

DOI: 10.19783/j.cnki.pspc.210917

一种基于深度强化学习算法的电网有功安全校正方法

孙立钧¹, 顾雪平¹, 刘彤¹, 王铁强², 杨晓东²

(1. 华北电力大学电气与工程学院, 河北 保定 071003; 2. 国网河北省电力有限公司, 河北 石家庄 050021)

摘要: 电力系统有功安全校正对于保障电网安全运行具有重要意义。传统有功安全校正方法无法综合考虑系统潮流分布状态和机组的调整性能, 求解效率低、涉及调整的机组多, 存在调整反复的现象, 在实际应用中具有一定困难。因此, 采用深度强化学习算法, 提出一种基于深度 Q 网络(Deep Q Network, DQN)的有功安全校正策略。首先, 建立系统有功安全校正模型。其次, 采用卷积神经网络(Convolutional Neural Networks, CNN)挖掘电网运行状态深层特征。进一步利用 DQN 算法通过“状态-动作”机制, 以“奖励”为媒介, 构建电网运行状态与最优调整机组组合的映射模型, 确定调整机组。最后, 根据过载线路对调整机组的灵敏度, 计算得到调整量。IEEE39 节点系统的验证结果表明, 所提出的有功安全校正策略在处理多线路过载时可综合考虑系统潮流分布的总体状况和机组调节性能, 高效地消除线路过载。

关键词: 电力系统; 安全校正; 深度强化学习; DQN 算法; 灵敏度

A deep reinforcement learning algorithm-based active safety correction method for power grids

SUN Lijun¹, GU Xueping¹, LIU Tong¹, WANG Tieqiang², YANG Xiaodong²

(1. School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China;
2. State Grid Hebei Electric Power Co., Ltd., Shijiazhuang 050021, China)

Abstract: Active safety correction of a power system is of great importance in ensuring the safe operation of a power grid. The traditional active safety correction method cannot comprehensively consider the system power flow distribution state and the adjustment performance of the units, and has difficulties in practical application because of the low solution efficiency, the adjustment involved in many units, and the need for repeated adjustment. Therefore, an active safety correction strategy based on the deep Q network (DQN) by using a deep reinforcement learning algorithm is proposed. First, a system active safety correction model is established; secondly, convolutional neural networks (CNN) are used to explore the deep features of the grid operation state. The DQN algorithm is used to construct a mapping model of the combination of power grid operation state and optimal adjustment unit through the mechanism of "state-action" and the medium of "reward", and the adjustment unit is determined. Finally, the adjustment quantity is calculated according to the sensitivity of overload line to the adjusting unit. The validation results of the IEEE39-bus system show that the active safety correction strategy proposed can comprehensively consider the overall situation of system power flow distribution and unit regulation performance when dealing with multi-line overload, and effectively eliminate line overload.

This work is supported by the Science and Technology Project of State Grid Corporation of China (No. SGTYHT/17-JS-199).

Key words: power system; safety correction; deep reinforcement learning; DQN algorithm; sensitivity

0 引言

电力系统运行中, 将线路潮流控制在合理阈值

内是保证系统安全稳定运行的基本要求。一般情况下, 对于系统负荷波动引起的频率偏差和系统间联络线的功率波动, 可以由自动发电控制(Automatic Generate Control, AGC)进行调节^[1]。对于检修计划、线路故障等因素导致系统运行方式变化引起的线路

基金项目: 国家电网公司科技项目资助 (SGTYHT/17-JS-199)

过载, 则须重新安排机组出力来消除线路的过载情况以保证系统的安全运行。有功安全校正主要通过合理安排发电机的出力使潮流重新分配, 达到减小系统频率偏差、消除线路功率越限的目的, 当单独调整发动机出力无法达到运行要求时需考虑切负荷措施^[2-3]。

目前有功安全校正方法可划分为优化法和灵敏度算法两类^[4]。优化类方法通过制定目标函数和确定安全约束构建优化模型, 利用数学规划的方法求解。使用优化类方法进行安全校正的求解可以看作是一个最优潮流问题, 但该类方法往往只能得到局部最优解, 因此, 大多数研究集中于求解算法的改善。文献[5]通过将静态安全控制模型分解为灵敏度计算和优化控制两个子问题, 简化了求解模型的复杂度。针对求解空间大、求解慢等问题, 文献[6]建立源-荷协同静态安全校正控制模型, 在控制代价最小的情况下消除静态安全问题。文献[7]通过减小模型的搜索空间, 提高了求解效率。文献[8]将模型结合多核并行技术加快了求解速度。文献[9]将内点法与进化算法结合应用于模型求解, 通过对控制变量的局部搜索获得最优解。优化类方法能兼顾各种约束条件, 但结果涉及的调整机组的数目较多, 难以在实际系统中应用^[10]。灵敏度算法通过将各个机组对线路的灵敏度进行排序得到发电机组的调整顺序, 并以发电机出力对线路潮流的灵敏度指标为依据对发电机出力进行调整^[11-12]。这一指标虽能有效调整越限线路的潮流, 但在调整过程中容易忽略其他线路的负载状况, 可能使原本处于高负载状态的线路发生新的越限, 导致调整反复。文献[13]采用综合灵敏度反映节点注入功率对所有过载线路功率的综合影响。尽管已有兼顾其他支路的灵敏度评估指标, 但这些评估指标未能充分利用全局的状态信息。针对上述问题, 文献[14]考虑机组对过载线路和接近过载线路的影响, 提出综合灵敏度; 文献[15]考虑调整节点对正常线路的灵敏度影响, 对调整总量进行约束, 避免调整反复; 文献[16]提出综合灵敏度概念, 利用反向配对技术, 通过负荷在送电端或受电端内的相邻节点间的转移, 达到消除支路过载的目的。

