第 52 卷 第 4 期：1653-1666 高电压技术 Vol.52, No.4: 1653-1666
2026 年 4 月 30 日 High Voltage Engineering April 30, 2026
DOI: 10.13336/j.1003-6520.hve.20251170

融合台风灾害场景智能生成的移动应急电源两阶段优化预置方法

陈 春[1]，李佳顺[1]，曹一家[1]，安 义[2]，李 勇[3]
（1.电网防灾减灾全国重点实验室(长沙理工大学)，长沙 410114；2. 国网江西省电力有限公司电力科学研究院，南昌 330096; 3. 湖南大学电气与信息工程学院，长沙 410082）

摘 要：台风灾害严重威胁配用电网络与交通网络安全，预先优化移动应急电源(mobile emergency power supply，MEPS)配置是提升配电网韧性的关键措施，有助于提高灾后应急电源调度效率与负荷恢复速度。为此，提出基于条件式 Wasserstein 生成对抗网络(conditional Wasserstein generative adversarial network with gradient penalty，cWGAN-GP)的灾害场景生成方法，构建两阶段随机优化模型以确定预定区域移动应急电源最优位置。利用 cWGAN-GP 模拟气象因素与线路故障间非线性关系，生成多样化故障场景，并通过层次聚类法，提取典型故障场景；考虑灾后恢复过程，建立融合电力-交通网络的两阶段随机混合整数规划模型，采用逐步对冲算法(progressive hedging algorithm ，PHA)求解各中转站 MEPS 的优化预置方案。利用 IEEE33 节点配电网与 44 节点交通网，构建耦合系统分析算例，结果表明所提优化方法有效提升灾后 MEPS 响应速度，显著缩短负荷恢复供电时间。
关键词：极端灾害；电力-交通网；条件式 Wasserstein 生成对抗网络；故障场景生成；移动电源预置

Two-stage Optimization Method for Prepositioning Mobile Emergency Power Supplies Integrated with Intelligent Generation of Typhoon Disaster Scenarios

CHEN Chun[1], LI Jiashun[1], CAO Yijia[1], AN Yi[2], LI Yong[3]
(1. State Key Laboratory of Disaster Prevention & Reduction for Power Grid(Changsha University of Science & Technology), Changsha 410114, China;
2. Electric Power Research Institute, State Grid Jiangxi Electric Power Co., Ltd., Nanchang 330096, China;
3. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract：Typhoon disasters pose a severe threat to the security of power distribution networks and transportation networks. Pre-positioning mobile emergency power supplies (MEPS) in an optimized manner is a key measure to enhance distribution network resilience, contributing to improved efficiency of post-disaster emergency power dispatch and faster load restoration. To this end, a disaster scenario generation method based on conditional Wasserstein generative adversarial network with gradient penalty (cWGAN-GP) is proposed, and a two-stage stochastic optimization model is constructed to determine the optimal MEPS locations within predetermined areas. The cWGAN-GP is employed to capture the nonlinear relationship between meteorological factors and line failures, thereby generating diverse failure scenarios, from which representative scenarios are extracted using hierarchical clustering. After considering the post-disaster restoration process, a two-stage stochastic mixed-integer programming model integrating power and transportation networks is formulated, and the progressive hedging algorithm (PHA) is applied to solve the optimal MEPS pre-positioning plan for each transit station. A coupled system comprising the IEEE 33-bus distribution network and a 44-node transportation network is used for case studies. The results demonstrate that the proposed optimization method can be adopted to significantly improve MEPS response speed and substantially reduce theload restoration time after disasters.
Key words：extreme disasters; power-transportation network; conditional Wasserstein generative adversarial network with gradient penalty; fault scenario generation; mobile power prepositioning

基金资助项目：国家自然科学基金(面上项目)(52577081)；湖南省自然科学基金优秀青年项目(2023JJ20039)。
Project supported by National Natural Science Foundation of China (General Program) (52577081), Outstanding Youth Project of the Hunan Provincial Natural Science Foundation (2023JJ20039).

0 引言

近年来，台风等极端气象灾害频发，对区域基础设施构成严重威胁。2024 年，西北太平洋和南海共生成 26 个台风，其中 9 个登陆我国沿海，导致多地电力系统严重受损。其中，台风“摩羯”肆虐海南，海南全省 35 kW 及以上变电站停运 79 座，10 kW 及以上线路跳闸 836 条，受影响用户达 83 万户，占全省用户的 1/3[1-3]。台风灾害常造成配电网故障与道路中断并发，严重制约供电恢复效率。移动应急电源(mobile emergency power supply, MEPS)具备快速部署、灵活接入等优势，可为关键负荷提供临时电力支撑，是灾后应急供电重要保障手段[4]。然而，由于 MEPS 供电能力的差异性，其灾前预置位置对灾后调度效率具有重要影响[5-7]。因此，为提升灾后供电恢复效率，亟需构建合理且具有代表性的配电网灾害场景，在灾前科学规划不同供电能力 MEPS 的预置位置，增强预置方案对多种灾害冲击的适应性与鲁棒性。

在灾害场景生成方面，已有研究多采用物理建模与统计抽样方法。文献[8-9]通过地理信息系统(geographic information system，GIS)气象数据构建台风路径与故障率矩阵，结合蒙特卡罗模拟生成典型灾害场景，并引入设备脆弱性和负荷不确定性，利用 K-means 聚类压缩场景集，提高场景代表性与优化效率。尽管此类方法具有一定物理可解释性，但难以准确刻画各类灾害变量之间复杂的非线性耦合关系，且建模过程对人工经验和先验规则依赖较强。文献[10-11]借助生成对抗网络及其条件扩展模型，分别提出了适用于风电和风光联合出力的场景生成方法，验证了该类模型在建模复杂概率分布和学习数据结构方面的潜力。

在灾前资源预置优化方面，文献[12]提出将移动应急发电机视为可调度电源，通过场景驱动的随机优化模型，实现关键负荷的优先供电能力配置。文献[13]综合考虑配电网与交通网络的空间耦合特性，构建了基于鲁棒优化的资源预部署模型，以提高系统的抗灾能力。文献[14]基于多源资源协同理念，提出以加权失电量最小为目标的应急仓库选址方法。文献[15-16]则围绕灾害风险区域与关键节点的空间特性，通过图论方法或混合整数规划优化资源配置位置，有效提升了预部署方案对潜在断电区域的覆盖程度。文献[17]将应急电源作为灾后配电网的补充恢复，但其没有考虑灾前预置而是将应急电源停在同一节点处等待调度。文献[18]建立两阶段鲁棒优化模型来确定移动储能的位置，但其考虑的是光伏极端出力场景，缺乏场景多样性。

针对现有研究的不足，本文聚焦于台风灾害下配电网的故障场景生成与 MEPS 的灾前预置问题，提出一种融合场景生成与资源优化配置的方法。一方面，近年来，大量研究表明人工智能技术在智能配电网的故障诊断、场景生成、与决策优化等方面具有显著优势，为复杂灾害场景的建模与预测提供了新的思路[19-22]。基于此，本文基于条件 Wasserstein 生成对抗网络(conditional Wasserstein generative adversarial network with gradient penalty，cWGAN-GP)构建灾害场景生成模型，刻画台风气象因素与配电网故障之间的非线性关系，生成多种配电网故障灾害场景；另一方面，考虑灾后恢复并结合场景生成结果构建两阶段随机优化模型，协同优化灾前移动电源在中转站的预置位置与灾后供电路径，提升资源配置的合理性与系统恢复的效率。

1 电力-交通网耦合框架

配电网与交通网的耦合框架如图 1 所示。上层为配电网，部分线路受台风影响发生断线故障，需要 MEPS 支援以维持负荷供电；下层为交通网，部分道路因台风灾害造成道路阻断不通。交通网络中有多个中转站，为实现高效的灾害应急响应，生成灾后典型灾害场景，考虑各场景下灾后恢复过程，灾前预先在各中转站部署好不同供电能力的 MEPS，灾后 MEPS 从中转站出发，沿交通路径前往配电网络中失电孤岛区域进行支援供电。

