

doi: 10.7690/bgzd.2025.05.023

基于 Actor-Critic 算法的无人机集群任务分配方法

苏瑞¹, 龚俊¹, 张鸿宇²

(1. 中国兵器装备集团自动化研究所有限公司特种计算机事业部, 四川 绵阳 621000;
2. 重庆大学计算机学院, 重庆 400044)

摘要:为最小化无人机集群任务分配中任务的完成总时间和总航程, 提出一种基于 Actor-Critic 算法的优化方法。利用 Actor-Critic 算法中的 Actor 网络, 根据当前状态生成任务分配策略, 并用 Critic 网络评估 Actor 网络生成的策略价值。采用多阶时序差分误差, 结合多个时间步的奖励来更新策略, 以提高学习效率并减少延迟奖励。在多种任务场景下, 通过仿真实验进行对比。仿真结果表明: 该方法能够显著减少任务完成时间和航行距离, 验证了在任务分配问题上的有效性。

关键词: 无人机集群; 任务分配; 强化学习; 演员评论家算法

中图分类号: V279 **文献标志码:** A

UAV Swarm Task Allocation Based on Actor-Critic Algorithm

Su Rui¹, Gong Jun¹, Zhang Hongyu²

(1. Department of Special Computer, Automation Research Institute Co., Ltd. of
China South Industries Group Corporation, Mianyang 621000, China;
2. College of Computer Science, Chongqing University, Chongqing 400044, China)

Abstract: An optimization method based on the Actor-Critic algorithm is proposed to minimize the total task completion time and total flight distance in drone swarm task allocation. The Actor network in the Actor-Critic algorithm generates task allocation strategies based on the current state, while the Critic network evaluates the value of the strategies generated by the Actor network. By employing multi-step temporal difference errors and combining rewards from multiple time steps to update the strategy, the method improves learning efficiency and reduces delayed rewards. Comparative simulations are conducted across various task scenarios. The simulation results show that the proposed method significantly reduces task completion time and flight distance, validating its effectiveness in task allocation problems.

Keywords: UAV swarm; task allocation; reinforcement learning; actor-critic algorithm

0 引言

随着时代和科技的发展, 无人机 (unmanned aerial vehicle, UAV) 已成为各国在国际战场不可或缺的空中力量。无人机相较于有人机, 不仅体积较小便于携带隐藏, 而且还可以到达有人机和战斗人员无法到达的危险、狭窄地区, 同时因为其成本低可以大量投放到战场中。在实际战场环境中, 无人机可以执行侦察、搜索、追踪和打击等军事任务。由多架无人机组成的无人机集群 (unmanned aerial vehicle swarm, UAVS), 能通过协调和协作完成特定任务。与单个无人机相比, 无人机集群在战术灵活性、任务效率和抗干扰能力等方面具备显著优势, 在侦察和监视方面提供更大的覆盖面积区域, 实时收集情报, 发现目标时能够提供更加强大的火力, 提高打击效果。随着无人机数量增加, 任务变得更加复杂, 如何组织无人机集群执行任务变成了重要的一环, 成为无人机集群研究的热点。无人机

集群任务分配主要分为任务建模和模型求解, 本质上是求得一目标函数在约束下的最优解问题。

对于无人机集群, 需要确定集群的架构, 即如何把每架无人机组织起来。对于不同的架构有着不同的模型和方法, 最终也会产生不同的策略决策和执行效果。无人机集群架构主要分为集中式、分布式和混合式。

集中式是把其中一架无人机设置为头节点, 作为数据传输枢纽和指令下发中心, 其他无人机的数据都会流经此节点, 并根据数据做出决策下发指令到其他无人机。集中式任务分配模型有混合整数线性规划模型^[1]、车辆路径问题^[2]、多旅行商问题^[3]、多选择背包问题^[4]、动态网络流优化模型^[5]等。建立模型之后需要对模型进行求解, 求解方法主要分为最优化方法和启发式方法。常见的最优化方法有矩阵作业法^[6]、分支界定法、约束规划法^[7]、图论法等; 常见的启发式方法有列表算法^[8]、聚类算

