqslant N_\theta \\ 0, & \text{其他}\end{cases} \tag{12}$$

式中，$F(t)$ 为 t 时刻时序故障对系统稳定性的累积影响；N_0 为暂态失稳时停电规模的线路故障总数；N_θ 为不稳定状态下的系统临界阈值，即系统进入暂态失稳的关键故障线路总数；k 为连续发生故障的线路总数。

如果某个故障策略通过放大效应成功触发系统暂态失稳，即通过条数少于 N_θ 条的线路的故障导致 N_θ 条或更多线路失稳，则该策略被认为是成功的。相反地，若必须 $k \geqslant N_\theta$ 成立，才能引发系统失稳，则该策略被视为不成功。而当故障次数和失稳线路数均少于 N_θ 时，该策略处于中性状态，故障攻击策略将继续执行，直到达到系统暂态失稳的目标。

结合系统暂态稳定性可知，该过程反映了故障线路的逐步累积效应，即一系列较小的故障可能通过连锁反应引发大规模的系统失稳。在这种情况下，及时识别薄弱线路并预防连锁故障扩散对保障电网的安全与稳定运行至关重要。

3　针对时序故障的薄弱线路的辨识

在考虑系统暂态稳定性的情况时，线路的薄弱度指标与时序故障之间的关系至关重要。在电网中，薄弱线路通常是那些在系统运行过程中的小规模故障或扰动引发的系统暂态失稳的线路。薄弱度指标可以用于衡量每条线路对系统暂态稳定的影响，并结合时序故障来分析线路在不同时间段内的故障行为及其对整体系统的影响。

当某条线路发生故障时，系统的暂态稳定性会受到影响[28]。如果故障线路的薄弱度高，则该线路将更容易导致连锁故障，进一步加剧系统的不稳定性。因此，线路薄弱度指标不仅与线路自身的状态（运行或故障）相关，还与时序故障的累积效应有关。综上所述，薄弱线路在时序上的多次或连续故障更有可能引发系统暂态失稳。

3.1　线路薄弱度指标

线路薄弱度是评估线路对电网暂态稳定影响的关键指标。通常情况下，系统在正常运行时具有一个稳定裕度；当线路发生故障时，系统的稳定裕度下降。因此，线路薄弱度可通过故障前、后的系统稳定裕度差值来表征。电网中的线路故障往往是时间相关的，即线路在不同时间发生的故障可能会对系统稳定性产生累积效应。系统在某一时刻的线路薄弱度和故障影响表达式分别为

$$W(l)=X_{\mathrm{nomin}}-X(l) \tag{13}$$

$$F(t)=\sum_{l=1}^{N} W(l) f(l,t) \tag{14}$$

式中，$W(l)$ 为线路 l 的薄弱度；X_{nomin} 为系统稳定裕度；$X(l)$ 为线路 l 发生故障时的系统稳定裕度的下降值；N 为系统中的总线路数。

3.2　时序故障累积效应的暂态稳定约束

为考虑时序故障的累积效应，引入一个衰减系数 φ，描述时间间隔对线路故障影响的弱化程度。系统暂态稳定的约束可以通过临界稳定裕度来表示。如果系统的稳定裕度在某一时间步长下低于该临界值 X_{critical}，则系统进入暂态失稳状态。假设连续 2 次故障发生之间的时间间隔为 Δt，则系统故障影响的暂态稳定约束为

$$F(t)=\sum_{l=1}^{N} W(l) f(l,t) \mathrm{e}^{-\varphi \Delta t} \tag{15}$$

$$X^*(t)=X_{\mathrm{nomin}}-F(t) \tag{16}$$

$$X^*(t) \geqslant X_{\mathrm{critical}} \tag{17}$$

式中，φ 为衰减系数；$X^*(t)$ 为考虑时序故障累积效应下系统的稳定裕度；X_{critical} 为临界值。

通过引入暂态稳定约束，可评估某条线路在发生故障时对系统稳定性的贡献程度。若线路薄弱度较高，则该线路在时序故障过程中对系统稳定性的破坏能力较强，其可增加连锁反应发生的可能性。因此，线路薄弱度指标与时序故障之间的关系反映了系统在不同时间点的动态故障特性，其可帮助识别薄弱支路和潜在风险，以便在故障发生前采