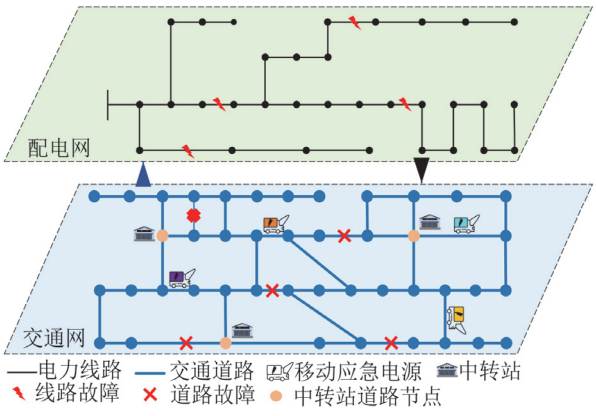


图 1 电力-交通网耦合框架

Fig.1 Framework of coupled power and transportation network

相较于配电网络，交通道路网络具有更高的拓扑精细度、节点密度和路径丰富度。本文在分析电力–交通网络的协同恢复过程中，对交通网络进行适度简化，保留关键节点与路径，使其在空间结构上更好地匹配配电网的拓扑特征，从而增强电网节点与交通网络节点之间的空间关联性。考虑到地下电缆往往沿道路铺设，本文在网络架构中使电力网络的关键节点与交通路径保持一定的空间重叠，从而更真实地反映了电缆走廊与交通网络的耦合关系。基于这种空间分布特性，可以进一步发现：(1)交通路径能够覆盖配电网系统的全部节点，保障应急电源具备全局可达性；(2)任意电网节点均可在交通网络中找到相应的空间位置并实现与交通节点的重叠；(3)交通网络为 MEPS 接入某一电力节点提供多条可行路径，增强应急调度的灵活性。

2　基于 cWGAN-GP 的配电网故障场景生成模型

2.1　条件式 Wasserstein 生成对抗网络

cWGAN-GP 的基本结构如图 2 所示。cWGAN-GP 通过将气象因素作为条件输入，在保留 WGAN-GP 本身极佳训练稳定性和梯度惩罚机制的同时，引入随机噪声采样，使模型能够针对同一组未来气象因素生成多种合理的故障场景，充分反映灾害的不确定性；每个故障场景由 32 条线路的运行状态描述，每条线路状态用二值变量编码，其中 0 表示正常运行，1 表示发生故障。基于 Wasserstein 距离的损失与梯度惩罚有效避免了模式崩溃和梯度消失，保证深层网络的可靠收敛。

条件向量 $\boldsymbol{c}$ 表示影响故障发生的关键气象因素，包括台风登陆位置、移动方向角、移动速度及初始中心气压差。每组气象因素对应一个历史故障场景，气象因素不仅作为生成器的输入，同时也作为判别器的输入，以便模型能够学习气象因素与故障之间的联合分布，从而提升生成故障场景的准确性和针对性。生成分布 P_{g} 与历史分布 P_{data} 之间的条件 Wasserstein 距离可表示为：

$$W(P_{\mathrm{data}},P_{\mathrm{g}})=\sup_{\theta}E_{(\boldsymbol{x},\boldsymbol{c})\sim P_{\mathrm{data}}}(D(\boldsymbol{x},\boldsymbol{c}))-E_{(\boldsymbol{z},\boldsymbol{c})\sim P_{\mathrm{z}},P_{\mathrm{c}}}(D(\boldsymbol{G}(\boldsymbol{z},\boldsymbol{c}),\boldsymbol{c})) \tag{1}$$

式中：$\boldsymbol{c}$ 为气象条件；$\boldsymbol{z}$ 为随机噪声变量，服从噪声分布 P_{z}；$\boldsymbol{x}$ 为历史故障场景；P_{data} 为真实样本分布；P_{c} 为气象条件分布；$\boldsymbol{G}(\boldsymbol{z},\boldsymbol{c})$ 表示在条件 $\boldsymbol{c}$ 下生成器输出的故障场景；$D(\boldsymbol{x},\boldsymbol{c})$ 和 $D(\boldsymbol{G}(\boldsymbol{z},\boldsymbol{c}),\boldsymbol{c})$ 分别代表判别器对历史故障场景和生成故障场景的评分；E 表示数学期望；~ 表示服从相应分布；$\sup_{\theta}$ 表示对判别器参数 θ 取上确界。通过引入条件向量 $\boldsymbol{c}$，判别器能够在场景对比的基础上学习条件依赖下的场景分布差异，从而提升故障场景生成的针对性和判别能力。

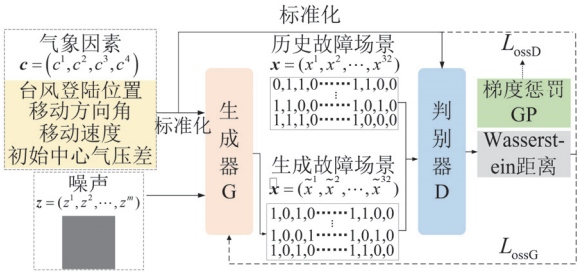


图 2　cWGAN-GP 基本结构

Fig.2　Basic structure of cWGAN-GP

为进一步保证模型满足 1-Lipschitz 连续性并提升训练稳定性，在 cWGAN-GP 中保留了 WGAN-GP 的梯度惩罚机制。具体地，在历史故障场景和生成故障场景之间进行线性插值，得到中间点 $\hat{\boldsymbol{x}}$，并对其梯度范数施加惩罚，梯度惩罚项定义如下：

$$G_{1\hat{\boldsymbol{x}},\boldsymbol{c}}=E_{\hat{\boldsymbol{x}}\sim P_{\hat{\boldsymbol{x}}}}((\|\nabla_{\hat{\boldsymbol{x}}}D(\hat{\boldsymbol{x}},\boldsymbol{c})\|_2-1)^2) \tag{2}$$

式中：$\hat{\boldsymbol{x}}=t\boldsymbol{x}+(1-t)\boldsymbol{G}(\boldsymbol{z},\boldsymbol{c}),t\sim \mathrm{U}[0,1]$，表示在历史场景 $\boldsymbol{x}$ 和生成场景之间按比例插值得到的随机中间点；t 为线性插值系数；$E_{\hat{\boldsymbol{x}}\sim P_{\hat{\boldsymbol{x}}}}(\cdot)$ 表示对随机中间点 $\hat{\boldsymbol{x}}$ 按其分布 $P_{\hat{\boldsymbol{x}}}$ 进行采样，并对括号内表达式求数学期望；$\nabla_{\hat{\boldsymbol{x}}}$ 表示判别器输出对 $\hat{\boldsymbol{x}}$ 的梯度运算符。引入该惩罚项后，判别器的整体损失函数可重写为：

$$L_{\mathrm{cWGAN\text{-}GP}}=E_{(\boldsymbol{z},\boldsymbol{c})\sim P_{\mathrm{z}},P_{\mathrm{c}}}(D(\boldsymbol{G}(\boldsymbol{z},\boldsymbol{c}),\boldsymbol{c}))-E_{(\boldsymbol{x},\boldsymbol{c})\sim P_{\mathrm{data}}}(D(\boldsymbol{x},\boldsymbol{c}))+\lambda\cdot G_{1\hat{\boldsymbol{x}},\boldsymbol{c}} \tag{3}$$

式中：λ 为梯度惩罚系数，用于控制正则项在整体损失函数中的权重；$E_{(\boldsymbol{z},\boldsymbol{c})\sim P_{\mathrm{z}},P_{\mathrm{c}}}(\cdot)$ 表示对随机噪声 $\boldsymbol{z}$ 和条件变量 $\boldsymbol{c}$ 分别从其对应分布中采样后，判别器对生成样本评分的数学期望。生成器则以最小化 $-E_{(\boldsymbol{z},\boldsymbol{c})\sim P_{\mathrm{z}},P_{\mathrm{c}}}(D(\boldsymbol{G}(\boldsymbol{z},\boldsymbol{c}),\boldsymbol{c}))$ 为目标，使其生成故障场景得分尽可能接近历史故障场景，从而实现生成结果向真实分布逼近。

每条样本由气象因素与线路故障场景拼接而成，将气象因素作为条件向量输入生成器，使模型能够自适应地学习气象变量与线路脆弱性之间的非线性映射关系。cWGAN-GP 在保留 WGAN-GP 稳

定收敛与梯度流畅优势的同时，加入噪声扰动以驱动多样性，从而生成具有更高真实性与分布保真度的灾害样本。在给定一组未来气象因素时，模型可多次采样输出不同故障场景，有效模拟灾害影响的不确定性，并为电网在极端天气下的风险评估与MEPS 的预先布置提供更加可靠和针对性的决策支撑。

2.2 典型场景提取

利用训练好的网络在给定气象因素下生成大量配电网故障场景。为了有效压缩大规模故障场景数据并保留其代表性特征，采用凝聚型层次聚类方法[23]对故障场景进行分组，并在每个聚类簇内提取典型场景。

2.2.1 样本聚类方法

针对二值化的故障场景矩阵，采用基于 Jaccard 距离的凝聚型层次聚类方法。Jaccard 距离能够有效度量故障场景间的相似性，重点关注线路故障状态的一致性而忽略大规模正常线路对结果的影响。聚类过程中采用平均链接准则，定义两个簇间的距离为簇内所有故障场景两两之间距离的平均值。