随着人工智能技术的进步, 逐渐有学者将人工智能技术应用到电力系统安全校正策略中^[17-19]。深度学习对模型的状态有较强的感知能力, 强化学习则具有较强的决策能力^[20]。二者相互结合对复杂系统的感知决策问题提供了新的解决思路。文献[21]将 BP 神经网络和最小二乘支持向量机算法应用于电网安全校正, 证明了两种方法与灵敏度法相比可

以显著降低误差。文献[22]将聚类算法与原-对偶内点法相结合, 通过对电力网络潮流进行重构, 消除输电断面内部有功过载。文献[23]将反向传播神经网络与灵敏度法结合, 通过神经网络给出兼顾历史数据的灵敏度值, 避免了调整量偏小引起的多次调整。

深度强化学习将深度学习的感知能力和强化学习的决策能力相结合^[24-26], 通过神经网络建立模型, 实现了对电力系统整体状态的感知, 提取出电力系统更深层次的状态特征, 强化学习依据深度学习提取的状态特征构建起系统状态特征与动作决策的映射关系, 实现对电网的智能调节。目前采用深度强化学习解决有功安全校正的问题鲜有研究。在已有的灵敏度类有功安全校正方法中, 机组的选择多是以灵敏度为基础, 考虑其他因素建立选择指标指导机组选择, 这种选择方法须人为确定各项参数, 受主观因素的影响较大, 与实际的调整效果可能存在偏差。深度强化学习算法通过多年来在训练算法、网络结构、学习机制等方面的改进, 具有较好的应用效果, 在相关领域已有应用研究。

本文基于深度强化学习, 同时结合优化法和灵敏度法的优点, 提出了一种有功安全校正策略。该策略采用卷积神经网络(Convolutional Neural Networks, CNN)提取电网状态的深层特征, 通过深度 Q 网络(Deep Q Network, DQN)算法确定调整机组的组合, 最后以过载线路对机组的灵敏度为基础计算调整量。算法以调整效果作为“奖励”, 指导模型自主学习构建电网状态与调整机组之间的映射, 可在减少参与调整机组数目的同时, 高效地消除线路过载, 避免发电机功率的反复调节。通过与传统调整方法进行对比, 验证了本文方法的有效性。

1 有功安全校正模型

电力系统校正控制通过对系统可控变量的调整, 消除状态变量的越限现象, 使系统恢复到安全状态。有功安全校正是其中一项重要内容, 一般情况下有功安全校正通过调整发电机出力, 使系统潮流重新分配, 达到消除系统中过载线路的目的。因此有功安全校正通常研究发电机出力的调整顺序、调整幅度等内容。常用的方法包括有约束最优化方法和灵敏度分析法。

一般情况下, 稳态运行条件下的电力系统有功安全校正模型可用以下的模型来描述。

1.1 目标函数

有功安全校正模型可根据具体要求设置不同目标函数。以消除线路过载为目的时, 有功校正的目

标函数通常以机组功率调整量最小为优化目标, 目标函数可表示为 $\min \sum_{i=1}^N |\Delta P_k|$, 其中 ΔP_k 表示第 k 个机组的调整量。

1.2 约束条件

1.2.1 系统有功功率平衡约束

在不计网损的情况下, 机组出力和负荷的大小应满足式(1)。

$$\sum_{i \in N} P_i = \sum_{j \in L} L_j \quad (1)$$

式中: P_i 为机组 i 的有功功率; L_j 为节点 j 的有功负荷。

1.2.2 机组出力约束

机组出力应满足式(2)。

$$P_i^{\min} \leq P_i \leq P_i^{\max} \quad (2)$$

式中: P_i^{\max} 为机组 i 出力上限; P_i^{\min} 为机组 i 出力下限; P_i 为机组 i 的有功出力。

1.2.3 线路有功安全约束

线路潮流应满足式(3)。

$$P_L^{\min} \leq P_L \leq P_L^{\max} \quad (3)$$

式中: P_L^{\max} 为线路 L 最大潮流限值; P_L^{\min} 为线路 L 最小潮流限值; P_L 为线路 L 的实际有功功率。

等式约束表示在任何时刻发电机产生的功率与负荷消耗的功率相等; 不等式约束条件表示在有合格电能质量的条件下, 系统内的有关设备处于安全的运行限值内。

2 DQN 算法

2.1 DQN 算法简介

Q 学习算法是解决马尔可夫决策过程的经典方法, 同时是不依赖环境模型的强化学习算法。该算法通过不断更新状态-动作值函数, 达到学习目标最优策略的目的。其迭代公式为

$$Q_{t+1}(s_t, a_t) = Q_t(s_t, a_t) + \alpha \delta_t \quad (4)$$

式中: Q_{t+1} 为第 $t+1$ 次迭代的值函数; Q_t 为第 t 次迭代的值函数; α 为学习率; s_t 为第 t 次迭代的状态; a_t 为第 t 次迭代的动作; δ_t 为第 t 次循环的时间差分误差, 详细表达式如式(5)所示。

$$\delta_t = r_{t+1} + \gamma Q_t(s_{t+1}, a') - Q_t(s_t, a_t) \quad (5)$$

式中: a' 为状态 s_{t+1} 时执行的动作; r_{t+1} 为第 $t+1$ 次迭代获得的奖励, 本文中奖励计算方式见第 3.3 节; γ 为衰减因子。

Q 学习算法需要构建状态-动作的一一对应关系, 对于状态空间和动作空间的要求是离散且有限

的, 因此将强化学习运用于实际问题时需要将实际状态和动作进行离散化处理, 较高的离散化粒度使算法的泛化能力变弱, 而较低的离散化粒度则会带来维数灾难。

针对 Q 学习算法的不足, DeepMind 公司于 2013 年提出 DQN 算法, DQN 算法利用神经网络强大的拟合能力构建状态-动作的对应关系, 直接对状态-动作值函数进行表征, 将强化学习的应用范围扩展到了连续、高维的实际问题, 结合目标网络技术和经验回放机制, 使其更加贴近实际应用场景。