收稿日期: 2024-08-11; 修回日期: 2024-09-25

第一作者: 苏瑞 (1997—), 男, 四川人, 硕士。

法^[9]和模拟退火算法等。文献[10]将狼群算法和模拟退火算法混合，有效缓解了无人机集群任务分配中搜索时全局性与收敛速度相矛盾的问题。文献[11]为了使得固定翼无人机集群迅速对环境做出反馈和决策，提出一种快速集群任务规划算法，将聚类算法和化学反应模型相结合。文献[12]基于 CBBA 算法，面对环境资源异构的供需问题，提出了改进的 CBBA 算法。文献[13]的方法适用于集群任务场景拥有较为复杂的耦合关系，提出基于交叉熵的分层任务规划模型，提高了规划效率。文献[14]对于无人机集群内部，组织集群进行研究，结合 PSO 算法和网络拓扑结构来解决任务分配问题。分布式架构则没有等级划分，每架无人机都独立执行计算和决策任务，但各个无人机也可以相互传输数据并且联合执行任务。分布式任务分配模型有多 Agent 理论、类市场机制和分布式约束^[15]等，常见的求解方法有贝叶斯法、合同网法^[16]和分布式马尔可夫法^[17]等。

文献[18]基于多个智能体在有限图上移动时的到达时间最小化问题模型，设计一种分布式马尔可夫链，用于多智能体问题。文献[19]开发了一种分布式拍卖算法，并引入联盟竞争均衡机制，来解决多机器人联盟执行任务的场景。文献[20]提出一种分布式鲁棒拍卖算法，在拍卖过程中引入任务奖励反馈机制，有效地降低了任务分配系统的成本，并提高了任务分配应对复杂环境的能力。文献[21]为了适应任务动态变化的复杂情况，提出一种在线任务再分配算法，将合同网法和空位链结合起来，提高了无人潜艇的任务成功率。

集中式依赖单一控制节点，易出现单点故障，同时中心节点要频繁通信和计算，存在资源瓶颈，分布式缺乏全局协调，可能导致任务冲突，各节点协调和通信开销大，鲁棒性差。为解决这些问题，结合两者优点的混合式可能会成为未来技术发展的实用化体系结构。混合式既可以中心进行控制和管理，各个节点也可以自治执行任务。由于其架构的特殊性，为了使得混合式整个集群的持续优化，针对不同的任务目标来优化策略，强化学习和群体智能等算法就可以有效解决此类问题^[22]。

1 问题建模

假定有 S 架无人机，其集合为 $U=\{U_1, U_2, \dots, U_S\}$ ，目标总数是 N ，其集合为 $G=\{G_1, G_2, \dots, G_N\}$ ，每架无人机为同构无人机，可执行所有类别的任务，

无人机要对目标需进行侦察、打击、评估 3 种任务，同一目标的 3 种任务可以由不同无人机执行。对于同一个目标，无人机要先对其执行观测任务，然后对其执行打击任务，最后才能够执行打击结果评估任务，因此，对同一个目标上的 3 种任务需满足如下时序约束：

$$T_{\text{Observe}} < T_{\text{Attack}} < T_{\text{Evaluate}} \quad (1)$$

进行打击任务需要消耗弹药，每架无人机弹药数有限，弹药消耗完毕则不能完成打击任务，则存在以下约束：

$$M_{\text{rest}} \geq M_{\text{launch}} \quad (2)$$

该类问题通常选取飞行总距离或飞行总时间作为策略好坏的重要评判标准。笔者将总时间与总航程之和的相反数作为优化目标，设置为目标函数，这样就可以最大化目标函数，从而求得和最小，同时设置权重来平衡二者的相对重要性：

$$J = -(\lambda_1 \cdot T_{\text{total}} + \lambda_2 \cdot D_{\text{total}}) \quad (3)$$

2 基于多阶 TD 误差的 Actor-Critic 算法

Actor-Critic 方法是一种强化学习算法，它结合了策略学习和价值学习，利用 Actor 网络和 Critic 网络来优化智能体在环境中的行为。其主要目标是通过平衡这 2 部分来提升学习的效率与稳定性，使得智能体在环境中有更好的表现。Actor 网络负责选择策略，它根据当前状态生成一个策略，并通过这个策略决定智能体在给定状态下应该采取什么动作。Critic 网络负责评估 Actor 选择的动作，它通过估计状态动作价值函数来衡量某个状态的优劣，为 Actor 提供反馈，指导 Actor 如何改进策略^[23]。算法框架如图 1 所示。




图 1 Actor-Critic 框架

Actor-Critic 算法的核心思想是通过同时训练这 2 个网络来优化策略。算法的具体流程可以分为以下步骤：

- 1) 初始化：初始化 Actor 网络和 Critic 网络。Actor 负责输出一个动作的概率分布，而 Critic 则负责输出某个状态-动作的价值估计。
- 2) 交互与回报：在每一个时间步，智能体根据当前状态 s_t 通过 Actor 选择一个动作 a_t ，执行动作并与环境交互得到下一个状态 s_{t+1} 和奖励 r_t 。