通过计算故障场景间的距离矩阵并逐步合并簇，形成完整的聚类树状图。然后依据设置的剪切阈值对树状图进行截断，将故障场景划分为若干个具有较高内部相似性、较低外部差异性的聚类簇。

2.2.2 提取典型场景

在完成故障场景的聚类后在每一聚类簇内提取典型场景。即在每个聚类簇内，计算每个故障场景与该簇内其他故障场景之间的距离总和，选取距离总和最小的故障场景作为该簇的典型场景。典型场景能够充分代表原始数据中各类故障模式，场景数量的显著减少为后续分析与建模奠定基础。

设第 j 个聚类簇包含场景集合 $C_j=\left\{\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_{n_j}\right\}$，则该簇的典型场景 $\boldsymbol{x}^*$ 定义为：

$$\boldsymbol{x}^*=\arg\min_{\boldsymbol{x}_i\in C_j}\sum_{\boldsymbol{x}_k\in C_j}d(\boldsymbol{x}_i,\boldsymbol{x}_k) \tag{4}$$

式中：$d(\boldsymbol{x}_i,\boldsymbol{x}_k)$ 表示故障场景 $\boldsymbol{x}_i$ 与 $\boldsymbol{x}_k$ 之间的 Jaccard 距离。$\arg\min$ 表示使目标函数取得最小值时对应的自变量，即在聚类簇 C_j 内选取与簇内其他故障场景距离总和最小的故障场景作为典型场景。

3 多种典型故障场景下的 MEPS 预置模型

本章提出了一种在多种典型场景下同时优化的 MEPS 预置方法。模型首先把每台 MEPS 在每个孤岛内能够恢复的加权负荷量以及其到达时间离线化为参数；接着，考虑 MEPS 在中转站的预布置决策，以及在各场景中指派至孤岛的调度决策，构建一体化的两阶段随机 0-1 混合整数规划模型；最后，采用逐步对冲算法(progressive hedging algorithm，PHA)在全部典型场景上并行求解，从而得到兼顾所有场景的综合最优 MEPS 预置方案。

3.1 离线化参数

在所有聚类簇内提取多个典型故障场景，场景集合为 Ω，对每个典型故障场景按照文献[8]中的方法赋予概率权重。在场景 ω 中，孤岛集合记为 $\mathcal{I}_\omega$，孤岛节点 n 的有功需求和权重系数分别为 $P_{n,\omega}$ 与 α_n。对于额定功率为 P_{gen} 的移动应急电源车 g 与孤岛 $i\in\mathcal{I}_\omega$，若孤岛总负荷 $\sum_{n\in i}P_{n,\omega}\le P_{\text{gen}}$，则整岛可由该 MEPS 供电。若超出则需在保持连通性的前提下，选取一个不超过 P_{gen} 且权重最大的子集合，为此将节点按 α_n 降序，结合深度-广度混合搜索[24]，在每次扩展节点前检查当前已选节点的总功率与待加入节点功率之和是否仍不超过功率上限 P_{gen}，搜索结束后即可得到 MEPS-孤岛-场景三维子集合 $F_{g,i,\omega}$。据此定义该 MEPS 在场景内能够恢复的加权负荷量表达式为：

$$L_{g,i,\omega}=\sum_{n\in F_{g,i,\omega}}\alpha_nP_{n,\omega} \tag{5}$$

枚举 $F_{g,i,\omega}$ 中孤岛的所有节点并采用一次化潮流模型评估线损，选择线损最小节点 $p^*(g,i,\omega)$ 作为 MEPS 的最优接入点[25]。由道路最短行驶时间矩阵 $\Delta\boldsymbol{t}(s,p)$，可得移动应急电源 g 预置在中转站 s 时驶达接入点 p 所需的最短行程时间为：

$$T_{g,i,s}=\Delta\boldsymbol{t}(s,p^*(g,i,\omega)) \tag{6}$$

由此可得到两组参数化结果 $L_{g,i,\omega}$ 与 $T_{g,i,s}$，二者将潮流计算、孤岛划分以及道路行驶时间等连续环节全部固化为离散系数，因此在随后的优化阶段不必再重复这些复杂运算，使主优化问题仅保留离散指派决策，计算规模大幅降低。

3.2 目标函数

典型灾后情形往往呈现出高度的不确定性，预置方案若仅针对单一故障场景进行优化，极易在其他场景下失效。为此，本研究以场景集 Ω 为概率空间，引入加权期望的概念，把多场景中的负荷恢复效益与行驶耗时统一纳入同一价值函数，并据此评价 MEPS 的整体预置优劣。由此建立的目标函数如下：

$$\max Z=\sum_{\omega=1}^{\Omega}\pi_{\omega}\sum_{g\in M}\sum_{i\in\mathcal{I}_{\omega}}\left(L_{g,i,\omega}-\beta\sum_{s\in S}T_{g,i,s}x_{g,s}\right)y_{g,i,\omega} \quad (7)$$

式中：决策变量 $x_{g,s}$ 为 0-1 量，表示移动应急电源 g 是否停放在中转站 s；$y_{g,i,\omega}$ 同为 0-1 量，代表在场景 ω 中该 MEPS 是否被派往孤岛 i；M 为移动应急电源集合；S 为中转站集合；参数 $L_{g,i,\omega}$ 是移动应急电源 g 在场景 ω 下到达孤岛 i 后能够恢复的加权负荷量；$T_{g,i,s}$ 为移动应急电源预置在站点 s 时驶达孤岛 i 最优接入点的行程时间；β 为行程时间折算系数，用于把行程时间折算成与负荷恢复量同量纲的等效损失，从而在括号内实现两种效益的直接相减；π_{ω} 是场景 ω 的发生概率。通过最大化 Z，可在期望意义上同时提高负荷恢复水平并降低 MEPS 移动时间，从而获得对全部典型故障场景均具有鲁棒性的 MEPS 预置方案。

3.3　约束条件

1）MEPS 唯一放置约束

每台 MEPS 只能停放在一个中转站，保证预置方案可实施。

$$\sum_{s\in S}x_{g,s}=1,\forall g\in M \quad (8)$$

2）孤岛供电分配约束

在每个典型场景中，任何一辆 MEPS 只能被指派到一处孤岛，防止出现同时服务多处的冲突。

$$\sum_{i\in\mathcal{I}_{\omega}}y_{g,i,\omega}\le 1,\forall g\in M,\forall\omega\in\Omega \quad (9)$$

3）预置与派遣一致性约束

仅当 MEPS 已被预置在某个中转站时才允许派遣，否则对应的 $y_{g,i,\omega}$ 必为 0。

$$y_{g,i,\omega}\le\sum_{s\in S}x_{g,s},\forall g\in M,\forall i\in\mathcal{I}_{\omega},\forall\omega\in\Omega \quad (10)$$

4）中转站容量约束

每个中转站 s 最多容纳两台 MEPS，防止出现超载停放。

$$\sum_{g\in M}x_{g,s}\le 2,\forall s\in S \quad (11)$$

5）孤岛接纳能力约束

每个孤岛在任一场景下最多接入一台 MEPS。

$$\sum_{g\in M}y_{g,i,\omega}\le 1,\forall\omega\in\Omega,\forall i\in\mathcal{I}_{\omega} \quad (12)$$

6）二进制约束

所有决策变量取 0-1 值。

$$x_{g,s},y_{g,i,\omega}\in\{0,1\} \quad (13)$$

3.4　求解方法

MEPS 预置模型属于典型的两阶段随机混合整数规划，其结构特点在于第 1 阶段的预置决策在所有场景中保持一致，而第 2 阶段的 MEPS 派遣决策可随场景变化而调整。逐步对冲算法(progressive hedging algorithm ，PHA)正是面向这一结构提出的分解-协调方法，通过在每轮迭代中将问题按场景拆分为多个可独立求解的子问题，并借助拉格朗日乘子机制实现跨场景一致性的动态调整，从而在兼顾求解效率与解耦性的同时获得全局一致的高质量解[26]，详细介绍见附录 B。此外，附录 D 比较了 MILP 求解器与 PHA 在不同场景规模下的表现。模型求解的流程图如图 3 所示。

4　算例分析

4.1　算例介绍

算例采用 IEEE33 节点配电网和 44 节点交通网组成的耦合系统进行分析，耦合系统如图 4 所示，配电网与交通网节点对应关系见附录 A 表 A1，负荷等级及权重系数见附录 A 表 A2。有 3 个中转站和 4 台不同的 MEPS 参与孤岛供电恢复，中转站 S1、S2、S3 分别位于交通网节点 7、11、35(对应于配电网节点 7、11、23)。MEPS 的参数见附录 A 表 A3。