取防范措施，确保系统的暂态稳定性。

3.3 结合时序故障影响的薄弱线路辨识流程

基于Q学习的关键薄弱线路识别流程如图5所示。

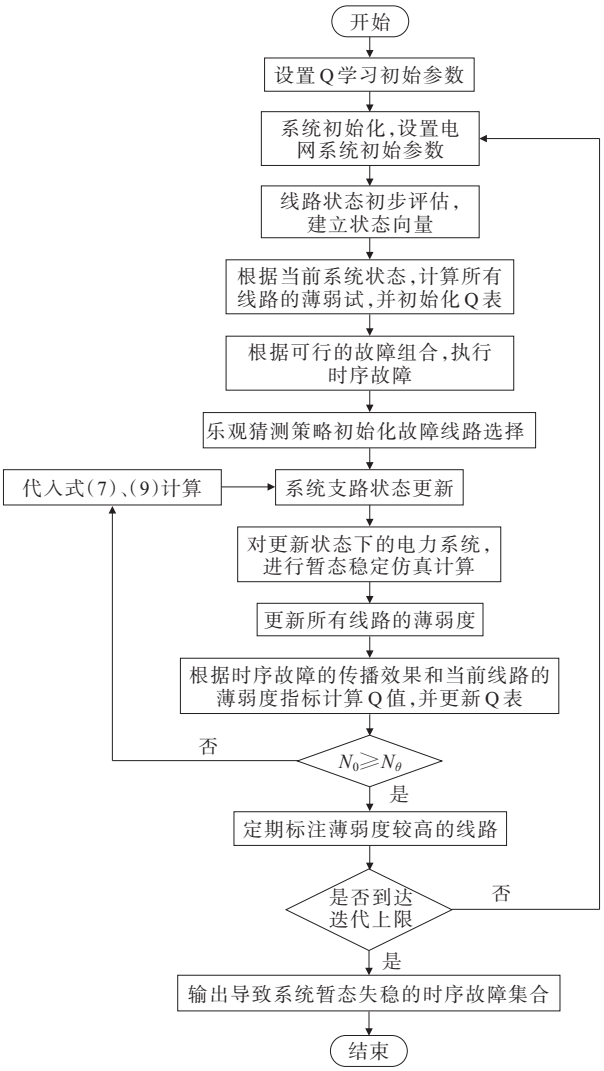

图5 基于Q学习的关键薄弱线路识别流程

Figure 5 Identification flow of key weak lines based on Q learning

依照图5所示的流程，线路薄弱度、时序故障的传播效果与Q值的动态更新形成一个相互影响的闭环，构成了关键薄弱线路识别的基础。

4 算例仿真

4.1 仿真参数设计

为验证提出的基于DRL的脆弱性分析方法，在MATLAB/Simulink计算平台中选择3个基准测试系统进行测试：小型IEEE 5节点测试系统、中型IEEE 39节点测试系统与大型IEEE 300节点测试系统。其中，IEEE 5和IEEE 39节点系统分别如图6、7所示。不同系统规模的暂态失稳所需的级联中断临界值不同，故为每个系统设置了相应的暂态失稳阈值。

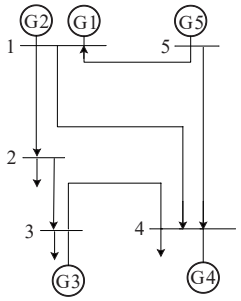

图6 IEEE 5节点测试系统

Figure 6 IEEE 5 node test system

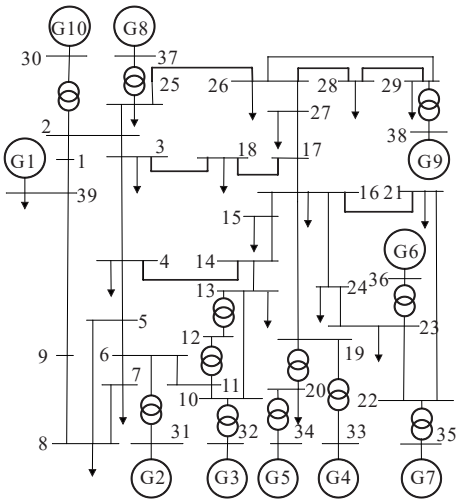

图7 IEEE 39节点测试系统

Figure 7 IEEE 39 node test system

对于小型IEEE 5节点系统，目标是使系统完全崩溃，设$\theta=100\%$，$N_\theta=6$。对于中型IEEE 39节点系统和大型IEEE 300节点系统，设定更为现实的临界暂态失稳故障目标。其中，IEEE 39节点系统的临界值$\theta=20\%$（对应$N_\theta=9$），IEEE 300节点系统的临界值$\theta=2.5\%$（对应$N_\theta=11$）。在具体分析流程中，采用蒙特卡洛模拟解决脆弱性分析中的随机性因素，这也是电力系统安全性验证中的常用方法。对每个基准系统进行100次独立模拟试验，每次试验最多包含1 000次尝试。

Q学习参数设置：在初始阶段，每个状态-动作对的Q值均设置为+1.0，作为一种乐观的估计，其目的是在训练早期鼓励智能体积极尝试不同的动作组合。每次试验后，初始状态重置为无故障状态，且线路中断状态设置为0。同时，保留从先前试验中学到的Q值。探索概率采用逐渐衰减策略，探