2.2 值函数

DQN 算法采用卷积神经网络来逼近动作值函数, 即 $Q(s, a; \theta) \approx Q_\pi(s, a)$ 。卷积神经网络由输入层、卷积层、池化层、全连接层和输出层组成。其中卷积层是卷积神经网络的核心, 其功能是实现输入量的特征提取, 池化层用于数据和参数的压缩提取其中重要特征, 全连接层将卷积层和池化层特征进行加权, 将特征空间变换映射到样本标记空间。其具体结构如图 1 所示。

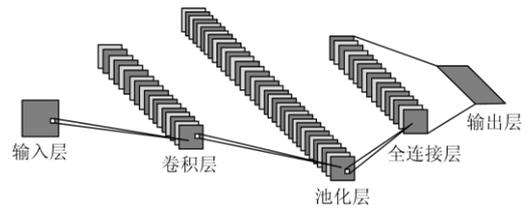


图 1 卷积神经网络结构

Fig. 1 Convolutional neural network structure

2.3 Q 网络与目标 Q 网络

DQN 模型训练过程中采用最小化损失函数进行参数更新, 如式(6)所示。

$$L_t(\theta_t) = E_{(s, a, r, s')} (y - Q(s, a; \theta_t))^2 \quad (6)$$

式中: $L_t(\theta_t)$ 为 t 时的损失函数; θ_t 为 t 时 Q 网络的参数; s 为状态; a 为动作; $E_{(s, a, r, s')}$ 为数学期望; y 为 Q 网络的优化目标值, 如式(7)所示。

$$y = r + \gamma Q(s', a'; \theta_t^-) \quad (7)$$

式中: θ_t^- 为目标网络的参数; s' 为下一轮迭代的状态; a' 为下一轮迭代的动作; r 表示在 θ_t^- 条件下状态执行动作 a' 所获得的累计折扣奖励。

Q 网络基于梯度更新网络权重, 式(6)的损失函数对权重求偏导, 即可得到:

$$\nabla_{\theta_t} L_t(\theta_t) = E_{(s, a, r, s')} [(y - Q(s, a; \theta_t)) \nabla_{\theta_t} Q(s, a; \theta_t)] \quad (8)$$

式中, ∇ 表示梯度计算。

目标 Q 网络与 Q 网络具有相同的神经网络结构。深度强化学习在训练过程中, 当采用非线性函

数逼近 Q 值函数时, Q 值的更新容易发生震荡, 呈现出不稳定的学习行为, 因此引入目标 Q 网络。目标 Q 网络在结构上与 Q 网络相同, 但在目标 Q 网络中, 参数会在一定步数后独立更新, 因此训练过程中 Q 值暂时固定, 使学习过程更加稳定。

2.4 经验回放机制

深度强化学习在数据学习过程中存在经验数据相关性和非平稳分布的问题。DQN 算法通过引入经验回放机制成功解决这两个问题。在该机制中, 每次训练获取的经验都储存在经验池中, 每次学习时从经验池中抽取一部分数据进行学习。该方法具有多个优势: 首先经验可以重复学习, 提高了数据利用率; 其次由于样本之间的强相关性, 直接学习连续样本效果较差, 采用经验池打破了样本之间的相关性, 加快算法收敛速度; 最后采用经验回放可避免算法陷入局部最优解, 通过经验回放行为, 分布可在许多先前状态中进行平均, 从而平滑学习过程, 避免参数波动或发散。

3 基于深度强化学习的有功安全校正

本文综合优化法和灵敏度法各自的优势, 提出基于 DQN 算法的有功安全校正策略。该策略采用 DQN 模型评估系统状态, 并给出调整机组的组合。DQN 算法中用卷积神经网络代替 Q 算法中的值函数, 避免了系统规模扩大导致的效率降低问题。该策略在确定调整机组后根据灵敏度计算调整量, 实现线路过载的准确消除。深度强化学习方法用于有功校正的示意图如图 2 所示。

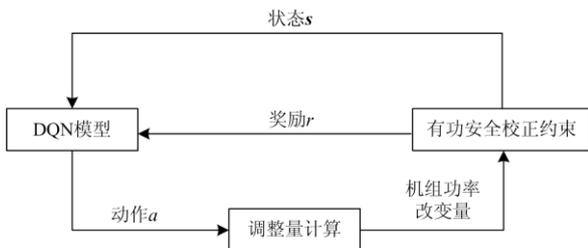


图 2 基于深度强化学习的有功安全校正模型示意图

Fig. 2 Schematic diagram of active power safety correction model based on deep reinforcement learning

3.1 状态空间的建立

传统灵敏度算法以过载线路对机组的灵敏度作为制定调整策略的依据。这类方法仅考虑发电机组对过载线路的影响, 而未考虑出力改变后对其他重载线路及系统整体状态的影响, 易导致调整反复、低效。因此综合考虑线路负载、系统拓扑和节点负荷, 提出了状态矩阵, 如式(9)所示。

$$s = \begin{bmatrix} s_{11} & \cdots & s_{1j} & \cdots & s_{1n} \\ \vdots & & \vdots & & \vdots \\ s_{i1} & \cdots & s_{ij} & \cdots & s_{in} \\ \vdots & & \vdots & & \vdots \\ s_{n1} & \cdots & s_{nj} & \cdots & s_{nn} \end{bmatrix} \quad (9)$$

式中: 当 $i=j$ 时, s_{ij} 为节点 i 所带负载, 其中向系统输出功率为正值, 向系统索取功率为负值; 当 $i \neq j$ 时, s_{ij} 为以节点 i 和节点 j 为端点的线路上流过的功率, 方向由节点 i 指向节点 j 。