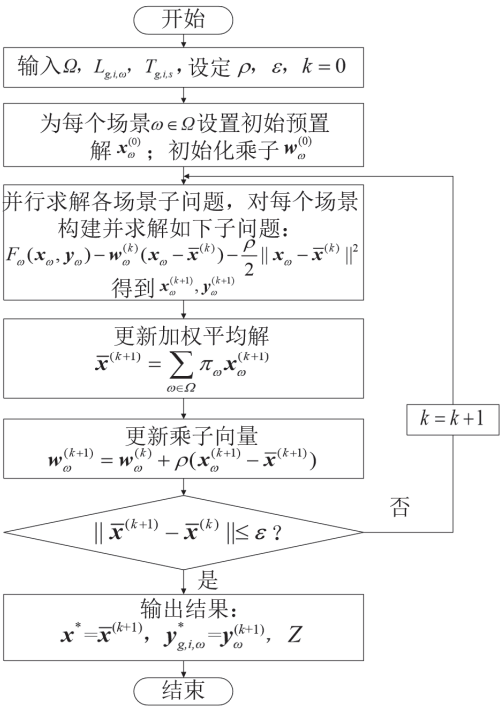


图 3　求解流程图

Fig.3　Flowchart of the solution process

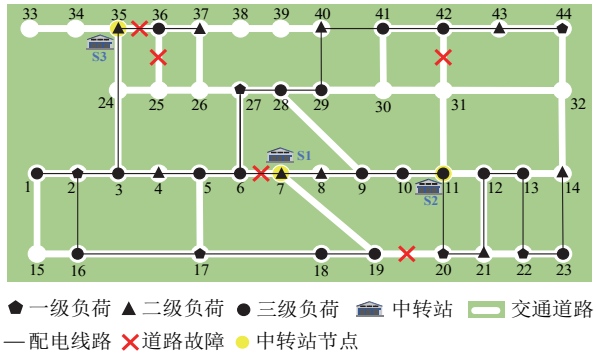


图 4 耦合测试系统

Fig.4 Coupled test system

交通道路(35，36)、(25，36)、(31，42)、(6，7)、(19，20)由于台风的影响发生堵塞不能通行。各交通线路均为双向道路，道路之间的行程时间见附录 A 表 A4。给定气象因素见附录 A 表 A5。CWGAN-GP 的训练参数配置见附录 A 表 A6。

4.2 cWGAN-GP 生成故障场景

4.2.1 生成故障场景的合理性与多样性分析

为全面评估所提出的 cWGAN-GP 模型在配电网故障场景生成的有效性，在所有样本中预留了 20 个样本用作验证，分别从生成场景的合理性与多样性两个维度开展验证分析。针对每个验证样本，首先利用训练好的生成器在其对应的气象因素下生成 200 条故障场景，并统计各线路的平均故障概率。由于验证样本的每组气象因素对应唯一的故障场景，若简单地将单个历史故障场景与生成的多个故障场景逐一比对，将难以反映模型对条件分布的整体学习效果。为此，基于欧几里得距离，在样本集中针对每个验证样本的气象因素选取与其最相似的 200 条历史故障场景，同样统计各线路的平均故障概率，从统计层面对比生成样本是否贴合真实的条件分布特征。

从故障概率分布的拟合角度进行分析，图 5 展示了在各验证样本的气象因素下生成故障场景与相似历史故障场景 32 条线路的平均故障概率对比结果。整体来看，在多数线路上的概率分布趋势较为一致，具备较高的拟合度。在所有验证样本中，相似历史故障场景中有两条线路的平均故障概率明显高于其他线路，且生成故障场景中这两条线路的平均故障概率也显著高于其他线路，表明模型能够准确捕捉线路间的典型故障关联关系。对于个别样本(如样本 1、11 和 17)，在部分线路上的平均故障概率存在一定偏差，可能由于该气象因素在样本集中对应的相似气象因素的样本数量较少，导致参考样本中故障模式的差异性较大。但总体来看，生成故障场景的概率分布未出现系统性偏移或显著异常，生成结果仍在合理范围内。

图 6 展示了模型生成的故障场景在场景结构规模与多样性两个维度的统计结果，其中柱状图对比了在每个验证样本的气象因素下生成故障场景与相似历史故障场景的平均故障线路数量，用于衡量模型生成结果在场景结构规模上的一致性。结果表明，生成故障场景与相似历史故障场景的平均故障数量保持一致或差异较小，反映模型在空间结构尺度上具备较强的重构能力。多数样本中两类数据的平均值差异不超过 1 条线路，表明模型既未出现过拟合导致的结构膨胀，也未因保守生成导致故障规模收缩。

折线图展示了在每个样本气象因素下，生成的故障场景中不同故障场景的数量，用于评估模型在相同气象因素下生成结构多样场景的能力。结果表明，生成器在 20 个样本下生成故障场景的多样性水平普遍处于合理区间，其中样本 2、11 和 17 生成不同故障场景数超过 40，说明模型在相同气象因素下能够生成具有显著结构差异的多种故障模式，结合概率分布结果可见，该多样性并非来源于随机扰动，而是在保持整体概率结构稳定的前提下，引入合理的组合变化，体现出模型对条件分布中不确定性的建模能力。

4.2.2 典型故障场景

用训练好的生成器生成给定气象因素下 10 000 条故障场景，剔除掉其中没有发生故障的场景，计算余下样本之间的 Jaccard 距离，并采用平均链接准则的凝聚型层次聚类方法进行场景分组，通过递归式合并距离最小的样本簇，生成故障样本的层次聚类树状图，如图 7 所示。其中虚线表示剪切阈值位置，剪切阈值设定为 0.52，据此对树状图进行切分，最终将故障场景划分为 20 个聚类簇。

在每个聚类簇内部，选取到簇内其他故障场景总体距离最小的样本作为典型场景，最终从 20 个聚类簇中分别提取出 20 个典型场景。附录 A 表 A7 给出了聚类簇内的场景数量统计情况，可以看出簇 10 内只有 1 个故障场景，而簇 18 内有 2 748 个故障场景，表明本文方法能够有效覆盖常见与罕见的故障场景，具有较好的全面性。

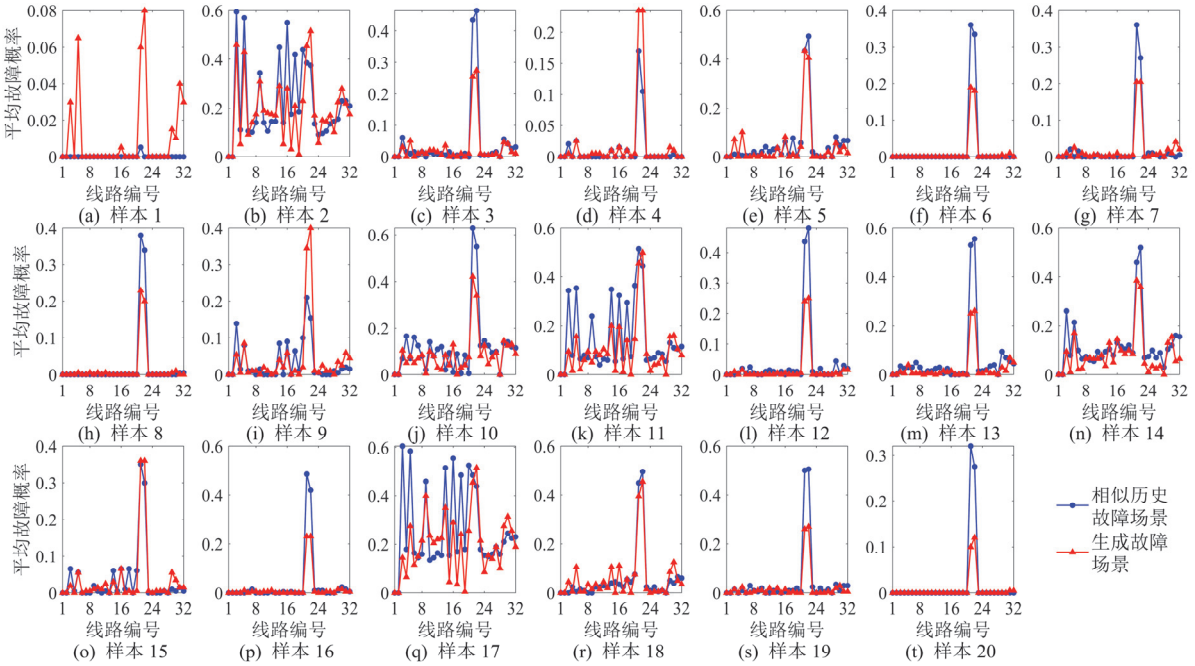


图 5　20 个验证样本线路的故障概率分布

Fig.5　Fault probability distribution of 20 validation sample feeders

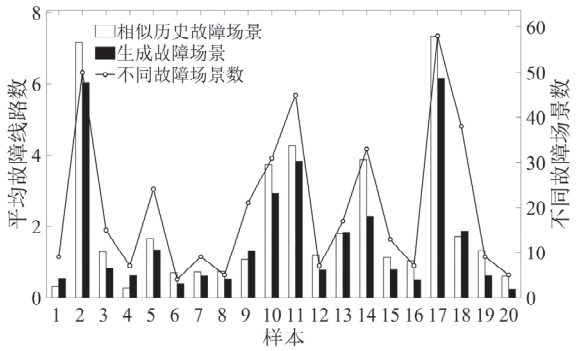


图 6　验证样本下的平均故障线路数与不同故障场景数

Fig.6　Average number of faulty lines under validation samples for different numbers of fault scenarios