索概率的初始值 $\varepsilon_{max}=0.30$，将其逐步减小至最终值 $\varepsilon_{min}=0.05$，衰减率 $\lambda=0.01$，以保证探索的平滑过渡。此外，为适应较为保守的学习进程，设置学习率 $\alpha=0.1$，折扣因子 $\beta=0.9$，平衡近期和长期的回报，并通过调整权重来提升对策略的全面评估。

4.2　基于深度强化学习的标准系统薄弱线路辨识

表 1 列出了各个测试系统的具体参数。首先采用 Q 学习算法辨识 IEEE 5 节点系统中的薄弱线路。

表 1　各个测试系统具体参数

Table 1　Specific parameters of each test system

测试节点系统	母线	支路	负载/MW	容量/MW
IEEE 5	5	6	1 000.0	1 530.0
IEEE 39	39	46	6 176.6	7 367.0
IEEE 300	300	411	23 525.8	32 678.4

IEEE 5 节点系统时序故障后的 Q 值变化情况及线路失稳规模分别如图 8、9 所示。从图 8、9 中可看出，每次试验中所采取的动作的 Q 值变化情况与其导致的线路暂态故障失稳次数。经过约 200 次试验后，该算法趋于稳定。从图 8 中可以观察到，在初始阶段（$t=1$），Q 值初始值为 1.0，在约 10 次试验后，该值迅速下降至接近 0。这表明早期试验大多未能有效识别出薄弱线路。由于冷启动效应，100 次试验中的早期试验均为随机探索，缺乏针对性。这种 Q 值的急剧下降也说明随机或穷举搜索在识别薄弱线路序列方面效率低下。在初期试验之后，Q 学习逐步锁定薄弱线路组合，积极更新 Q 值以优化序列选择，以表征每条线路在系统暂态故障中的脆弱程度和潜在失稳影响。约 100 次试验后，Q 值趋于稳定，在不同轮次的测试中，各动作的不同预期总回报逐渐显现。该算法有效识别出了薄弱线路。

图 9 还展示了线路失稳的数量（失稳规模）。除首次故障扰动外，在 Q 学习过程中，每次扰动后的平均失稳规模都在增加，扰动后的失稳规模见表 2。第 2 次扰动的失稳规模提升最显著，该次失稳增加了 1.20 条失稳线路。在第 5 次扰动时，Q 学习实现了 0.58 条线路的额外失稳增量，且最终的平均失稳规模为 6.00，即达到 6 条线路的系统临界失稳水平。值得注意的是，系统为 N-1 安全，故首次扰动只导致一条线路失稳对应的 Q 值约为 0.58。

从图 8、9 中还可以看出，随机扰动未能利用任何先前试验中的信息，故其无法随着试验推进识别出更脆弱的序列。IEEE 5 节点系统的仿真结果也

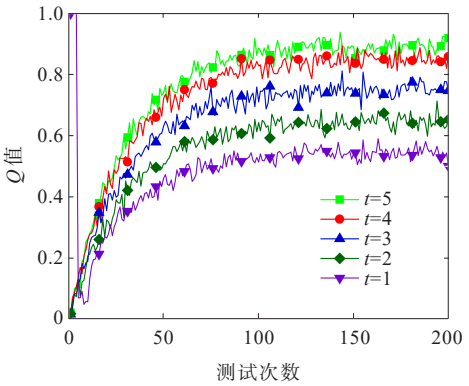

图 8　IEEE 5 节点系统时序故障后的 Q 值变化情况

Figure 8　Variation of Q value in IEEE 5 node system after timing fault

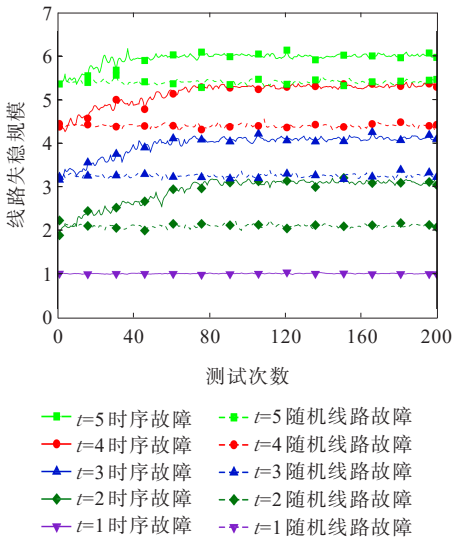

图 9　IEEE 5 节点系统时序故障后线路失稳规模

Figure 9　Scale of line instability in IEEE 5 node system after timing fault

表明，基于 Q 学习的薄弱线路辨识在逐步试验中识别潜在薄弱线路组合方面效果颇佳，其可使系统在基于纯拓扑信息的目标失稳规模下进行分析和优化。

IEEE 39 节点系统时序故障后的 Q 值变化情况及线路失稳规模分别如图 10 和图 11 所示。从图 10 中可观察到 Q 值在第 1 次至第 3 次扰动期间的变化