3.2 动作空间的描述

电力系统有功安全校正策略的其中之一是调节机组选择。系统中线路受机组出力变化量的影响不同, 选择合适的机组组合可以在保证调整效果的前提下减小调整量。本文中的有功校正机组控制动作策略由 DQN 模型输出动作值确定, 表示为 $a_c = \{a_1, a_2, \dots, a_i, \dots, a_n\}$ 。其中 a_i 的含义见式(10)。

$$a_i = \begin{cases} 1 & \text{机组 } i \text{ 作为增加出力机组} \\ 0 & \text{机组 } i \text{ 不参与调节} \\ -1 & \text{机组 } i \text{ 作为减少出力机组} \end{cases} \quad (10)$$

3.3 奖励函数的构建

强化学习是计算机以“试错”的方式进行学习, 通过与环境交互获得的奖励指导行为, 目标是获得最大的奖励。强化学习中的奖励是对模型决策的一种评价, 而不是告诉计算机如何产生正确的动作, 因此设计一个合适的奖励对于提高强化学习的效率尤为重要。在实际操作中, 调整过载线路不仅仅关注消除过载线路, 同时应考虑机组出力变化对系统整体状态的影响以及调整成本最小化。为了以较低的成本实现机组出力的调整, 达到改善系统整体负载率的目的, 本文将调整前后机组的发电成本减少量作为经济性的评价指标, 将线路负载率的标准差作为系统整体状态的评价指标, 提出如式(11)所示的奖励函数。

$$r = \frac{1}{T} (k_1 \sum_{i \in K} (\sum_{j \in M} F_{ij} \Delta P_{Gij}) + k_2 \sqrt{\frac{\sum_{i \in N} (\mu_i - \bar{\mu})^2}{N}}) \quad (11)$$

式中: F_{ij} 为机组 i 在第 j 个容量段上的调整成本 (万元/(MW h)); ΔP_{Gij} 为机组 i 在第 j 个容量段上调整的有功出力 (MW); K 为机组集合; M 为机组调整成本的规定容量段数; μ_i 为第 i 条线路的负载率; N 为系统线路的数目; T 为每一轮学习时的迭代次数; k_1 、 k_2 分别为发电成本系数和整体负载率系数, 根据需要取不同值。

3.4 机组调整量的确定

在确定需要调整的机组后, 根据待调整线路对机组的灵敏度确定各个机组的调整量。电力系统安全校正中的灵敏度是指节点有功出力对支路有功潮流的灵敏度, 是指当控制变量发生微小变化时, 状态变量和输出变量相应地发生微小变化, 它们之间的微分比例关系称作灵敏度指标。本文提出的调整策略在 Q 网络给出调整机组组合后, 以机组对过载线路的灵敏度计算机组的调整量。用于有功安全校正的灵敏度指标可由潮流方程推导得出。

在稳态条件下, 电力系统可由 n 个非线性网络方程表示。

$$f(\mathbf{u}, \mathbf{x}) = 0 \quad (12)$$

式中: \mathbf{u} 表示控制变量的列向量; \mathbf{x} 表示状态变量的列向量。方程形式随着控制变量和状态变量的选取、坐标形式的变化而有所不同。在某一稳定运行点下, 该式变为

$$f(\mathbf{u}_0, \mathbf{x}_0) = 0 \quad (13)$$

在系统运行状态发生变化后, \mathbf{x} 、 \mathbf{u} 分别产生偏差量 $\Delta \mathbf{x}$ 和 $\Delta \mathbf{u}$, 此时系统的平衡方程变为

$$f(\Delta \mathbf{u} + \mathbf{u}_0, \Delta \mathbf{x} + \mathbf{x}_0) = 0 \quad (14)$$

式(14)在运行点处采用泰勒级数展开, 略去二阶以上高阶项, 得

$$f(\mathbf{x}_0, \mathbf{u}_0) + \frac{\partial f}{\partial \mathbf{x}} \Delta \mathbf{x} + \frac{\partial f}{\partial \mathbf{u}} \Delta \mathbf{u} = 0 \quad (15)$$

结合式(10), 式(15)变为

$$\frac{\partial f}{\partial \mathbf{x}} \Delta \mathbf{x} + \frac{\partial f}{\partial \mathbf{u}} \Delta \mathbf{u} = 0 \quad (16)$$

该式为灵敏度方程的基本形式。

由式(16)的线性模型, 可得到控制变量 $\Delta \mathbf{u}$ 和被控变量 $\Delta \mathbf{x}$ 的线性关系为

$$\Delta \mathbf{u} = -\left(\frac{\partial f}{\partial \mathbf{u}}\right)^{-1} \frac{\partial f}{\partial \mathbf{x}} \Delta \mathbf{x} = \mathbf{S} \Delta \mathbf{x} \quad (17)$$

式中, $\mathbf{S} = -\left(\frac{\partial f}{\partial \mathbf{u}}\right)^{-1} \frac{\partial f}{\partial \mathbf{x}}$, 称为灵敏度矩阵。

灵敏度反映了线路潮流对发电机出力改变的敏感程度, 根据灵敏度矩阵, 可计算出消除过载线路需要改变的发电机调节量, 见式(18)。

$$\begin{cases} \Delta \mathbf{u} = \mathbf{S} \Delta \mathbf{x} \\ a_c \Delta \mathbf{u} = 0 \end{cases} \quad (18)$$

式中: $\Delta \mathbf{u}$ 为发电机机组出力改变量的向量; $\Delta \mathbf{x}$ 为线路越限量向量; a_c 为动作策略集合。