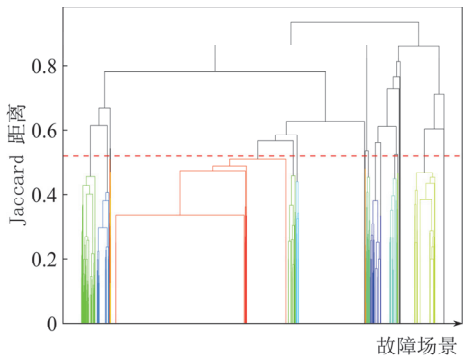


图 7　故障场景层次聚类图

Fig.7　Hierarchical clustering diagram of failure scenarios

4.3　MEPS 预置结果分析

β 不同，MEPS 的预置位置也会有所区别，该权重选取可根据调度者的保守性确定，若更倾向于恢复更多的加权负荷，则可适当减小 β 取值；反之希望有更短的行程时间可增大取值，不同 β 下的电源预置方案如附录 A 表 A8 所示，本文取 $\beta=1\,000$。PHA 算法中惩罚系数 ρ 取 30。综合 20 个典型故障场景，由 MEPS 预置模型最终求解得到 MEPS 最优预置方案如表 1 所示。

表 1　MEPS 最优预置方案

Table 1　Emergency power pre-deployment plan

MEPS 编号	预置位置
1	S2
2	S1
3	S1
4	S2

4.4　对比分析

4.4.1　对比方案

为验证预置方案的有效性，需联合考虑灾后恢复，用训练好的生成器生成 100 组随机故障场景，在 100 个故障场景下用 MEPS 调度模型对各 MEPS 进行灾后调度，调度时记录加权负荷恢复量以及行程时间两个指标，用来验证预置方案的有效性，MEPS 调度模型介绍见附录 C。设置了 3 组不同

MEPS 初始位置的对比方案，方案如下：

方案 1：本文方法求解出来的 MEPS 最优预置位置。MEPS1 和 MEPS4 预置在中转站 S2；应急电源 2 和应急电源 3 预置在中转站 S1。

方案 2：考虑 MEPS 预置但预置位置随机。设置了 3 组 MEPS 的随机预置位置。位置 1：MEPS1 和 MEPS2 预置在 S3、MEPS3 预置在 S2、MEPS4 预置在 S1。位置 2：MEPS1 和 MEPS3 预置在 S1、MEPS2 和 MEPS4 预置在 S3。位置 3：MEPS1 和 MEPS2 预置在 S1、MEPS3 和 MEPS4 预置在 S3。

方案 3：不考虑 MEPS 的预置。全部 MEPS 在灾前不预先配置到各个中转站，全都停放在首节点 1 处等待灾后调度。

4.4.2 对比结果分析

100 个故障场景下各方案的加权负荷恢复量与 MEPS 行程时间的统计平均值如表 2 所示。MEPS 行程时间可认为是负荷恢复供电时间。总体来看，在所有随机故障场景中，各方案的平均加权负荷恢复量差异较小，说明无论 MEPS 的初始安置位置如何，调度模型均能够有效发挥资源配置能力，优先恢复关键负荷，保障系统的供电稳定性。在行程时间方面，方案 1 在大多数随机灾害场景下的应急电源行程时间最短，平均行程时间仅为 4.17 h，显著低于方案 3 的 9.14 h，方案 3 在所有场景下的行程时间最长，负荷恢复供电时间比方案 1 晚了 4.97 h，负荷恢复效率低。方案 2 中 3 个位置的平均行程时间介于方案 1 与方案 3 之间，位置 1 的平均行程时间为 5.88 h，位置 2 为 6.37 h，位置 3 为 6.41 h，均高于方案 1。表明在加权负荷恢复量相近的前提下，方案 1 能以最短的调度响应时间完成关键负荷的供电恢复，在效率层面表现出显著的优势。

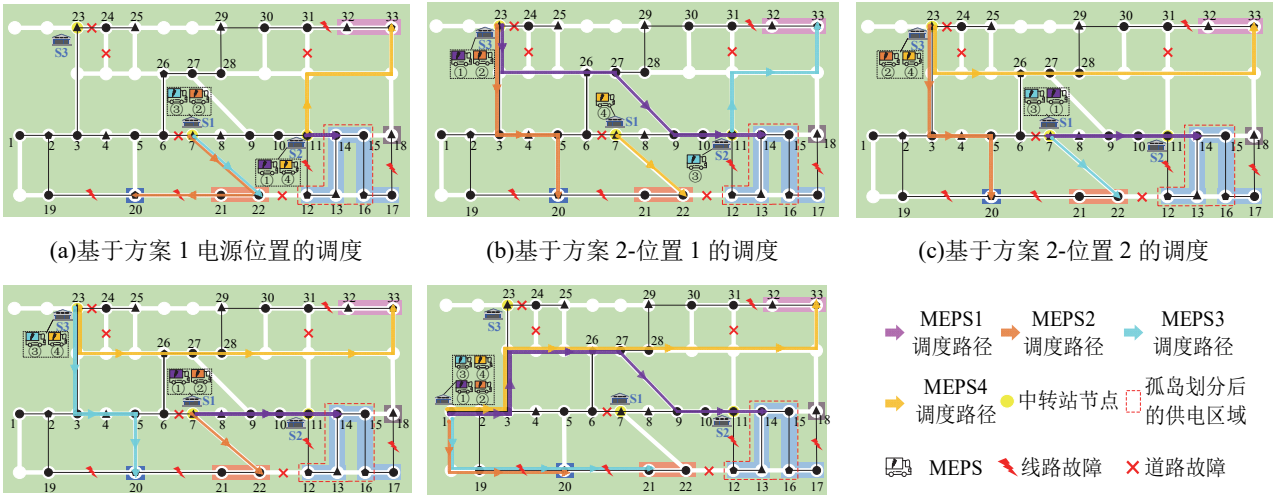
为了更直观的说明本文预置方案的有效性，以配电线路 11-12、17-18、19-20、20-21、31-32 发生断线故障为例，3 个不同预置方案的调度过程如图 8 所示，该场景下 MEPS 在恢复负荷供电过程中的调度路径、行程时间、平均负荷恢复时间以及负荷恢复率见附录 A 表 A9。

由图 8 可知，不同的预置方案可能会导致同一孤岛所匹配的 MEPS 存在差异，各 MEPS 的供电路径亦不相同，表明预置方案对灾后负荷恢复效率具有显著影响。在该故障场景中，共有 5 个失电孤岛，需调度多辆 MEPS 进行供电。结果显示，尽管不同方案下各孤岛所接入的 MEPS 不同，但每种方案恢复的总加权负荷量保持一致，且一级负荷的恢复率均为 100%。这表明调度模型能够在不同预置方案

表 2 各方案平均加权恢复负荷量与平均行程时间

Table 2 Average weighted restored load and average travel time of each scheme

不同 MEPS 位置	平均加权恢复负荷量/kW	MEPS 平均行程时间/h
方案 1	**16 437.85**	**4.17**
方案 2-位置 1	16 573.15	5.88
方案 2-位置 2	16 324.45	6.37
方案 2-位置 3	16 280.05	6.41
方案 3	16 585.45	9.14



(a)基于方案 1 电源位置的调度 (b)基于方案 2-位置 1 的调度 (c)基于方案 2-位置 2 的调度

(d)基于方案 2-位置 3 的调度 (e)基于方案 3 电源位置的调度

图 8 各方案移动应急电源调度路径图

Fig.8 Dispatch route diagrams of mobile emergency power sources for each scheme

下实现 MEPS 的合理分配，确保重要负荷的优先恢复，验证了调度模型的有效性，调度模型的有效性是评估预置方案可行性的前提。

在该故障场景下，方案 1 对应的 4 辆 MEPS 的平均调度行程时间为 0.91 h，显著低于其余 4 种预置方案。在各方案实现相同总加权负荷恢复量的前提下，方案 1 所对应的调度时间更短，体现出所提 MEPS 预置方案在该场景下的有效性。