3) Critic 评估: Critic 使用其估计的价值函数 $q(s_t, a_t)$ 来评估当前状态动作和下一状态动作。然后, Critic 计算 TD 误差(时序差分误差), 这反映了实际奖励与估计价值之间的差距:

$$\delta_t = r_t + \gamma \cdot q_{t+1} - q_t \quad (4)$$

式中 γ 是折扣因子, 用来权衡未来奖励的重要性。

4) Critic 更新: Critic 通过最小化 TD 误差来更新其价值函数的参数。常见的更新方法是通过梯度下降进行:

$$\omega_{t+1} \leftarrow \omega_t - \alpha \cdot \delta_t \cdot \nabla q(s_t, a_t, \omega_t) \quad (5)$$

式中: α 为学习率; $\nabla q(s_t, a_t, \omega_t)$ 为价值的梯度。

5) Actor 更新: Actor 使用 Critic 提供的反馈来更新其策略。通过使用策略梯度方法, Actor 会根据 Critic 的反馈来调整策略, 使选择更好的动作的概率增加。具体的策略更新通常通过如下公式来实现:

$$\theta_{t+1} \leftarrow \theta_t + \beta \cdot \delta_t \cdot \nabla \log \pi(a_t | s_t, \theta_t) \quad (6)$$

式中: β 为学习率; $\nabla \log \pi(a_t | s_t, \theta_t)$ 为策略的梯度。

在无人机任务分配问题中, 任务之间存在明显的时序关系, 若使用原本的 TD 误差计算方式这些任务之间的奖励并不会立即显现, 即当前的奖励信号无法充分反映后续奖励的影响, 尤其是当任务有多个步骤时, 未来任务的奖励对当前决策的影响无法很好地传递。多阶 TD 误差可以有效缓解这个问题, 因为它通过考虑未来多个时间步的奖励和状态价值, 能够捕捉更远期奖励信息。通过将 n -step 奖励加权累积到当前决策中, 算法可以更好地理解长期决策的影响, 使得无人机的任务分配和执行更加精确。同时通过多阶更新, 算法在每次更新时已经考虑了多个时间步的奖励信息, 可以加速策略的优化过程, 避免了过于依赖单步奖励所带来的学习效率低下的问题。

对于 n -step TD 误差的更新公式如下:

$$\delta_t^{(n)} = \sum_{k=0}^{n-1} \gamma^k r_{t+k} + \gamma^n q_{t+n} - q_t \quad (7)$$

式中: r_{t+k} 为时间步 $t+k$ 的奖励; γ 为折扣因子, 控制每个时间步的奖励影响。

基于多阶 TD 误差的 Actor-Critic 算法流程:

- 1) 初始化参数 γ, β, α ;
- 2) for $t=1:T$;
- 3) 根据环境状态 s_t 随机选择动作 $a_t \sim \pi(a_t | s_t, \theta_t)$;
- 4) 执行动作 a_t 后得到新状态 s_{t+1} 和环境奖励 r_t ;
- 5) 评估价值网络 $q_t = q(s_t, a_t, \omega_t)$;
- 6) for $k=1:n$;

7) 根据新状态 s_{t+k} 随机选择动作 $a_{t+k} \sim \pi(a_{t+k} | s_{t+k}, \theta_t)$;

8) 模拟执行动作 a_{t+k} ;

9) 评估价值网络 $q_{t+k} = q(s_{t+k}, a_{t+k}, \omega_t)$;

10) 计算环境奖励之和 $r_{\text{sum}+} = \gamma^{k-1} \cdot r_{t+k-1}$;

11) 产生新状态 s_{t+k+1} ;

12) end;

13) 计算 n 阶 TD 误差 $\delta_t^{(n)} = r_{\text{sum}+} + \gamma^n q_{t+n} - q_t$;

14) 更新价值网络 $\omega_{t+1} \leftarrow \omega_t - \alpha \cdot \delta_t^{(n)} \cdot \nabla q(s_t, a_t, \omega_t)$;

15) 更新策略网络 $\theta_{t+1} \leftarrow \theta_t + \beta \cdot \delta_t^{(n)} \cdot \nabla \log \pi(a_t | s_t, \theta_t)$;

16) end;