3.5 基于 DQN 的有功安全校正方法

首先应基于 DQN 算法对样本数据进行深度强化学习, 训练得到有功安全校正模型。对电力系统

随机断开线路, 获得不同运行状态下的潮流分布, 之后根据式(9)构建训练样本。

基于 DQN 算法的有功安全校正模型训练过程如图 3 所示。

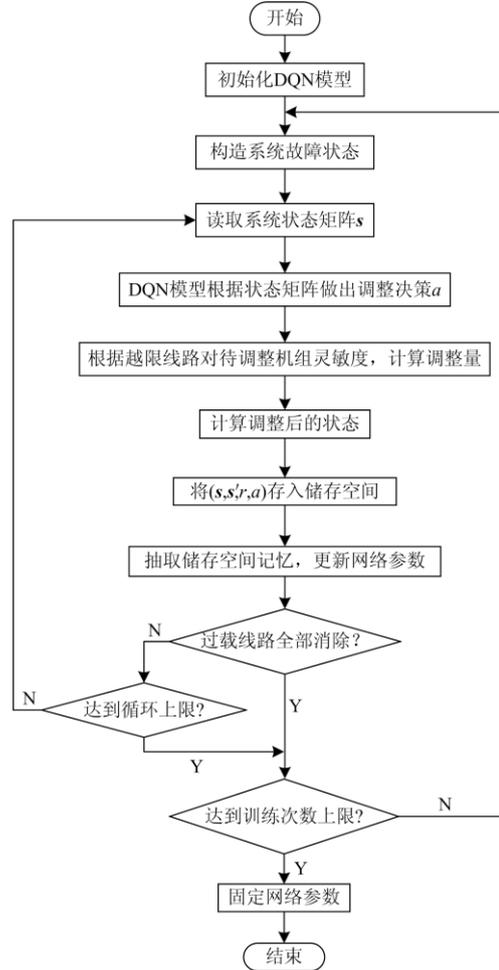


图 3 基于 DQN 算法的有功安全校正模型训练流程图

Fig. 3 Training flow chart of active safety correction model based on DQN algorithm

训练结束后, DQN 模型的参数将被保存, 在有功安全校正问题中可加载模型参数直接用于问题的求解。

本文方法基于深度强化学习模型确定参与调节的机组, 根据机组相对于过载线路的灵敏度计算相应的调节量, 过程如下所述。

校正过程采用已经训练完成的模型。首先模型读取系统状态信息, 并根据读取的状态信息给出参与调节的机组, 包括增出力机组和减出力机组。然后在确定参与调节的机组后, 根据灵敏度计算参与调节机组的出力变化量。根据新的机组出力计算系统潮流, 判断过载能否全部消除。若过载被消除,

则说明调整策略对于消除当前状态的线路过载有效, 系统执行调整策略; 若线路过载无法被消除, 则说明在当前状态下采取机组出力再分配的调整策略无法完全消除线路过载, 只能在一定程度上降低

线路过载的影响, 须考虑切负荷策略, 达到消除过载的目的。

基于 DQN 算法的有功安全校正模型图如图 4 所示。

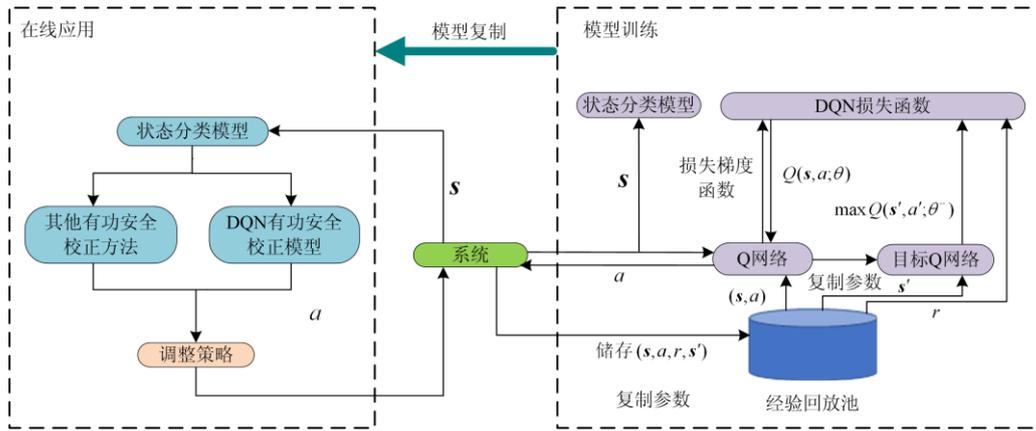


图 4 基于 DQN 算法的有功安全校正模型图

Fig. 4 Flow chart of active safety correction based on DQN algorithm

4 算例仿真

本文以 IEEE39 节点系统为例进行分析(如图 5 所示), 将实验结果与传统调整策略进行对比, 验证了本文所提方法的有效性。实验设计采用 Pycharm 开发环境在 Tensorflow 框架下建立有功安全校正模型, 利用 Matpower 计算系统潮流。

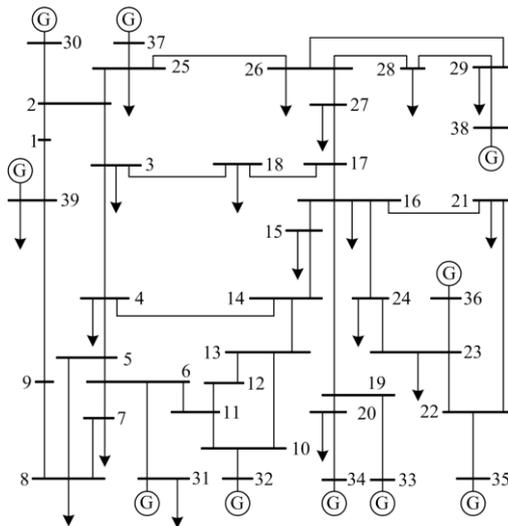


图 5 IEEE39 节点系统

Fig. 5 IEEE 39-bus system

初始系统参数如表 1 所示。

当线路 23-24 线路断开后, 线路 21-22、16-21 出现过载, 两条线路过载量分别为 135.8367 MW 和

表 1 系统初始状态参数

Table 1 System initial state parameters

节点 编号	负荷量/ MW	节点 编号	出力量/ MW	负荷量/ MW	成本/(万元/ MWh)
3	14.548	27	—	87.438	—
4	52.152	28	—	399.378	—
7	75.342	29	—	124.981	—
8	75.414	30	134.624	—	0.038
10	9.610	31	242.284	378.951	0.03
12	135.286	32	21.723	—	0.039
15	92.148	33	253.518	—	0.035
16	225.594	34	306.265	—	0.032
18	242.011	35	562.138	—	0.03
21	528.407	36	556.491	—	0.032
22	70.553	37	20.803	—	0.035 2
24	454.595	38	804.727	—	0.03
25	130.339	39	290.914	66.970	0.032
26	29.772	—	—	—	—