表 2　扰动后的失稳规模

Table 2　Instability scale after disturbance

故障序列	初始失稳规模	最终失稳规模	最优随机故障失稳规模
2	2.03	3.23	2.25
3	3.09	4.27	3.33
4	4.50	5.42	4.56
5	5.42	6.00	5.51

与这些扰动带来的各自预期总回报。从图 11 中还可以看出，在第 2 次扰动后，系统的失稳规模从 2.17 显著提升至 6.33，而在第 3 次扰动后，失稳规模进一步从 3.21 增加至 9.93。尽管 IEEE 39 节点系统具备 N-1 安全性，且系统失稳的临界目标设定为 $N_\theta = 9$，但在应用 Q 学习算法并经过 460 次试验后，仅需 3 次连续扰动故障就可达到 9 条线路失稳的程度。

从图 10、11 中还可以看出，随机扰动的结果未随着试验次数的增加表现出任何显著改善。这表明了随机扰动故障在逐步识别系统关键线路和关键扰动故障序列方面的低效性。随机扰动故障所引起的最大线路失稳数量与 Q 学习的相比，显得微不足道，随机扰动故障未能有效挖掘出系统的脆弱线路和关键故障序列。在相同的拓扑信息条件下，所提出的基于 Q 学习的扰动序列发现方法能更有效地识别出了 IEEE 39 节点系统中的关键扰动序列，更准确地定位系统中的薄弱线路，能更好地帮助识别对系统暂态稳定影响较大的线路。

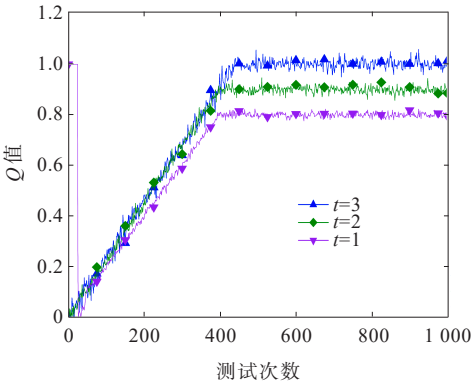

图 10 IEEE 39 节点系统时序故障后的 Q 值变化情况

Figure 10 Variation of Q value in IEEE 39 node system after timing fault

最后，以 IEEE 300 节点系统作为算例，进一步验证所提方法在大型系统中的有效性。IEEE 300 节点系统时序故障后的 Q 值变化情况及线路失稳规模分别如图 12 和图 13 所示。从图 12、13 中可以看出，在 Q 学习的过程中，Q 值逐步收敛，DRL 从第 2 次扰动开始使目标失稳事件的规模得到有效提升；在 491 次试验后，即可达到 11 条线路失稳；在 700 次试验后，达到 14 条线路失稳的状态。这是系统连锁失效和潜在的隐藏故障导致失稳规模的进一步扩大。该仿真结果表明，所提方法可以扩展应用到大规模电力系统中。在较大规模的电网下，所提方法同样能够有效识别薄弱线路，评估暂态故障下的失稳风险，具有良好的稳定性和适用性。