3 实验与结果分析

实验环境: 通过 Python 编程并在 Pytorch 框架下实现实验场景, 软件环境选用 Windows 11 操作系统并搭载 Visual Studio Code 1.93.1 编译器, 硬件环境 CPU 为 Intel i5-13500, 内存 16 GB, 支撑算法的计算工作。

实验场景: 在大小为 $10 \text{ km} \times 10 \text{ km}$ 的 2 维区域进行任务分配, 分为 3 种规模的无人机-目标组合, 组合 1 有 10 架无人机和 7 个目标, 如图 2 所示; 组合 2 有 12 架无人机和 12 个目标, 如图 3 所示; 组合 3 有 14 架无人机和 17 个目标, 如图 4 所示。




图 2 10 架无人机 7 个目标位置分布




图 3 12 架无人机 12 个目标位置分布




图 4 14 架无人机 17 个目标位置分布

无人机对目标进行侦察、打击、评估 3 种任务，3 种任务存在时序关系，执行侦察任务耗时 3 min，执行打击任务耗时 1 min 并消耗 1 枚弹药，初始都有 2 枚弹药，执行评估任务耗时 4 min，无人机匀速飞行速度为 20 km/h，目标函数 2 个权重分别设置为 0.7 和 0.3，表示更关注总时间。

Actor 网络和 Critic 网络，2 个神经网络均为 3 层结构，输入层相同，均为动作空间和状态空间的大小；中间隐藏层也相同，都使用 ReLU 激活函数。不同的是 Actor 网络的输出层，输出动作的概率分布，大小等于动作空间大小，选用 Softmax 激活函数；而 Critic 网络输出层是价值，为标量没有激活函数。针对于任务场景中的 3 种时序性任务，把 n 阶 TD 中的 n 设置为 3。算法中的学习率，因为 Critic 网络的目标是最小化值函数的误差，所以 Critic 更新通常比 Actor 更新更频繁和迅速，所以需要相对较大的学习率来加速值函数的学习，那么把 α 初始化为 0.001，改变 β 的值来观察算法表现，分别设置 4 组值 $\alpha=0.001, \beta=0.001$ ； $\alpha=0.001, \beta=0.005$ ； $\alpha=0.001, \beta=0.01$ ； $\alpha=0.001, \beta=0.015$ ，迭代 400 次来观察平均奖励，并把平均奖励调整为一个正小数范围便于观察，如图 5 所示，当 $\beta=0.01$ 时平均奖励最高，再增大 β 值平均奖励就开始下降，所以设置 $\alpha=0.001, \beta=0.01$ ，折扣率 γ 初始化为 0.9。




图 5 不同学习率的算法表现

将 1 阶 TD 误差的 Actor-Critic 算法和遗传算法作为对照组，迭代 300 次，来对比改进算法的表现，如图 6—8 所示。




图 6 组合 1 中各算法的表现




图 7 组合 2 中各算法的表现




图 8 组合 3 中各算法的表现

通过在各种规模的无人机-目标组合中运行 3 种算法，观察到在组合 1 中，无人机-目标组合规模较小，3 种算法的表现差距不大，尤其是 1 阶 TD 误差和 3 阶 TD 误差的 Actor-Critic 算法，收敛速度大体一致，最终解也近乎相同，相比之下遗传算法收敛速度更慢，并且最终解劣于 Actor-Critic 算法，波动也较大。将总代价看作正数，3 阶 TD 误差的 Actor-Critic 算法相比 1 阶和遗传算法降低了 2.65% 和 15.38%。在组合 2 中，任务规模扩大，3 种算法差距拉大，3 阶 TD 误差的 Actor-Critic 算法表现最优，略优于 1 阶 TD 误差的 Actor-Critic 算法 4.65%，优于遗传算法 17.43%。在组合 3 中，任务规模扩大到 14 架无人机和 17 个目标，输入空间大大增加，3 阶 TD 误差和 1 阶 TD 误差的 Actor-Critic 算法差距进一步加大，到了 6.87%，相比遗传算法总代价降

低了 22.11%；但随着任务规模扩大，3 种算法的收敛速度都有所减缓，波动也在增加。

随着无人机和目标数量的增加，需要探索的状态和动作组合变得更加复杂，状态空间和动作空间迅速扩大，遗传算法由于基于种群的随机搜索机制、对历史信息的缺乏利用以及对复杂性处理的局限，常常较难高效找到优质解，而 Actor-Critic 算法能够通过策略梯度方法与价值函数的结合，动态更新逐步优化策略，在适当的超参数设置下能够更快速、更有效地找到高质量解。