59.205 2 MW, 超出线路允许传输功率最大值 15.09%和 9.87%。

当采用本文算法进行调整时, 依据线路越限的严重程度对线路依次校正。首先形成状态矩阵, 输入模型得到参与调整的机组为 34 号、36 号, 其中 34 号机组为加出力机组, 36 号机组为减出力机组。根据线路 21-22 对两组机组的灵敏度可以得到, 机组出力的改变量为 146.134 6 MW, 经过本轮调整, 线路 21-22 越限消除。模型更新当前的状态矩阵, 得到下一轮参与调整的机组为 32 号和 39 号, 其中

32 号机组增加出力 82.461 3 MW, 39 号机组减小相应出力, 经过本轮调整, 线路 26-29 越限情况被消除。

若采用传统灵敏度方法, 首先对线路 21-22 进行调整, 经计算, 第一轮调整选择 36 号、38 号机组, 根据相应的调整策略, 36 号机组增加出力, 38 号机组减少出力, 由于机组最大出力的限制, 机组出力改变量被限制为 60.273 2 MW, 经过本轮调整, 线路 21-22 负载率有所降低, 从 1.150 9 降低至 1.102 7, 越限情况未消除; 第二轮选择机组 30 号和 37 号, 机组的出力调整分别为 47.084 6 MW 和 -47.084 6 MW, 经过本轮调整, 线路 21-22 的过载被消除。之后对线路 16-21 的过载进行消除, 首先根据相应策略, 选择 32 号与 39 号机组, 分别增加出力 76.564 2 MW 和减少相应出力, 此时虽然消除了线路 26-29 的越限现象, 但线路 22-35 出现了潮流越限, 根据调整策略, 30 号机组出力增加 50.624 7 MW, 并减少 39 号机组相应出力, 可消除线路 16-21 过载现象, 且并未出现新的线路过载。若采用优化方法, 以调整量最小为目标函数, 采用规划法得到相应调整结果。3 种策略出力调整结果与调整成本结果分别如表 2、表 3 所示。

由表 2 可以看出: 优化类方法调整策略涉及 8 台发电机, 调整发电机的数量过多, 增加了实际调度执行的困难程度。传统灵敏度法虽能减少参与调整的机组数量, 但在调整的过程中导致新的过载线路出现, 扩大了过载范围。本文方法以最少的机组达到消除过载线路的目的。

由表 3 可以看出: 本文方法将调整成本纳入机组的选择依据当中, 相比于优化法和传统灵敏度法, 调整成本分别降低了约 45%、47%。

表 2 3 种调整策略出力调整量结果对比

Table 2 Comparison of the results of the three adjustment strategies

发电机节点	出力调整/MW		
	优化法	传统灵敏度法	本文方法
30	46.397 1	97.709 3	—
31	29.457 8	—	—
32	40.153 4	76.564 2	82.461 3
33	—	—	—
34	—	—	146.134 6
35	-100.676	—	—
36	-70.110 6	60.273 2	-146.134 6
37	80.504 7	-47.084 6	—
38	-56.967 5	-60.273 2	—
39	31.240 9	-127.188 9	-82.461 3
调整总量/MW	455.507 8	469.093 4	457.191 8
参与调整的 机组数量/台	8	6	4

表 3 三种调整策略调整成本结果对比

Table 3 Comparison of adjustment cost results of three adjustment strategies

发电机节点	出力调整成本改变量/(万元/MWh)		
	优化法	传统灵敏度法	本文方法
30	1.763 1	3.713 0	—
31	0.883 7	—	—
32	1.566 0	2.986 0	3.216 0
33	—	—	—
34	—	—	4.676 3
35	-3.020 3	—	—
36	-2.243 5	1.928 7	-4.676 3
37	2.833 8	-1.657 4	—
38	-1.709 0	-1.808 2	—
39	0.999 7	-4.070 0	-2.638 8
总费用/(万元/MWh)	1.073 4	1.092 1	0.577 2

为进一步体现本文方法与优化类方法和灵敏度方法相比所具有的优势, 将线路初始负载率由高到低排序后进行编号, 同时采用 3 种策略对线路进行调整。在初始状态下, 线路 21-22、16-21 分别过载 15.09%、9.87%, 多数线路的负载水平处于 20%~80%, 但仍有 13 条线路的负载率不足 10%, 调整结果如图 6 所示。

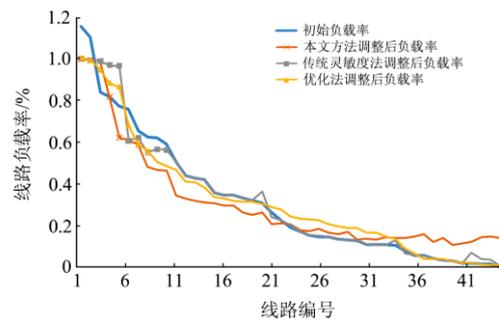


图 6 2 种不同策略调整后线路负载率

Fig. 6 Line load factor after adjustment by two different strategies

由图 6 可以看出: 传统灵敏度法在调整过程中通过将过载线路的负载转移至另外 3 条重负载线路, 达到消除过载的目的, 但调整结束后系统将出现 5 条处于高负载率的线路, 当系统高负载率线路较多时, 易产生新的过载线路。优化类方法调整结果依然存在较多的负载率较低的线路, 对于系统的整体状况没有较大改善。本文方法通过综合考虑机组出力成本、过载线路对机组的灵敏度和系统的整体负载, 引导 DQN 算法将过载线路的负载向负载率较低的线路转移, 在达到较小成本的同时减轻系