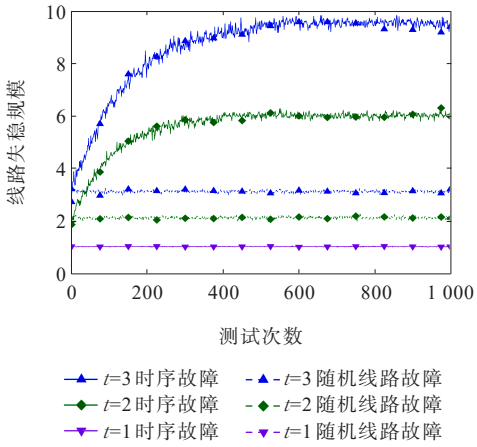

图 11 IEEE 39 节点系统时序故障后线路失稳规模

Figure 11 Scale of line instability in IEEE 39 node system after timing fault

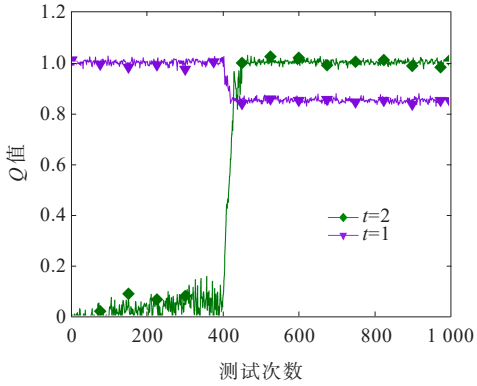

图 12 IEEE 300 节点系统时序故障后的 Q 值变化情况

Figure 12 Variation of Q value in IEEE 300 node system after timing fault

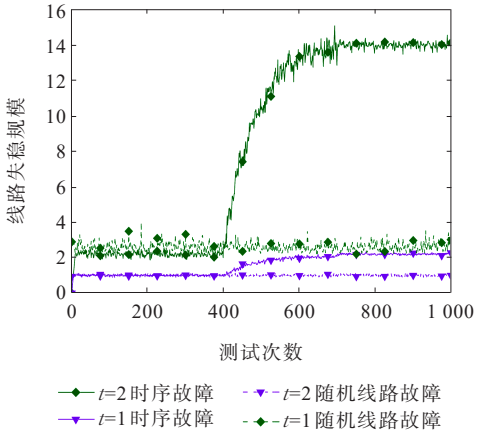

图 13 IEEE 300 节点系统时序故障后线路失稳规模

Figure 13 Scale of line instability in IEEE 300 node system after timing fault

不同系统下 Q 学习的扰动次数如图 14 所示。从图 14 中可以看出，扰动成本可通过实现目标失稳规模所需的平均扰动次数来评估。在最不成功（或

最差）情况下，可能要对系统中的更多线路施加扰动来实现失稳目标，这种情形下的扰动次数达到最大值。根据图 14 的结果，对 IEEE 5、IEEE 39 和 IEEE 300 节点系统，在初始阶段达到目标失稳规模所需的平均扰动次数分别为 5.65、8.08 和 10.03 次。IEEE 5 节点系统在 150 次试验的扰动次数下降至 4.86 次，IEEE 39 节点系统在 450 次试验的扰动次数下降至 2.91 次，IEEE 300 节点系统在 700 次试验的扰动次数下降至 3.28 次。此后，这些值保持在各自的稳定范围内，IEEE 5、IEEE 39 和 IEEE 300 这 3 个节点系统的实现目标失稳的最终扰动次数分别稳定在 4.84 次、2.88 次和 3.13 次。仿真结果显示，基于 Q 学习的方案不仅能有效减少学习过程中所需的扰动次数，还能显著提高识别系统脆弱线路和失稳风险的效率。这种方法有助于识别系统的薄弱点，能更有针对性地提高线路的稳态能力。

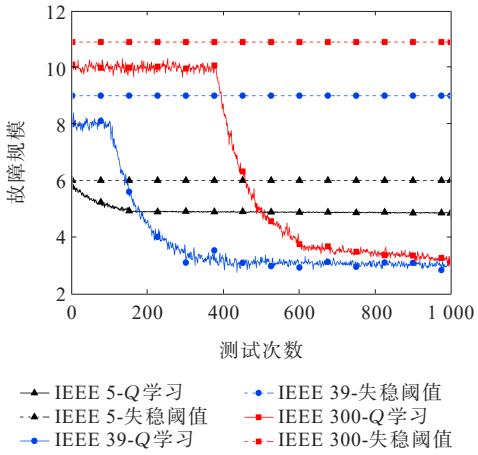

图 14　不同节点系统下 Q 学习的扰动次数

Figure 14　Number of disturbance in Q learning under different node systems

本文以 IEEE 39 节点系统仿真测试为例，展示 Q 学习识别出的时序故障。如图 7 所示的 IEEE 39 节点系统由 39 个节点和 46 条线路组成，这 46 条线路被标记为 l_1～l_{46}。

时序故障序列见表 3。表 3 中，列出了 5 组 3 线路组合以及相对应的线路故障序列。以组合（l_{26}，l_{39}，l_3）为例：在发生时序故障时，l_{26} 先发生故障，这导致了功率的重新分配，功率重新分配使得某些线路上的负载增加并且几乎达到其容量；l_{39} 再发生故障，导致与 l_{39} 连接的发电机的损耗，引起功率重新分配；最后，经过一段时间的延迟，l_3 开始发生故障，l_3 的故障进一步导致 l_{42}、l_1、l_6、l_{13}、l_9 和 l_{23} 在短时间内发生一系列故障。最终，整个电网被分成 6 个子电网。“/”表示前后故障序列无直接联系。

表 3　时序故障序列

Table 3　Sequence of timing faults

顺序故障线路	故障线路顺序
l_{26}，l_{39}，l_3	l_{26}，l_{39}，l_3，l_{42}，l_1，l_6，l_{13}，l_9，l_{23}
l_{10}，l_{33}，l_3	l_{10}，l_{33}，l_3，l_{42}，l_{23}，l_1，l_8，l_{28}，l_{38}，l_9
l_8，l_{27}，l_3	l_8，l_{27}，l_3，l_{23}，l_{42}，l_{13}/ l_{28}，l_4/ l_4，l_{29}，l_{38}
l_6，l_{33}，l_3	l_6，l_{33}，l_3，l_{42}，l_6，l_4/ l_{28}，l_{13}/ l_{38}，l_9
l_{28}，$l_{38}l_9$	l_{28}，$l_{38}l_9$，l_3，l_{42}，l_1，l_{13}，l_7，l_{24}