4 结束语

笔者通过仿真实验结果的对比分析得出：多阶 TD 误差的 Actor-Critic 算法在处理时序性任务时，具有一定优势。与基础的 Actor-Critic 算法和遗传算法相比，改进后的算法能够有效应对无人机集群复杂任务环境，捕捉时序性任务之间的关联，获取多步奖励，从而加快收敛速度和增加算法稳定性，显著减少无人机集群任务完成的总时间和总航程。

对于动态的任务场景，以及实际战场环境中更多的约束条件，更大规模的任务场景，该算法也会面临收敛速度减缓，局部最优解等问题。未来的研究可以进一步增加算法评价指标，设置更为合理的目标函数和选择适当的集群架构来组织无人机，从而提升无人机集群在实际应用中的性能与效率。

参考文献：

[1] 蒋世文. 动态环境下多无人机任务规划算法研究及仿真[D]. 成都: 电子科技大学, 2021.

[2] 梁峥峥. 风影响下的无人机任务分配问题研究[D]. 合肥: 合肥工业大学, 2018.

[3] ODILI B J, NORAZIAH A, SIDEK M R. Swarm intelligence algorithms' solutions to the travelling salesman's problem[J]. IOP Conference Series Materials Science and Engineering, 2020, 769(1): 012030.

[4] SEIL A, JIN K H. Simultaneous task assignment and path planning using mixed-integer linear programming and potential field method[C]. 2013 13th International Conference on Control, Automation and Systems. South Korea: IEEE, 2013.

[5] ZHU D Q, HUANG H, YANG S X. Dynamic task assignment and path planning of multi-AUV system based on an improved self-organizing map and velocity synthesis method in three-dimensional underwater workspace[J]. IEEE Transactions on Cybernetics, 2013, 43(2): 504-514.

[6] 李大卫, 陆立娟, 王莉. 基于矩阵运算的配送中心动态选址问题研究[C]. 第 26 届中国控制会议. 张家

界, 2007.

[7] 黄映, 周科峰, 叶婷. 基于机会约束规划法和非支配排序差分进化算法的含风电多目标输电网规划[J]. 电气应用, 2016, 35(6): 42-46.

[8] LEVCHUK G M, LEVCHUK Y N, LUO J, et al. Normative Design of Organizations—Part I: Mission Planning[J]. IEEE systems, man, and cybernetics, 2002, 32(3): 346-359.

[9] HOANG P D, RABAEY J M. Scheduling of DSP programs onto multiprocessors for maximum throughput[J]. IEEE Transactions on Signal Processing, 1993, 41(6): 2225-2235.

[10] 袁德平. 基于混合群智能算法的无人机集群任务分配[J]. 中国电子科学研究院学报, 2023, 18(6): 531-538, 553.

[11] 吴昌伟, 谢红薇. 针对固定翼无人机集群的快速任务规划算法[J]. 计算机工程与设计, 2023, 44(10): 2979-2987.

[12] ZHAO X, WEI Z, ZHAO B, et al. Task allocation of multiple UAVs under heterogeneous resource types[J]. Journal of National University of Defense Technology, 2023, 45(4): 232-242.

[13] WANG K H, ZHANG X, QIAO X Y, et al. Adjustable Fully Adaptive Cross Entropy Algorithms for Task Assignment of Multi-UAVs[J]. Drones, 2023, 7: 204.

[14] KIM D Y, LEE J W. Joint Mission Assignment and Topology Management in the Mission Critical FANET[J]. IEEE Internet of Things Journal, 2020, 7(3): 2368-2385.

[15] JIN Y N, WU Y X, FAN N J. Research on Distributed Cooperative Control of Swarm UAVs for Persistent Coverage[C]. 第三十三届中国控制会议. 南京, 2014.

[16] REID G S. The Contract Net Protocol: High-Level Communication and Control in a Distributed Problem Solver[J]. IEEE Transactions on Computers, 1980, C29(12): 1104-1113.

[17] HAKSAR R N, SCHWAGER M. Distributed Deep Reinforcement Learning for Fighting Forest Fires with a Network of Aerial Robots[C]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid, Spain: IEEE, 2018.

[18] DÍAZ-GARCÍA G, BULLO F, MARDEN J R. Distributed Markov Chain-based Strategies for Multi-Agent Robotic Surveillance[J]. IEEE Control Systems Letters, 2023, 7(2): 2527-2532.