统整体的负载率, 避免产生新的重载线路。

对比 3 种调整策略可见, 传统灵敏度法未考虑机组调节容量, 选择最高灵敏度的机组可能调整容量不足、调整过程中可能出现新的线路过载, 使处于过载状态的线路扩大。而优化类方法参与调整的机组过多。同时两种传统方法均未将调整成本纳入机组选择的考虑因素。本文通过 DQN 算法调整机组特性与系统状态之间的映射关系, 将负载较重的线路的潮流在调整过程中向负载较轻的线路转移, 提高了轻载线路的负载率, 改善了系统的整体负载水平, 提高了系统应对负荷增加的能力。同时机组的选择考虑了线路对机组的灵敏度、机组的可调容量和机组的调整成本, 在避免了传统调整策略仅选择灵敏度最高的机组而导致机组可调容量不足的同时降低了调整成本。

5 结论

本文将 DQN 算法应用于有功安全校正, 实现了以消除线路过载为目标的机组出力准确调整。首先建立有功安全校正模型, 采用 DQN 算法综合考虑机组调整容量、调整成本以及系统整体潮流状态, 建立系统状态与最优调整机组组合的对应模型; 进一步, 依据灵敏度法确定各机组的调整量, 达到消除线路过载的目的。采用 IEEE39 节点系统算例验证了本文方法的有效性和可行性。本文方法具有以下优势:

1) 与传统有功安全校正方法相比, DQN 算法通过引入“奖励”媒介, 能够选择对过载线路影响较大的机组的前提下兼顾机组调整容量, 以较小的机组调整量的同时避免了过多机组参与调整。

2) 该方法相比于传统灵敏度调整方法更加高效。由于采用卷积神经网络挖掘运行状态的深层特征, 在多支路过载的情况下可兼顾其他负载率较高的线路, 避免了调整反复的现象。

参考文献

[1] 杨蕾, 李胜男, 黄伟, 等. 考虑风光新能源参与二次调频的多源最优协同控制[J]. 电力系统保护与控制, 2020, 48(19): 43-49.
YANG Lei, LI Shengnan, HUANG Wei, et al. Optimal coordinated control of multi-source for AGC with participation of wind and solar energy[J]. Power System Protection and Control, 2020, 48(19): 43-49.

[2] 林涛, 毕如玉, 陈汝斯, 等. 基于二阶锥规划的计及多种快速控制手段的综合安全校正策略[J]. 电工技术学报, 2020, 35(1): 167-178.
LIN Tao, BI Ruyun, CHEN Rusi, et al. Comprehensive security correction strategy based on second-order cone programming considering multiple fast control measures[J].

Transactions of China Electrotechnical Society, 2020, 35(1): 167-178.

[3] MAGDY G, MOHAMED E A, SHABIB G, et al. Microgrid dynamic security considering high penetration of renewable energy[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 236-246.

[4] 刘太学, 李晨光, 王芸波. 电力系统安全校正问题研究综述[J]. 中国电力教育, 2010(4): 256-258.
LIU Taixue, LI Chenguang, WANG Yunbo. A review of power system safety correction problems[J]. China Electric Power Education, 2010(4): 256-258.

[5] 赵晋泉, 江晓东, 张伯明. 一种基于连续线性规划技术的在线静态安全校正算法[J]. 电网技术, 2005, 29(5): 25-30.
ZHAO Jinquan, JIANG Xiaodong, ZHANG Boming. A successive linear programming based on-line static security corrective control approach[J]. Power System Technology, 2005, 29(5): 25-30.

[6] 王艳松, 卢志强, 李强, 等. 基于源-荷协同的电网静态安全校正最优控制算法[J]. 电力系统保护与控制, 2019, 47(20): 73-80.
WANG Yansong, LU Zhiqiang, LI Qiang, et al. Optimal control algorithm for static safety correction of power grid based on source-load coordination[J]. Power System Protection and Control, 2019, 47(20): 73-80.

[7] KUCUKTEZCAN C F, GENÇ V. Preventive and corrective control applications in power systems via big bang-big crunch optimization[J]. International Journal of Electrical Power and Energy Systems, 2015, 67.

[8] 傅志生, 白晓清, 李佩杰, 等. 一种快速求解大规模安全约束最优潮流的多核并行方法[J]. 电力系统保护与控制, 2015, 43(3): 29-37.
FU Zhisheng, BAI Xiaoqing, LI Peijie, et al. A high-speed multi-core parallel method for solving large-scale security constrained OPF[J]. Power System Protection and Control, 2015, 43(3): 29-37.

[9] WEN Yunfeng, GUO Chuangxin. Discussion on "Solving preventive-corrective SCOPF by a hybrid computational strategy"[J]. IEEE Transactions on Power Systems, 2014, 29(6): 3124-3134.

[10] 吴际舜, 侯志俭. 利用带上、下界变量的线性规划法求解有功安全校正问题[J]. 电力系统自动化, 1985, 9(1): 12-20.
WU Jishun, HOU Zhijian. Active power security control using liner programming with bounded variables[J]. Automation of Electric Power Systems, 1985, 9(1): 12-20.

[11] 徐双双, 姚维为. 基于灵敏度分析的有功安全校正[J]. 机电信息, 2015(33): 66-67.
XU Shuangshuang, YAO Weiwei. Active safety correction based on sensitivity analysis[J]. Mechatronics Information, 2015(33): 66-67.