4.3　基于深度强化学习的标准系统不同负载率薄弱线路辨识

电力系统的负荷水平会随时间波动，故应在不同的运行点下进行测试，以验证所提出方法的鲁棒性。本文假设基准系统的默认负载水平为 100%，通过求解最优潮流得到的峰值负载为 130% 的运行点与低负载为 70% 的运行点。基于这 3 个不同的运行点，在各基准系统上分别进行多次模拟试验，分析在不同负载水平下达到失稳目标时的最终扰动规模。不同负载条件下系统暂态失稳的影响分别见表 4～6。在表 4～6 中，“—”代表在确定的负载率条件下仿真已达到失稳规模。

表 4　IEEE 5 节点系统不同负载条件下系统暂态失稳的影响

Table 4　Impact of transient instability on IEEE 5 node system under different load conditions　%

时刻	默认负载率	高负载率	低负载率
1	1.00	1.95	1.00
2	3.23	4.01	3.11
3	4.27	5.03	4.19
4	5.42	6.00	5.21
5	6.00	—	5.98
6	—	—	6.00

表 5　IEEE 39 节点系统不同负载条件下系统暂态失稳的影响

Table 5　Impact of transient instability on IEEE 39 node system under different load conditions　%

时刻	默认负载率	高负载率	低负载率
1	1.00	1.91	1.00
2	6.33	7.16	2.95
3	9.93	10.97	4.15
4	—	—	5.31
5	—	—	6.43
6	—	—	7.56
7	—	—	8.73
8	—	—	9.91

表6 IEEE 300节点系统不同负载条件下系统暂态失稳的影响

Table 6 Impact of transient instability on IEEE 300 node system under different load conditions %

时刻	默认负载率	高负载率	低负载率
1	2.09	2.67	1.00
2	14.36	14.98	3.02
3	—	—	5.64
4	—	—	9.81
5	—	—	13.08

由表4～6可知，所提方法能有效识别在不同负载水平下系统中存在的薄弱线路，并确定可能引起系统失稳的故障序列。在不同负载条件下，系统对级联故障的耐受能力有所不同。较低负载水平能缓解系统压力，提高其对连续线路故障的弹性，保证系统不会发生级联故障。而在峰值负载条件下，即便是N-1安全的系统也会更紧张、更易受影响，更容易因线路薄弱而发生失稳情况。

综上所述，所提方法能灵活地适应不同负载率条件，生成的停电规模随负载变化而调整。随着负载增加，系统对连续薄弱线路故障的敏感性增强，发生故障线路的数量和连锁反应导致的线路失稳风险显著增加。在相同的故障次数和高负载率下，所提方法更快地实现了失稳目标，体现了负载水平对系统整体稳定性的重要影响。这些结果验证了该方法在不同负载率条件下的鲁棒性和适用性。

5 结语

1）本文提出了一种基于DRL的考虑电网暂态安全稳定约束下的识别系统薄弱环节的电网脆弱性分析新方法。通过监测系统的拓扑变化，该方法利用Q学习找到导致系统出现临界性失稳的薄弱线路序列。其不仅在学习过程中提升了识别故障线路的准确率，还通过排除未引发系统级联失稳的无效序列，减少了分析所需的尝试次数。本文使用IEEE 5节点、IEEE 39节点和IEEE 300节点系统作为测试案例，进行仿真，数值仿真结果验证了所提方法在学习能力和识别电网薄弱环节方面的有效性。

2）从电网防御者和运行人员的角度来看，基于Q学习的脆弱性分析能识别潜在的顺序切换方案中的关键线路，提供关键防护信息。此外，该方法还为利用拓扑状态信息设计高破坏性的故障方案提供了借鉴，有助于提升电网抵御系统故障的态势感知能力。

本方法通过DRL技术识别出潜在的脆弱线路切换序列，但并不局限于直流潮流模型或隐含故障模型，下一步研究还可以扩展对电压、频率等因素进行脆弱性分析；进一步研究针对序列性故障的检测和缓解策略，增强电网的安全性和稳定性；还可将数据源拓展到更多参数，更准确识别对关键电力基础设施构成威胁的因素；在实际应用中精细化脆弱性检测，进一步提高方案的适应性和有效性。

参考文献：

[1] 李响，武海潮，王文雪，等. 基于电网承载能力的新能源并网适应性评估[J]. 中国电机工程学报，2023，43(增刊1)：107-113.
LI Xiang, WU Haichao, WANG Wenxue, et al. Adaptability evaluation of new energy grid connection based on power grid carrying capacity[J]. Proceedings of the CSEE, 2023, 43(Sup 1): 107-113.