[19] DENG R L, YAN R, HUANG P N, et al. A Distributed Auction Algorithm for Task Assignment With Robot Coalitions[J]. IEEE Transactions on Robotics, 2024, 40(4): 4787-4804.

[20] 李鑫滨, 郭力争, 韩松. 一种分布式异构多 AUV 任务分配鲁棒拍卖算法[J]. 北京航空航天大学学报, 2022, 48(5): 736-746.

[21] ZHUANG J Y, LONG L Y, ZHANG L, et al. Research on task allocation for multi-type task of unmanned surface

vehicles[J]. Ocean Engineering, 2024, 308: 118321.

[22] LI T X, ZHU K, LUONG N C, et al. Applications of Multi-agent Reinforcement Learning in Future Internet: A Com-prehensive Survey[J]. IEEE Communications

(上接第 65 页)

[25] JIN L, HUANG Z G, CHEN L M, et al. Modified single-output Chebyshev-polynomial feed for ward neural network aided with subset method for classification of breast cancer[J]. Neuro computing, 2019, 350: 128-135.

[26] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Comput, 1997, 9: 1735-1780.

[27] KRATZERT F, KLOTZ D, BRENNER C, et al. Rainfall - runoff modelling using long short-term memory (LSTM)networks. Hydrol[J]. Earth Syst Sci, 2018, 22: 6005-6022.

[28] XIANG Z R, YAN J, DEMIR I. A rainfall-runoff model with LSTM-based sequence-to-sequence learning[J]. Water Resour Res, 2020, 56: 025326.

[29] KANG J L, WANG H M, YUAN F, et al. Prediction of Precipitation Based on Recurrent Neural Networks in Jing de zhen, Jiang xi Province, China[J]. Atmosphere 2020, 11: 246.

[30] ZHOU Y L, LI Y, JIN J L, et al. Stepwise Identification of Influencing Factors and Prediction of Typhoon Precipitation in Anhui Province Based on the Back Propagation Neural Network Model[J]. Water, 2021, 13: 550.

[31] ZAHRAEI A, HSU K L, OROOSHIAN S, et al. Quantitative precipitation nowcasting: A Lagrangian pixel-based approach[J]. Atmos Res, 2012, 118: 418-434.

[32] BOWLER N E, PIERCE C E, SEED A. Development of a precipitation nowcasting algorithm based upon optical flow techniques[J]. J Hydrol, 2004, 288: 74-91.

Surveys and Tutorials, 2022, 24(2): 1240-1279.

[23] BHATNAGAR S, SUTTON S R, GHAVAMZADEH M, et al. Naturalactor-critic algorithms[J]. Automatica, 2009, 45(11): 2471-2482.

[33] PHAM B T, LE L M, LE T T, et al. Prakash I Development of advanced artificial intelligence models for daily rainfall prediction[J]. Atmos Res, 2020, 237: 104845.

[34] BANADKOOKI F B, EHTERAM M, AHMED A N, et al. Precipitation forecasting using multilayer neural network and support vector machine optimization based on flow regime algorithm taking into account uncertainties of soft computing models[J]. Sustainability, 2019, 11: 6681.

[35] WANG J N, ZHANG L F, GUAN J P, et al. Evaluation of combined satellite and radar data assimilation with POD-4DEnVar methodon rainfall forecast[J]. Appl. Sci, 2020, 10: 5493.

[36] 杨少才, 徐漠北, 雷凯超. SF6 气体带电检测方法研究及分析[C]//2022 年电力行业技术监督工作交流会暨专业技术论坛论文集. 中国电力协会, 2022: 484-489.

[37] 吴勇, 申红志. 苏通 GIL 管廊工程应急抢修中 SF₆ 气体快速回收处理技术[J]. 自动化技术与应用, 2022, 41(9): 180-183.

[38] 钱渊泉, 沈谢林, 彭炜文, 等. 高压断路器中 SF₆ 气体环境监测系统设计[J]. 仪表技术, 2022(4): 70-72.

[39] 巫吉祥, 陈功勋, 毛乾宏. 苏通 GIL 管廊工程应急抢修 SF₆ 气体自适应充注系统[J]. 自动化技术与应用, 2022, 41(7): 114-117.

[40] 郭帆, 贾伟, 谢霖燊, 等. 百 kV/cm 场强下 SF₆ 气体开关纳秒脉冲击穿场强和时延经验公式[J]. 强激光与粒子束, 2022, 34(7): 51-56.