

# 寒潮下基于智能导航的电动汽车充电网络韧性提升

王晗, 汤迪霏, 旷嘉庆, 张明潇, 王鹏

(南京师范大学南瑞电气与自动化学院, 江苏 南京 210046)

**摘要:**寒潮引发气温骤降, 易导致电动汽车(electric vehicle, EV)续航降低和充电设施故障, 无法满足 EV 用户的充电需求, 影响充电网络韧性。针对该问题, 文中提出一种基于智能导航的韧性提升方案。首先, 分析寒潮对 EV 充电网络的影响以及寒潮中 EV 充电桩的故障机理与级联特性, 对现有数据进行分析处理, 建立寒潮的级联影响模型; 其次, 利用图强化学习方法训练智能导航模型并利用该模型将移动应急发电机(mobile emergency generator, MEG)导航至故障充电站进行功率补偿, 从供电层面实现韧性提升; 然后, 利用导航模型为需要充电的 EV 推荐合适的充电站并进行路径规划, 从充电层面实现韧性提升; 最后, 通过算例验证寒潮中充电桩故障的主要原因是基于级联效应的负荷占比增长。文中所提协同导航方法能够在供电层面保证充电站充电功率的稳定和故障状态下的快速恢复, 在充电层面降低用户的充电前等待时间, 满足用户的充电需求。

**关键词:**电动汽车(EV); 充电网络; 移动应急发电机(MEG); 图强化学习; 智能导航; 充电网络韧性

**中图分类号:** TM72

**文献标志码:** A

**文章编号:** 2096-3203(2025)06-0073-11

## 0 引言

电动汽车(electric vehicle, EV)逐渐普及, 由充电站和连接充电站的交通道路组成的 EV 充电网络(EV charging network, EVCN)成为连接电力网络和交通网络的重要纽带<sup>[1-4]</sup>。寒潮来临时, EV 用户除面临电池性能下降带来的“里程焦虑”外, 亦面对 EVCN 设施损坏带来的“充电焦虑”。EVCN 的韧性是指充电网络在极端情况下提供稳定充电功率并在故障中快速恢复的能力。寒潮中, 电力线路覆冰、充电站断电、交通拥堵等不利影响对 EVCN 的韧性提出了更高的要求。

关于寒潮对 EVCN 的影响, 学者们从供电层面和充电层面展开研究。供电层面, 文献[5]指出寒潮会影响电力系统的供电。针对寒潮对电力负荷、充电桩的影响进行分析和建模<sup>[6-8]</sup>, 研究寒潮中供电质量下降甚至供电中断问题。充电层面, 寒潮中的道路拥堵和充电设施故障增加了用户的充电难度。文献[9]指出, 寒潮中道路覆冰可能会导致交通拥堵, 用户难以顺利前往充电站。同时, 寒潮中充电站的性能会受到影响, 充电速度降低, 用户充电难度增加。寒潮造成的初始故障会在基础设施间传播造成供电中断和充电困难, 这种现象被称为级联效应<sup>[10]</sup>。寒潮中充电站的承载能力下降而用户的充电需求却升高, 这一矛盾反映了寒潮对 EVCN 韧性的影响包含供电层面和充电层面, 因此在考虑

韧性提升时也应从这 2 个层面入手。

在供电层面, 有学者使用修复方法对寒潮中损坏的供电设备进行修复<sup>[11]</sup>。文献[12]提出灾前储能调度、灾中优化切负荷以及灾后故障修复的全过程优化方法。文献[13]引入应急发电机, 通过硬件提供功率补偿和人为修复相结合的方式保证极端情况下的连续供电。在充电层面, 利用低温快充技术实现硬件上的提升, 构建充电桩-微电网的联合规划模型实现软件上的提升, 保障低温条件下的充电桩供电<sup>[14]</sup>。同时, 为了用户的顺利充电, 文献[15]提出基于时间序列算法的拥堵预测模型, 对道路上的交通流量进行宏观规划。智能导航的方法能够兼顾供电层面和充电层面的韧性提升, 在供电层面能够快速将重点设备运往故障处解决供电中断的问题, 在充电层面能够快速实现负荷的空间调度, 使负荷分布更加合理, 因此可以考虑将调度任务放在交通网络以增强 EVCN 的韧性。