单一场景的分析不足以全面反映方案性能的有效性。为此，进一步在图 9 所示的 100 个随机场景中对各方案进行了评估。结果显示各方案在加权恢复负荷量方面差异较小，其平均值汇总于表 2；在调度行程时间方面，从图中可知在大部分场景下方案 1 的行程时间均低于其他方案。结果表明，在加权恢复负荷量相近的条件下，本文的 MEPS 预置方案在大多数场景中均可实现更短的调度行程时间，验证了其在提高应急供电效率、保障关键负荷快速恢复方面的有效性。

根据上述分析可知：MEPS 从预置的中转站高效出动，快速参与孤岛区域的供电恢复，预置方案在多数场景下均能实现关键负荷的快速恢复，显著缩短灾后 MEPS 行程时间，验证了所提方案的可行性与实用性；考虑 MEPS 预置优化显著优于无预置情况下的被动调度。在不进行预置设计的条件下，MEPS 平均行程时间比进行预置设计条件下长 4.97 h，造成关键负荷长时间处于停电状态。引入预置策略后，调度路径显著压缩，供电行程时间明显减少，表明预置环节在提升负荷恢复供电效率中的关键作用；本文 MEPS 预置方案在不同配电网故障场景中均有较低的行程时间，说明其在多种灾害条件下具备良好的适应性与鲁棒性。该方案不仅能够提升单一场景下的调度效率，也具有面向多种复杂灾害环境下的广泛适用性。

5　结论

本文针对台风灾害条件下移动应急电源在灾前的预置问题，提出了一种基于 cWGAN-GP 的场景生成和两阶段随机混合整数规划的预置优化方法，并在 IEEE33 节点配电网和 44 节点交通网耦合系统中进行验证分析，获得以下主要结论：

1）本文 cWGAN-GP 模型能够有效捕捉气象条件与配电线路故障之间的复杂非线性关系，生成的故障场景具备高合理性与多样性，能为灾害场景的精确模拟提供有力支撑。

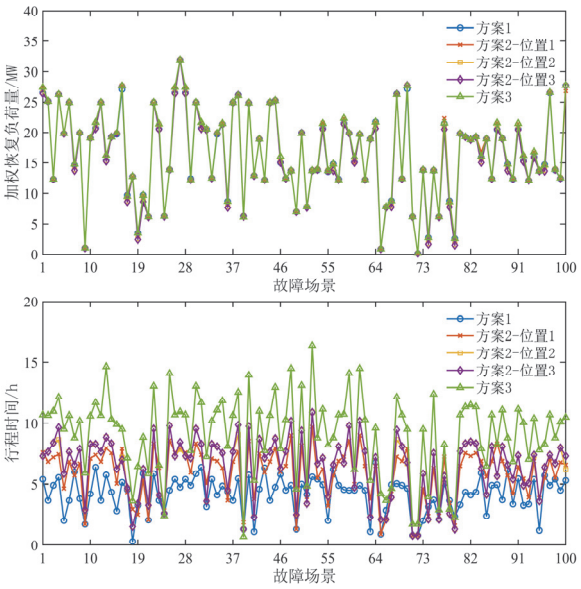


图 9　多场景下不同方案加权负荷恢复量和行程时间

Fig.9　Weighted load restoration and travel time of different schemes under multiple scenarios

2）基于典型故障场景的两阶段随机混合整数规划预置模型，能够综合考虑电力-交通网耦合约束，通过逐步对冲算法高效求解，获得强鲁棒性的最优预置方案。在多种随机故障场景下显著降低 MEPS 的行程时间，提升灾后关键负荷的恢复效率。

3）算例分析表明所提预置优化方法的有效性。与无预置及随机预置方案相比，本文预置方案能够大幅缩短 MEPS 的调度响应时间，且在多样的灾害条件下表现出良好的适应性与鲁棒性。

需要指出的是，本文在 MEPS 预置时灾后仅考虑 MEPS 恢复配电网的失电负荷，尚未考虑与多种固定电源的协同恢复。后续研究将联合移动与固定电源，协同恢复配电网故障，实现 MEPS 在多种灵活性资源参与下更为精准的预置。

附录见本刊网络版(http://hve.epri.sgcc.com.cn)。

参考文献　References

[1] 应急管理部防汛抗旱司. 2024 年全国防台风工作[J]. 中国防汛抗旱，2025，35(1)：4-7.
Flood Control and Drought Relief Department of Ministry of Emergency Management. National typhoon prevention work in 2024[J]. China Flood & Drought Management, 2025, 35(1): 4-7.

[2] 谢江涛，高方华. 援海南　抗“摩羯” 保供电[N]. 西江日报，2024-10-03(3).
XIE Jiangtao, GAO Fanghua. Supporting Hainan in typhoon "Mojie" relief to ensure power supply[N]. Xijiang Daily, 2024-10-03(3).

[3] 毛春初，刘 杰. 光明为誓 不胜不休 南方电网公司抗击台风“摩羯”抢修复电纪实[J]. 中国电力企业管理，2024(32)：92-94.
MAO Chunchu, LIU Jie. Sworn to restore power: a record of China southern power grid’s emergency repairs during typhoon "Mojie"[J]. China Power Enterprise Management, 2024(32): 92-94.

[4] 别朝红，林超凡，李更丰，等. 能源转型下弹性电力系统的发展与展望[J]. 中国电机工程学报，2020，40(9)：2735-2744.
BIE Zhaohong, LIN Chaofan, LI Gengfeng, et al. Development and prospect of resilient power system in the context of energy transition[J]. Proceedings of the CSEE, 2020, 40(9): 2735-2744.

[5] 侯 慧，耿 浩，肖 祥，等. 台风灾害下用户停电区域预测及评估[J]. 电网技术，2019，43(6)：1948-1954.
HOU Hui, GENG Hao, XIAO Xiang, et al. Research on prediction and evaluation of user power outage area under typhoon disaster[J]. Power System Technology, 2019, 43(6): 1948-1954.

[6] 严永辉，陈 辉，何俊驰，等. 台风灾害大范围停电诊断与抢修优化决策技术研究[J]. 电力学报，2020，35(5)：402-409.
YAN Yonghui, CHEN Hui, HE Junchi, et al. Study on emergency repair optimization decision technology based on diagnosis of large-scale blackout caused by typhoon disaster[J]. Journal of Electric Power, 2020, 35(5): 402-409.

[7] 蔡 维，余俊宏，余尔汶. 台风引发大面积停电危害分析及应对[J]. 电力安全技术，2021，23(5)：1-3.
CAI Wei, YU Junhong, YU Erwen. Analysis with measures on large-scale blackouts caused by typhoon disaster[J]. Electric Safety Technology, 2021, 23(5): 1-3.

[8] 王钰山，邓 晖，王 旭，等. 考虑台风时空演变的配电网移动储能优化配置与运行策略[J]. 电力系统自动化，2022，46(9)：42-51.
WANG Yushan, DENG Hui, WANG Xu, et al. Optimal configuration and operation strategy of mobile energy storage in distribution network considering spatial-temporal evolution of typhoon[J]. Automation of Electric Power Systems, 2022, 46(9): 42-51.

[9] 黄牧涛，周胡钧，卢 明，等. 面向配电网弹性提升的应急发电车配置策略[J]. 华中科技大学学报(自然科学版)，2025，53(1)：1-7.
HUANG Mutao, ZHOU Hujun, LU Ming, et al. Configuration strategy of emergency generator vehicle for resilience enhancement of distribution networks[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2025, 53(1): 1-7.

[10] 董骁翀，孙英云，蒲天骄. 基于条件生成对抗网络的可再生能源日前场景生成方法[J]. 中国电机工程学报，2020，40(17)：5527-5535.
DONG Xiaochong, SUN Yingyun, PU Tianjiao. Day-ahead scenario generation of renewable energy based on conditional GAN[J]. Proceedings of the CSEE, 2020, 40(17): 5527-5535.

[11] 顾 洁，刘书琪，胡 玉，等. 基于深度卷积生成对抗网络场景生成的间歇式分布式电源优化配置[J]. 电网技术，2021，45(5)：1742-1749.
GU Jie, LIU Shuqi, HU Yu, et al. Optimal allocation of intermittent distributed generation based on deep convolutions generative adversarial network in scenario generation[J]. Power System Technology, 2021, 45(5): 1742-1749.

[12] LEI S B, WANG J H, CHEN C, et al. Mobile emergency generator pre-positioning and real-time allocation for resilient response to natural disasters[J]. IEEE Transactions on Smart Grid, 2018, 9(3): 2030-2041.

[13] LEI S B, CHEN C, ZHOU H, et al. Routing and scheduling of mobile power sources for distribution system resilience enhancement[J]. IEEE Transactions on Smart Grid, 2019, 10(5): 5650-5662.