[2] 周煜智，徐政，唐庚. 三种MMC-HVDC直流故障处理方法下电力系统暂态稳定性分析[J]. 中国电机工程学报，2015，35(7)：1621-1627.
ZHOU Yuzhi, XU Zheng, TANG Geng. Analysis of power system transient stability characteristics under three different DC line fault clearance solutions of MMC-HVDC systems[J]. Proceedings of the CSEE, 2015, 35(7): 1621-1627.

[3] 赵晨浩，焦在滨，李程昊，等. 基于双塔Transformer的电力系统暂态稳定评估[J]. 全球能源互联网，2024，7(5)：521-529.
ZHAO Chenhao, JIAO Zaibin, LI Chenghao, et al. Power system transient stability assessment based on two-tower transformer model[J]. Journal of Global Energy Interconnection, 2024, 7(5): 521-529.

[4] 宁楠，孙睿择，潘凯岩，等. 基于运行方式与故障信息融合的配电网保护策略优化[J]. 电力科学与技术学报，2022，37(2)：54-61.
NING Nan, SUN Ruize, PAN Kaiyan, et al. Optimization of distribution network protection strategy based on the integration of operation mode and fault information[J]. Journal of Electric Power Science and Technology, 2022, 37(2): 54-61.

[5] 蔡晔，谭林峰，王炜宇，等. 阻断电力系统N-k连锁故障传播的关键环辨识[J]. 中国电机工程学报，2025，45(23)：9202-9213.
CAI Ye, TAN Linfeng, WANG Weiyu, et al. Critical cycle identification for resisting to the N-k cascading

failure in power grids[J]. Proceedings of the CSEE, 2025, 45(23): 9202-9213.

[6] 刘宝林，谈赢杰，段燕茹，等. 基于可靠性提升度的配电系统薄弱线路评估方法[J]. 南方电网技术，2023, 17(1): 43-54.
LIU Baolin, TAN Yingjie, DUAN Yanru, et al. Evaluation method of weak lines in distribution system based on reliability improvement index[J]. Southern Power System Technology, 2023, 17(1): 43-54.

[7] 张真，欧阳森，杨墨缘，等. 计及多重不确定因素的柔性互联配电网极限线损计算方法[J]. 南方电网技术，2022, 16(12): 88-97.
ZHANG Zhen, OUYANG Sen, YANG Moyuan, et al. Calculation method of limit line loss of flexible interconnected distribution network considering multiple uncertain factors[J]. Southern Power System Technology, 2022, 16(12): 88-97.

[8] 朱博，徐攀腾，王晓雪，等. 基于混合型MMC的柔性直流电网故障电流阻断控制策略[J]. 高压电器，2024, 60(6): 148-155, 165.
ZHU Bo, XU Panteng, WANG Xiaoxue, et al. Fault current blocking control strategy for DC grid based on hybrid MMC[J]. High Voltage Apparatus, 2024, 60(6): 148-155, 165.

[9] ZHANG F Y, YANG Q Y. False data injection attack detection in dynamic power grid: a recurrent neural network-based method[J]. Frontiers in Energy Research, 2022, 10: 1005660.

[10] AN D, ZHANG F Y, YANG Q Y, et al. Data integrity attack in dynamic state estimation of smart grid: attack model and countermeasures[J]. IEEE Transactions on Automation Science and Engineering, 2022, 19(3): 1631-1644.

[11] MA W J, FANG J Y, WU J J. Analyzing robustness of complex networks against incomplete information[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(5): 2523-2527.

[12] YAN J, HE H B, ZHONG X N, et al. Q-learning-based vulnerability analysis of smart grid against sequential topology attacks[J]. IEEE Transactions on Information Forensics and Security, 2017, 12(1): 200-210.

[13] ZHU Y H, YAN J, TANG Y F, et al. The sequential attack against power grid networks[C]//2014 IEEE International Conference on Communications (ICC). Sydney, NSW, Australia. IEEE, 2014: 616-621.

[14] 肖飞，杨建平，邓祥力，等. 基于遥信数据故障编码技术及DHNN校正的电网故障诊断方法[J]. 电力系统保护与控制，2019, 47(21): 62-72.
XIAO Fei, YANG Jianping, DENG Xiangli, et al. A fault diagnosis method of power grid based on remote signal data fault coding technology and DHNN correction[J]. Power System Protection and Control, 2019, 47(21): 62-72.

[15] YAN J, TANG Y F, HE H B, et al. Cascading failure analysis with DC power flow model and transient stability analysis[J]. IEEE Transactions on Power Systems, 2015, 30(1): 285-297.

[16] 韦晓广. 输电网络时空关联分析与脆弱性评估方法[D]. 成都：西南交通大学，2019.
WEI Xiaoguang. Temporal-spatial correlationanalysis and vulnerability assessment method for transmission network[D]. Chengdu: Southwest Jiaotong University, 2019.