训练高质量智能导航模型是基于交通调度增强 EVCN 韧性的重要途径。学者们发现将数据通过图表示能够使智能导航过程中的抽象参数具象化<sup>[16]</sup>。文献[17]将图卷积网络和深度强化学习相结合, 形成图强化学习(graph reinforcement learning, GRL), 组成 EV 充电导航决策框架。其中多智能体方法采用 GRL 作为基础算法, 利用卷积神经网络(convolutional neural network, CNN)提取环境信息, 然后, 使用深度 Q 学习(deep Q-learning, DQN)进行智能导航模型训练, 能够提升寒潮中导航决策的准确性。然而在现阶段研究中, 学者们鲜有考虑寒潮

对充电网络的影响,只将智能导航模型应用在EV上。文中为应对寒潮造成的不利影响,将智能导航模型的应用拓展到移动应急发电机(mobile emergency generator, MEG)上,通过MEG的供电作业导航与EV的充电导航同时提升EVCN在供电和充电层面的韧性。

当前研究面临双重挑战:(1)EVCN中的基础设施之间具有级联效应,寒潮中的故障会在充电网络中传播,针对单一基础设施的修复策略或保障策略难以保障韧性提升效果,且寒潮对充电桩的影响分析鲜有涉及,现有研究更多集中于寒潮对电网的影响分析;(2)寒潮中充电需求提升与充电站承载力下降之间的矛盾导致寒潮中的故障充电站自愈能力较差,供电难以自行恢复。

针对上述挑战,文中在3个维度提出解决方案:(1)分析寒潮中基于级联效应的故障传播机理,利用低温下充电桩性能变化数据集与充电桩负荷分布优化数据集定性分析寒潮中充电桩故障概率的影响因素并建立模型定量分析寒潮对充电桩与充电站故障概率的影响;(2)对MEG进行供电引导,利用功率补偿的方法从供电层面实现EVCN的韧性提升;(3)对EV进行充电引导,利用充电路径规划的方法从充电层面实现EVCN的韧性提升。

## 1 寒潮中的随机电力拓扑网络

EVCN由充电站和连接充电站的交通道路组成,其基础设施具有数量庞大、结构复杂的特点。寒潮对EVCN的影响包含对单一设备的影响和设备之间的级联故障。文中包含寒潮场景生成、模型建立、数据分析与模型对比4个部分。

### 1.1 寒潮场景生成

寒潮的影响范围较广,查阅相关气象学知识,寒潮的影响范围可以近似当作圆形,在一定时间内,其影响范围会发生移动<sup>[18]</sup>。定义 $(x_c, y_c)$ 为寒潮中心坐标,将中心坐标周围的一定范围视为寒潮的影响范围。寒潮的影响范围随时间动态变化,寒潮中心坐标位置可以表示为时间 $t$ 的函数:

$$\begin{cases} x_c(t) = x_0 + v_T \sin(\delta)\Delta t \\ y_c(t) = y_0 + v_T \cos(\delta)\Delta t \end{cases} \quad (1)$$

式中: $(x_0, y_0)$ 为寒潮中心坐标的初始位置; $v_T$ 为寒潮的移动速度; $\delta$ 为寒潮移动方向与正北方向的夹角; $\Delta t$ 为寒潮的移动时间。

某节点 $(x, y)$ 距离寒潮中心的距离 $d_c$ 为:

$$d_c = \sqrt{(x - x_c(t))^2 + (y - y_c(t))^2} \quad (2)$$

在寒潮影响半径内的节点都会受到寒潮的影

响,受影响强度 $a_u$ 为:

$$a_u = \begin{cases} A_c \exp\left(-\nu\left(\frac{x - x_c(t)}{\sigma_x}\right)^2 - \nu\left(\frac{y - y_c(t)}{\sigma_y}\right)^2\right) & d_c \leq R_c \\ 0 & d_c > R_c \end{cases} \quad (3)$$