[14] 李明昊，杨祺铭，李更丰，等. 台风场景下基于多种分布式资源协同的弹性配电网两阶段供电恢复策略[J]. 高电压技术，2024，50(1)：93-104.
LI Minghao, YANG Qiming, LI Gengfeng, et al. Two-stage power supply restoration strategy of resilient distribution network based on coordination of multiple distributed resources in typhoon scenario[J]. High Voltage Engineering, 2024, 50(1): 93-104.

[15] POUDEL S, MUKHERJEE M, DUBEY A. Optimal positioning of mobile emergency resources for resilient restoration[C]//2018 North American Power Symposium (NAPS). Fargo, USA: IEEE, 2018: 1-6.

[16] SHI Q X, WAN H Y, LIU W X, et al. Preventive allocation and post-disaster cooperative dispatch of emergency mobile resources for improved distribution system resilience[J]. International Journal of Electrical Power & Energy Systems, 2023, 152: 109238.

[17] 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.

[18] 王月汉，刘文霞，姚 齐，等. 面向配电网韧性提升的移动储能预布局与动态调度策略[J]. 电力系统自动化，2022，46(15)：37-45.
WANG Yuehan, LIU Wenxia, YAO Qi, et al. Pre-layout and dynamic scheduling strategy of mobile energy storage for resilience enhancement of distribution network[J]. Automation of Electric Power Systems, 2022, 46(15): 37-45.

[19] 葛磊蛟，范延赫，来金钢，等. 面向低碳经济的人工智能赋能微电网优化运行技术[J]. 高电压技术，2023，49(6)：2219-2238.
GE Leijiao, FAN Yanhe, LAI Jingang, et al. Artificial intelligence enabled microgrid optimization technology for low carbon economy[J]. High Voltage Engineering, 2023, 49(6): 2219-2238.

[20] 米 阳，卢长坤，申 杰，等. 基于条件生成对抗网络的风电功率极端场景生成[J]. 高电压技术，2023，49(6)：2253-2263.
MI Yang, LU Changkun, SHEN Jie, et al. Wind power extreme scenario generation based on conditional generative adversarial network[J]. High Voltage Engineering, 2023, 49(6): 2253-2263.

[21] 梁 涛，孙博峰，谭建鑫，等. 基于深度强化学习算法的风光互补可再生能源制氢系统调度方案[J]. 高电压技术，2023，49(6)：2264-2274.
LIANG Tao, SUN Bofeng, TAN Jianxin, et al. Scheduling scheme of wind-solar complementary renewable energy hydrogen production system based on deep reinforcement learning[J]. High Voltage Engineering, 2023, 49(6): 2264-2274.

[22] 刘鑫蕊，罗雨晴，侯 敏，等. 阶梯式碳交易的城市多能系统能量互补优化调度策略[J]. 高电压技术，2023，49(6)：2275-2285.
LIU Xinrui, LUO Yuqing, HOU Min, et al. Energy complementation optimal scheduling strategy of urban multi-energy system with stepped carbon trading[J]. High Voltage Engineering, 2023, 49(6): 2275-2285.

[23] 谢 炀，杨 鑫，黄亚飞，等. 基于凝聚层次聚类的接地网定向支路减维腐蚀诊断优化方法[J]. 高电压技术，2024，50(4)：1723-1730.
XIE Yang, YANG Xin, HUANG Yafei, et al. Optimization method for dimension-reduction corrosion diagnosis of directional branch of grounding grid based on condensation hierarchical clustering[J]. High Voltage Engineering, 2024, 50(4): 1723-1730.

[24] 刘科研，贾东梨，李 昭，等. 基于孤岛划分约束的有源配电网故

障恢复策略[J]. 科学技术与工程，2024，24(22)：9425-9436.
LIU Keyan, JIA Dongli, LI Zhao, et al. Fault recovery strategy of active distribution network based on islanding algorithm[J]. Science Technology and Engineering, 2024, 24(22): 9425-9436.

[25] 倪程捷，房鑫炎，赵文恺，等. 基于图论的移动应急电源孤岛划分及最优接入点搜索[J]. 电力系统自动化，2015，39(6)：34-40.
NI Chengjie, FANG Xinyan, ZHAO Wenkai, et al. Island partitioning and optimal connecting point search of mobile emergency power source based on graph theory[J]. Automation of Electric Power Systems, 2015, 39(6): 34-40.

[26] ROCKAFELLAR R T, WETS R J B. Scenarios and policy aggregation in optimization under uncertainty[J]. Mathematics of Operations Research, 1991, 16(1): 119-147.



CHEN Chun
Ph.D.
Associate professor
Corresponding author

陈　春(通信作者)
1987—，男，博士，副教授，博导
主要研究方向为智能配电网规划与自愈控制
E-mail: chch3266@126.com

收稿日期　2025-08-01　在线出版日期　2025-12-26　编辑　陈　蔓

附录 A

表 A1　节点对应关系

Table A1　Node correspondence

配电网节点	交通网节点	配电网节点	交通网节点	配电网节点	交通网节点	配电网节点	交通网节点
1	1	10	10	19	16	28	29
2	2	11	11	20	17	29	40
3	3	12	20	21	18	30	41
4	4	13	21	22	19	31	42
5	5	14	12	23	35	32	43
6	6	15	13	24	36	33	44
7	7	16	22	25	37	/	/
8	8	17	23	26	27	/	/
9	9	18	14	27	28	/	/

表 A2　负荷等级及权重系数

Table A2　Load levels and weighting coefficients

负荷等级	权重系数	节点
一级负荷	10	2、12、16、20、26、33
二级负荷	5	4、7、8、13、18、23、25、29、32
三级负荷	1	其余节点

表 A3　不同供电能力的 MEPS 参数

Table A3　Emergency power source parameters

编号	最大有功出力/kW	最大无功出力/kvar
1	400	300
2	380	350
3	250	200
4	150	100

表 A4　交通线路行程时间

Table A4　Travel time of transportation routes

道路	起点	终点	行程时间/h	道路	起点	终点	行程时间/h
1	1	2	0.3	28	20	21	0.3
2	1	15	0.4	29	21	22	0.3
3	2	3	0.3	30	22	23	0.3
4	3	4	0.3	31	24	25	0.3
5	3	24	0.4	32	24	35	0.35
6	4	5	0.4	33	25	26	0.3
7	5	6	0.3	34	25	36	Inf
8	5	17	0.4	35	26	27	0.3
9	6	7	Inf	36	26	37	0.35
10	6	27	0.4	37	27	28	0.3
11	7	8	0.3	38	28	29	0.3
12	7	19	0.5	39	29	30	0.4
13	8	9	0.3	40	30	31	0.4
14	9	10	0.3	41	30	41	0.35
15	9	28	0.5	42	31	32	0.5
16	10	11	0.3	43	31	42	Inf
17	11	12	0.3	44	32	44	0.35
18	11	31	0.4	45	33	34	0.35
19	12	13	0.3	46	34	35	0.3
20	12	21	0.4	47	35	36	Inf
21	13	14	0.3	48	36	37	0.3
22	14	32	0.4	49	37	38	0.3
23	15	16	0.3	50	38	39	0.3
24	16	17	0.5	51	39	40	0.3
25	17	18	0.5	52	41	42	0.4
26	18	19	0.3	53	42	43	0.3
27	19	20	Inf	54	43	44	0.3

表 A5　给定气象因素

Table A5　Given meteorological conditions

登陆位置	方向角	速度	初始气压差
159.3 km, -55.5 km	1.19 rad	11.3 km/h	63.94 hPa

表 A6　CWGAN-GP 训练参数

Table A6　CWGAN-GP training parameters

类别	具体参数	数值/设置
网络结构	条件向量维度	5
	噪声向量维度	16
	故障向量维度	32
	隐藏层宽度	128
优化器	类型	Adam
	学习率(Generator/Critic)	5×10^{-5}
	β_1/β_2	0.0/0.9
超参数	Critic 更新次数	4
	梯度惩罚系数 λ_{gp}	12
训练配置	训练轮数	50
	批次大小	128

表 A7　簇内场景数量

Table A7　Number of scenarios within the cluster

簇 1	簇 2	簇 3	簇 4	簇 5	簇 6	簇 7	簇 8	簇 9	簇 10
245	60	8	7	148	51	141	222	1035	1
簇 11	簇 12	簇 13	簇 14	簇 15	簇 16	簇 17	簇 18	簇 19	簇 20
20	9	7	25	21	18	165	2748	544	218