[17] 李大虎，孙建波，陈冰松，等. 基于风险指标与非支配故障筛选理论的安全约束机组组合算法[J]. 电力科学与技术学报，2016, 31(4): 65-72.
LI Dahu, SUN Jianbo, CHEN Bingsong, et al. Security constrained unit commitment algorithm based on risk index and non-dominated contingency screening theory [J]. Journal of Electric Power Science and Technology, 2016, 31(4): 65-72.

[18] 苟竞，刘俊勇，刘友波，等. 基于能量熵测度的电力系统连锁故障风险辨识[J]. 电网技术，2013, 37(10): 2754-2761.
GOU Jing, LIU Junyong, LIU Youbo, et al. Energy entropy measure based risk identification of power system cascading failures[J]. Power System Technology, 2013, 37(10): 2754-2761.

[19] 刘威，张东霞，丁玉成，等. 基于随机矩阵理论与熵理论的电网薄弱环节辨识方法[J]. 中国电机工程学报，2017, 37(20): 5893-5901.
LIU Wei, ZHANG Dongxia, DING Yucheng, et al. Power grid vulnerability identification methods based on random matrix theory and entropy theory[J]. Proceedings of the CSEE, 2017, 37(20): 5893-5901.

[20] 刘颂凯，龚潇，杨超，等. 结合更新机制的电力系统暂态稳定评估研究[J]. 电力科学与技术学报，2025, 40(2): 1-9.
LIU Songkai, GONG Xiao, YANG Chao, et al. Transient stability assessment of power system in combination with update mechanism[J]. Journal of Electric Power Science and Technology, 2025, 40(2): 1-9.

[21] 徐晓旭，郑鹏远，秦海杰，等. 基于场景概率分布不确定性和概率组合场景性能的微电网鲁棒经济优化[J]. 电力科学与技术学报，2024, 39(4): 187-200.
XU Xiaoxu, ZHENG Pengyuan, QIN Haijie, et al. Robust economic optimization of microgrid based on scenario probability distribution uncertainty and probability combination scenario performance[J]. Journal of Electric Power Science and Technology, 2024,

39(4): 187-200.

[22] 尚宇炜, 郭剑波, 吴文传, 等. 电力脑初探: 一种多模态自适应学习系统[J]. 中国电机工程学报, 2018, 38(11): 3133-3143.
SHANG Yuwei, GUO Jianbo, WU Wenchuan, et al. Preliminary study of electric power brain: a multimodal adaptive learning system[J]. Proceedings of the CSEE, 2018, 38(11): 3133-3143.

[23] 郑乐, 刘思远, 周小添, 等. 面向电力系统暂态稳定性评估的深度学习模型智能增强方法[J]. 电网技术, 2025, 49(7): 2649-2658.
ZHENG Le, LIU Siyuan, ZHOU Xiaotian, et al. Model enhancement for deep learning based transient stability assessment models[J]. Power System Technology, 2025, 49(7): 2649-2658.

[24] KONG W C, DONG Z Y, HILL D J, et al. Short-term residential load forecasting based on resident behaviour learning[J]. IEEE Transactions on Power Systems, 2018, 33(1): 1087-1088.

[25] 刘威, 张东霞, 王新迎, 等. 基于深度强化学习的电网紧急控制策略研究[J]. 中国电机工程学报, 2018, 38(1): 109-119+347.
LIU Wei, ZHANG Dongxia, WANG Xinying, et al. A decision making strategy for generating unit tripping under emergency circumstances based on deep reinforcement learning[J]. Proceedings of the CSEE, 2018, 38(1): 109-119+347.

[26] 李嘉文, 余涛, 张孝顺, 等. 基于改进深度确定性梯度算法的AGC发电功率指令分配方法[J]. 中国电机工程学报, 2021, 41(21): 7198-7212.
LI Jiawen, YU Tao, ZHANG Xiaoshun, et al. AGC power generation command allocation method based on improved deep deterministic policy gradient algorithm [J]. Proceedings of the CSEE, 2021, 41(21): 7198-7212.

[27] ZHANG Z M, HUANG S W, CHEN Y, et al. Key Branches identification for cascading failure based on q-learning algorithm[C]//2016 IEEE International Conference on Power System Technology (POWERCON). Wollongong, NSW, Australia. IEEE, 2016: 1-6.

[28] 刘颂凯, 周倩, 杨超, 等. 计及不确定性的随机暂态稳定约束最优潮流[J]. 电力系统及其自动化学报, 2024, 36(7): 1-10.
LIU Songkai, ZHOU Qian, YANG Chao, et al. Stochastic transient stability constrained optimal power flow with uncertainties[J]. Proceedings of the CSU-EPSA, 2024, 36(7): 1-10.