式中: $A_c$ 为寒潮中心的天气强度; $\nu$ 为距离与强度的影响因子,一般取值为0.1<sup>[5]</sup>; $\sigma_x$ 、 $\sigma_y$ 分别为 $x$ 、 $y$ 方向距离的标准差; $R_c$ 为寒潮最大影响范围半径。

### 1.2 寒潮中EVCN的级联效应

充电桩在寒潮中出现损坏主要是因为充电桩中充电模块故障<sup>[19]</sup>。低温环境和负载波动会共同影响充电模块随时间变化的故障概率 $p_f(t)$ <sup>[20-21]</sup>。

$$p_f(t) = p_0 + \beta_T(T(t) - T_s)^2 + \beta_L(L(t) - L_n)^2 \quad (4)$$

式中: $p_0$ 为充电模块的基础故障率,预估其取值范围为0.001~0.1; $T(t)$ 为 $t$ 时刻的温度; $T_s$ 为充电模块的安全工作温度,超出安全工作温度范围会显著增加故障概率,GB/T 18487.1—2023规定安全工作温度范围为-20~50℃; $L(t)$ 为 $t$ 时刻的负载大小; $L_n$ 为充电模块的额定负载,负载波动也会影响充电模块的性能; $\beta_T$ 为温度对故障概率影响的敏感系数,预估其取值范围为0.05~0.2; $\beta_L$ 为负载对故障概率影响的敏感系数,预估其取值范围为0.1~0.5。温度变化主要影响单个充电桩的故障概率,级联效应主要反映在负载变化上<sup>[22]</sup>,负载变化与温度有关,通常温度越低负载越高。为简化模型,可视为单个充电桩的故障率 $\lambda(t)$ 会随着温度的下降而增加,将其表示为温度的函数:

$$\lambda(t) = \alpha e^{-\beta_T T(t)} \quad (5)$$

式中: $\alpha$ 为正常数,用于控制充电桩损坏率的基准水平,文中假设充电桩的故障均由充电模块故障导致,所以 $\alpha$ 与 $p_0$ 在数值上近似相等。

在泊松过程<sup>[23]</sup>中,充电桩损坏的累计数量 $N(t)$ 在 $t$ 时刻的概率密度 $P$ 可以表示为:

$$P(N(t) \geq 1) = 1 - e^{-\lambda(t)} \quad (6)$$

充电桩故障会导致其所在充电桩集群负载能力下降,但用户的充电需求不会因此减少,该集群过载风险会有所增加,导致性能进一步下降。同理充电桩集群的性能下降会增加其所在充电站的过载风险,造成甩负荷,导致供电中断。建立寒潮中充电桩 $j$ 的故障概率受充电桩 $i$ 故障影响的模型。

$$p_j(t+1) = p_j(t) + \delta_{ij} f(p_i(t)) + g(L_j(t)) - r_j(t) \quad (7)$$

$$g(L_j(t)) = \eta \left( \frac{L_j(t)}{L_{\max}} \right)^{\beta_L} \quad (8)$$

式中:  $p_j(t+1)$  为充电桩  $j$  在  $t+1$  时刻的故障概率;  $f(p_i(t))$  为充电桩  $i$  在  $t$  时刻发生故障的影响强度的函数, 一般设定为  $f(p_i(t)) = p_i(t)$ , 表示充电桩故障对临近充电桩故障概率的直接影响;  $\delta_{ij}$  为充电桩  $i$  和  $j$  的耦合参数, 若充电桩属于同一个充电桩集群, 共用变压器和线路, 则属于强耦合关系,  $\delta_{ij}$  的取值为 0.3~0.8, 同一个充电站中的充电桩若不属于同一个充电桩集群, 则属于弱耦合关系,  $\delta_{ij}$  的取值为 0.1~0.3, 若充电桩不属于同一个充电站, 则属于独立关系,  $\delta_{ij}$  为 0;  $\eta$  为故障概率随负载增加的灵敏度系数, 主要用于描述负载占比较高的情况下负载变化对故障概率的影响, 负载占比较低时,  $\eta=1$ , 负载占比大于 90% 时,  $\eta$  取值为 1.5~3;  $L_j(t)$  为充电桩  $j$  在  $t$  时刻承担的负载大小;  $L_{\max}$  为单个充电桩的最大承载负载;  $r_j(t)$  用于描述充电桩  $j$  的修复等对结果带来的轻微扰动。