表 A8　不同 β 下的电源预置方案

Table A8　Power prepositioning schemes under different β values

β 取值	预置方案
500	电源 1：S2、电源 2：S1、电源 3：S1、电源 4：S2
1 000	电源 1：S2、电源 2：S1、电源 3：S1、电源 4：S2
1 500	电源 1：S2、电源 2：S1、电源 3：S1、电源 4：S2
2 000	电源 1：S2、电源 2：S1、电源 3：S1、电源 4：S2
2 500	电源 1：S2、电源 2：S1、电源 3：S1、电源 4：S2
3 000	电源 1：S2、电源 2：S1、电源 3：S1、电源 4：S2
3 500	电源 1：S1、电源 2：S2、电源 3：S1、电源 4：S2
4 000	电源 1：S1、电源 2：S2、电源 3：S1、电源 4：S2
4 500	电源 1：S1、电源 2：S2、电源 3：S1、电源 4：S2
5 000	电源 1：S1、电源 2：S2、电源 3：S1、电源 4：S2

表 A9　单场景下应急电源恢复负荷结果

Table A9　Emergency power load restoration results under a single scenario

方案	电源编号	调度路径(道路节点)	行程时间/h	平均负荷恢复时间/h	一级负荷恢复率	二级负荷恢复率	三级负荷恢复率
方案 1	1	11→12	0.3	0.91	100%	47.06	84.62
	2	7→19→18→17	1.3				
	3	7→19→18	0.8				
	4	11→31→32→44	1.25				
方案 2-位置 1	1	35→24→25→26→27→28→9→10→11→12	2.95	1.71	100%	47.06	84.62
	2	35→24→3→4→5→17	1.85				
	3	11→31→32→44	1.25				
	4	7→19→18	0.8				
方案 2-位置 2	1	7→8→9→10→11→12	1.5	1.91	100%	47.06	84.62
	2	35→24→3→4→5→17	1.85				
	3	7→19→18	0.8				
	4	35→24→25→26→27→28→29→30→31→32→44	3.5				
方案 2-位置 3	1	7→8→9→10→11→12	1.5	1.91	100%	47.06	84.62
	2	7→19→18	0.8				
	3	35→24→3→4→5→17	1.85				
	4	35→24→25→26→27→28→29→30→31→32→44	3.5				
方案 3	1	1→2→3→24→25→26→27→28→9→10→11→12	3.6	2.66	100%	47.06	84.62
	2	1→15→16→17	1.2				
	3	1→15→16→17→18	1.7				
	4	1→2→3→24→25→26→27→28→29→30→31→32→44	4.15				

附录 B

在第 k 轮迭代中，PHA 首先对每个场景 $\omega\in\Omega$ 构建独立的子问题，其目标函数由原场景目标 $F_\omega(\boldsymbol{x}_\omega,\boldsymbol{y}_\omega)$、场景解与平均解之间的偏差惩罚项以及拉格朗日乘子项共同组成，即

$$\max_{\boldsymbol{x}_\omega,\boldsymbol{y}_\omega} F_\omega(\boldsymbol{x}_\omega,\boldsymbol{y}_\omega)-\boldsymbol{w}_\omega^{(k)}(\boldsymbol{x}_\omega-\bar{\boldsymbol{x}}^{(k)})-\frac{\rho}{2}\|\boldsymbol{x}_\omega-\bar{\boldsymbol{x}}^{(k)}\|^2 \tag{B1}$$

式中：$\rho>0$ 为惩罚系数；$\bar{\boldsymbol{x}}^{(k)}$ 表示当前轮次下所有场景第 1 阶段解的加权平均；$\boldsymbol{w}_\omega^{(k)}$ 为场景 ω 的乘子。由于各子问题结构相同且相互独立，可并行调用 Gurobi 求解，有效提升计算效率。

当所有子问题求解完成后，计算新的加权平均解：

$$\bar{\boldsymbol{x}}^{(k+1)}=\sum_{\omega\in\Omega}\pi_\omega\boldsymbol{x}_\omega^{(k+1)} \tag{B2}$$

并基于平均解对乘子进行更新：

$$\boldsymbol{w}_\omega^{(k+1)}=\boldsymbol{w}_\omega^{(k)}+\rho(\boldsymbol{x}_\omega^{(k+1)}-\bar{\boldsymbol{x}}^{(k+1)}),\forall\omega\in\Omega \tag{B3}$$

迭代过程中，通过不断调整场景间的差异惩罚，逐步推动各场景的第一阶段解向统一方案收敛。当相邻两轮平均解满足 $\|\bar{\boldsymbol{x}}^{(k+1)}-\bar{\boldsymbol{x}}^{(k)}\|\le\varepsilon$ 的收敛准则时，迭代终止。此时可得到所有场景下统一的预置决策 $\boldsymbol{x}^*$，以及在该预置条件下的场景响应策略 $\boldsymbol{y}_{g,i,\omega}^*$。

附录 C

MEPS 给失电孤岛供电时，以加权负荷恢复量最大化和行程时间最小化为目标进行调度，相对于电源预置模型的多个场景，现在针对的是某个特定的的灾后场景，只有单个故障场景，所以目标函数为：

$$\max Z=\sum_{g\in M}\sum_{i\in\mathcal{I}_\omega}(L_{g,i}-\beta\sum_s T_{g,i,s}x_{g,s})y_{g,i} \tag{C1}$$

式中：$L_{g,i}$ 表示应急电源车 g 调度至孤岛 i 后可恢复的加权负荷量，已包含子孤岛划分结果；$T_{g,i,s}$ 为应急电源车 g 从其预置中转站 s 到孤岛 i 最优接入点的最短行程时间；$x_{g,s}$ 为预置阶段给定的结果；β 为行程时间折算系数，用于将响应时间转化为等效负荷损失，统一纳入目标函数进行评价。

约束条件同预置模型。

附录 D

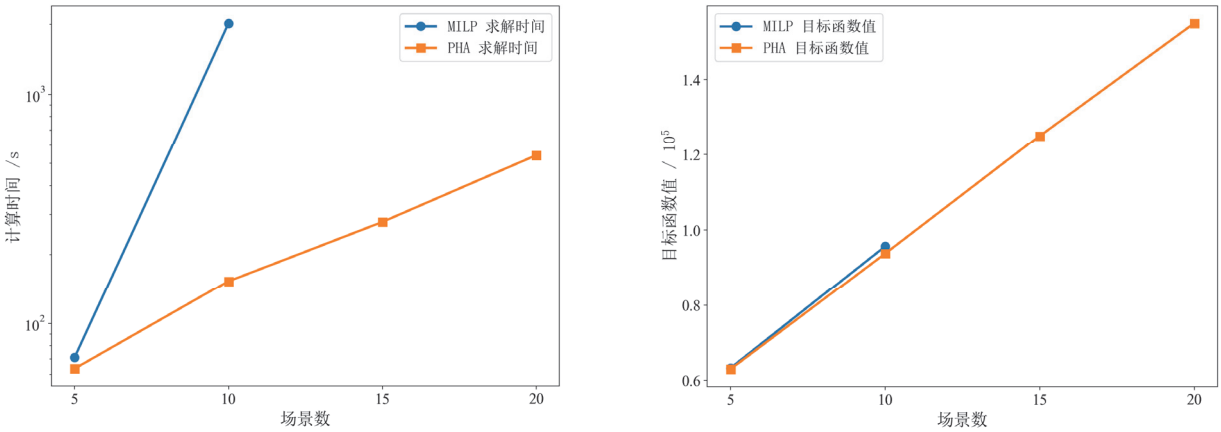
本文比较了 MILP 求解器与逐步对冲算法(PHA)在不同场景规模下的表现。最大计算时长设置为 5 h。在小规模场景数(5、10)时，MILP 可以在合理

时间内得到最优解，PHA 的解与之接近；而在中大规模场景数(15、20)时，MILP 在 5 h 的时间限制内已无法完成求解，而 PHA 依然能够在几分钟内快速输出可行解，并保持较优的目标函数值。误差分析表明，在小规模场景数时，PHA 得到的解与 MILP 的最优解相比，其相对误差不超过 3%，说明 PHA 在保证较高解质量的同时，显著降低了计算时间。本文算法在精度与效率之间取得了较好的平衡，更适用于灾害场景下的应急电源预置优化问题。

表 D1　MILP 与 PHA 求解时间及目标函数值对比

Table D1　Comparison of solution time and objective function values between MILP and PHA

场景数量	MILP 求解器		逐步对冲算法(PHA)	
	求解时间/s	目标函数值	求解时间/s	目标函数值
5	71.2	63 300.3	63.6	63 010.1
10	2 024.8	95 650.5	153.3	93 730.9
15	—	—	278.0	125 000.4
20	—	—	542.0	155 050.6



(a) 计算时间对比　　(b) 目标函数值对比

图 D1　MILP 与 PHA 求解时间及目标函数值对比

Fig.D1　Comparison of solution time and objective function values between MILP and PHA