[12] 代飞, 崔挺, 徐箭, 等. 基于综合灵敏度分析的电压校正控制[J]. 电力自动化设备, 2011, 31(12): 15-20.
DAI Fei, CUI Ting, XU Jian, et al. Voltage correction

- control based on comprehensive sensitivity analysis[J]. Electric Power Automation Equipment, 2011, 31(12): 15-20.
- [13] 罗永建, 李晓明, 黄彦浩, 等. 基于准稳态灵敏度和校正成本最小化的过载线路实时校正方法[J]. 电力系统保护与控制, 2020, 48(23): 1-10.
LUO Yongjian, LI Xiaoming, HUANG Yanhao, et al. Real-time correction method for overloaded lines based on quasi-steady-state sensitivity and correction cost minimization[J]. Power System Protection and Control, 2020, 48(23): 1-10.
- [14] 程临燕, 郝治国, 张保会, 等. 基于内点法消除输电断面过载的实时控制算法[J]. 电力系统自动化, 2011, 35(17): 51-55.
CHENG Linyan, HAO Zhiguo, ZHANG Baohui, et al. Fast elimination of overload in transmission line section based on simplified primal-dual interior point method[J]. Automation of Electric Power Systems, 2011, 35(17): 51-55.
- [15] 姚峰, 张保会, 周德才, 等. 输电断面有功安全性保护及其快速算法[J]. 中国电机工程学报, 2006, 26(13): 31-36.
YAO Feng, ZHANG Baohui, ZHOU Decai, et al. Active power security protection of transmission section and its fast algorithm[J]. Proceedings of the CSEE, 2006, 26(13): 31-36.
- [16] 钟贵和, 王星华, 甘德树, 等. 输电断面的有功安全预防-校正负荷调整算法[J]. 电力系统保护与控制, 2014, 42(16): 15-20.
ZHONG Guihe, WANG Xinghua, GAN Deshu, et al. Load adjusted algorithm on active power prevention-correction of transmission section[J]. Power System Protection and Control, 2014, 42(16): 15-20.
- [17] 刘朝阳, 穆朝絮, 孙长银. 深度强化学习算法与应用研究现状综述[J]. 智能科学与技术学报, 2020, 2(4): 314-326.
LIU Zhaoyang, MU Chaoyu, SUN Changyin. An overview on algorithms and applications of deep reinforcement learning[J]. Journal of Intelligent Science and Technology, 2020, 2(4): 314-326.
- [18] 魏敏, 叶剑. 遗传算法在电力市场下有功安全校正中的应用[J]. 华中电力, 2003, 16(4): 1-5.
WEI Min, YE Jian. Application of genetic algorithm in active safety correction in an electricity market[J]. Central China Power, 2003, 16(4): 1-5.
- [19] 秦心筱, 张昌华, 徐子豪, 等. 基于卷积神经网络的电力系统低频振荡主导模态特征定性辨识[J]. 电力系统保护与控制, 2021, 49(10): 51-58.
QIN Xinxiao, ZHANG Changhua, XU Zihao, et al. Research on qualitative identification of a low frequency oscillations dominant mode in power system based on a convolutional neural network[J]. Power System Protection and Control, 2021, 49(10): 51-58.
- [20] WANG H N, LIU B, ZHANG Y, et al. A review of deep reinforcement learning[J]. Frontiers of Information Technology & Electronic Engineering, 2020, 21(12): 1726-1745.
- [21] 王鹏翔. 基于机器自学习的电网安全校正算法研究[D]. 北京: 华北电力大学, 2011.
WANG Pengxiang. The study of active power security correction algorithm based on machine self-learning methods[D]. Beijing: North China Electric Power University, 2011.
- [22] 孙淑琴, 颜文丽, 吴晨悦, 等. 基于原-对偶内点法的输电断面有功安全校正控制方法[J]. 电力系统保护与控制, 2021, 49(7): 75-85.
SUN Shuqin, YAN Wenli, WU Chenyue, et al. Active power flow safety correction control method of transmission sections based on a primal-dual interior point method[J]. Power System Protection and Control, 2021, 49(7): 75-85.
- [23] 朱足君, 李扬, 陈文浩, 等. 节能发电调度中的有功安全校正策略[J]. 电力系统及其自动化学报, 2008, 20(6): 47-50.
ZHU Zujun, LI Yang, CHEN Wenhao, et al. Correction strategy of active power security in energy conservation generation dispatching[J]. Proceedings of the CSU-EPSA, 2008, 20(6): 47-50.
- [24] 王之伟, 陆晓, 刁瑞盛, 等. 基于深度强化学习的电网自主控制与决策技术[J]. 电力工程技术, 2020, 39(6): 34-43.
WANG Zhiwei, LU Xiao, DIAO Ruisheng, et al. Deep-reinforcement-learning based autonomous control and decision making for power systems[J]. Electric Power Engineering Technology, 2020, 39(6): 34-43.
- [25] ZHANG Z, ZHANG D, QIU R C. Deep reinforcement learning for power system applications: an overview[J]. CSEE Journal of Power and Energy Systems, 2020, 6(1): 213-225.
- [26] DU W, DING S. A survey on multi-agent deep reinforcement learning: from the perspective of challenges and applications[J]. Artificial Intelligence Review, 2020, 53: 1-24.

收稿日期: 2021-07-16; 修回日期: 2021-09-02

作者简介:

孙立钧(1997—), 男, 通信作者, 硕士研究生, 主要研究方向为人工智能技术及其在电力系统中的应用、电力系统安全评估与控制; E-mail: does877@163.com

顾雪平(1964—), 男, 博士, 教授, 博士研究生导师, 主要研究方向为电力系统安全稳定评估与控制、电力系统安全防御与恢复控制、智能技术在电力系统中的应用; E-mail: xpgu@ncepu.edu.cn

刘彤(1996—), 女, 博士研究生, 主要研究方向为人工智能技术及其在电力系统中的应用、电力系统安全评估与控制。E-mail: tongliu_1996@163.com

(编辑 姜新丽)