充电桩集群性能下降会导致充电站的整体性能下降<sup>[24]</sup>, 使用多项式分布<sup>[25]</sup>描述充电站中故障充电桩数量  $N$  为  $n$  的场景发生概率:

$$p(N=n) = \sum_{I(n)} \prod_{i \in I(n)} p_i(T) \prod_{j \notin I(n)} (1-p_j(T)) \quad (9)$$

式中:  $I(n)$  为充电桩集群中发生故障的充电桩的集合,  $n$  为故障充电桩数;  $p_i(T)$ 、 $p_j(T)$  分别为温度  $T$  下充电桩  $i$ 、 $j$  的损坏概率。基于充电桩故障的概率分布情况, 考虑非线性损失函数以及充电桩的异质性, 充电站在损坏  $N$  台充电桩时的性能  $S(N)$  的期望可以表示为:

$$E(S(N)) = \sum_{n=0}^{n_z} \sum_{I(n)} \prod_{i \in I(n)} p_i(T) \prod_{j \notin I(n)} (1-p_j(T)) \left(1 - \frac{n}{n_z}\right) \quad (10)$$

式中:  $n_z$  为充电站中的充电桩总数。式(10)描述充电站中充电桩故障、充电桩集群性能下降对充电站性能的影响。当一定数量的充电桩故障时, 充电站会出现供电中断。用户在面对目标充电站故障的情况下, 多数会选择就近前往其他未故障充电站, 导致其他充电站的负荷突增, 进而导致故障概率增加, 同时故障充电站的 EV 集中前往邻近充电站也会导致充电站附近的道路拥堵, 主要原理如图 1 所示。基于上述模型, 寒潮对 EVCN 的影响最终反映为充电站的损坏和道路的拥堵, 不同的损坏情况带来了不同的场景和动态变化的图拓扑, 文中将基于该动态图拓扑进行智能导航模型的训练以提升寒潮中 EVCN 的韧性。

### 1.3 数据分析与参数拟合

文献[26]通过实验分析了低温环境下充电桩




图 1 寒潮中的 EVCN

Fig.1 EVCN in extremely cold weather

的充电效率变化情况, 记录了不同温度下充电桩充电的电流电压数据、充电效率与负载率。其中电流电压数据是指充电接口处采集的充电电流与电压, 充电效率是指充电过程中输送到车辆的瞬时直流功率与电网供应的瞬时交流功率的比值, 负载率是指 EV 接入后充电桩负载占其额定负载的比值。文献[27]描述了不同温度下的充电负荷分布, 该数据集中的转移负载可作为级联效应对充电桩性能影响的参考数据, 转移负载是指充电桩因其他充电桩故障而被迫承担的额外负载。根据温度与负载情况对文献[26-27]中使用的 2 个数据集进行整合, 并设定充电功率低于额定功率 10% 的情况为充电桩不可用, 即充电桩故障。整合后的数据集经过相关性分析后得到包含温度、负载率、与 -20 °C 的温度差、过载率、级联负载率与充电桩故障概率的数据集。其中过载率是指充电桩过载情况下超出额定负载的部分与额定负载的比值, 级联负载率是指转移负载与额定负载的比值, 用于描述级联效应对故障概率的影响程度。

基于该数据集用热力图对多种寒潮中充电桩故障概率的影响因素进行定性分析, 如图 2 所示, 可知低温对充电桩的故障概率会造成一定的影响, 但基于级联效应的负载转移情况对故障概率的影响程度更高, 即级联效应对充电桩的故障概率有着较高的影响力。

用最小二乘法对式(4)—式(10)中的参数进行定量分析并拟合, 得到参数的最终取值为  $p_0=0.004$ ,  $\beta_T=0.08$ ,  $\beta_L=0.3$ ,  $\eta=2.2$ ,  $\delta_{ij}=0.7/0.2/0$  (分别对应强耦合、弱耦合与相互独立的情况)。上述参数取值也能够证明寒潮中因级联效应产生的负载占比过高是充电桩故障的主要原因。

### 1.4 模型对比

寒潮中, 充电桩的基础故障概率相互独立, 且主要受到温度影响, 短时间内单个充电桩出现多次故障的概率较低, 理论上非齐次泊松过程、马尔科






图2 充电桩故障概率影响因素热力图

Fig.2 Heat map of factors influencing the probability of charging pile failure

夫链、蒙特卡洛模拟等方法均可描述充电桩的故障概率。利用测试数据对3种模型进行数据拟合并检验其灵敏度,用均方根误差(root mean squared error, RMSE)、精确率与召回率(precision and recall, PR)、临界成功指数(critical success index, CSI)进行充电桩故障概率预测结果的对比,结果见表1。

表1 模型对比  
Table 1 Comparison of different models

模型	RMSE	PR/%	CSI/%
泊松过程	0.05	131.5	97.06
马尔科夫链	0.07	118.7	97.02
蒙特卡洛	0.11	111.2	97.02

由表1可知,非齐次泊松过程因其模型复杂度小且场景适配性好等原因在故障概率预测中具有更低的误差和更高的准确率,因此使用非齐次泊松过程进行寒潮中充电桩的故障概率建模能够提升场景准确性。

## 2 供电与充电层面的韧性提升优化模型

### 2.1 供电层面的MEG预置与调度

EVCN中发生供电中断后难以自我修复<sup>[28]</sup>,为了实现韧性提升,需要高灵活性地对故障充电站进行功率补偿,MEG是目前常用的方法<sup>[29]</sup>,能够单独为电网提供功率支撑和补偿。为了在充电站出现中断供电时MEG能够迅速动作,建立预置模型,以最小化移动距离和最大化负荷补偿为目标函数。

$$\max \sum_{y \in Y} P_y \left( \sum_{i \in I} \omega_i p_{i,y} - \gamma \sum_{s \in S} \sum_{q \in Q} \sum_{i \in I} m_{q,i,y,s} d_{q,i,y,s} \right) \quad (11)$$

式中:  $P_y$  为场景  $y$  发生的概率;  $Y$  为所有故障场景的集合;  $I$  为系统节点集合;  $\omega_i$  为节点  $i$  负荷的权重系

数;  $p_{i,y}$  为场景  $y$  下节点  $i$  承担的负荷;  $\gamma$  为交通系统的权重系数;  $S$  为 MEG 全部工作状态的集合,将用于强化学习模型的训练;  $Q$  为所有位置点的集合;  $m_{q,i,y,s}$  为故障场景  $y$  中 MEG 工作在状态  $s$  时节点  $i$  处位置  $q$  接入的 MEG 数量;  $d_{q,i,y,s}$  为场景  $y$  下工作在状态  $s$  的节点  $i$  处位置  $q$  的 MEG 移动到目标地点所需行驶距离。该模型的约束如下:

$$\sum_{s \in S} m_{q,s} \leq M_q \quad (12)$$

$$\sum_{q \in Q} m_{q,s} = 1 \quad (13)$$

$$\sum_{i \in I} m_{q,i,y,s} \leq 1 \quad (14)$$

$$\sum_{i \in I} m_{q,i,y,s} \leq m_{q,s} \quad (15)$$

式中:  $M_q$  为位置  $q$  允许安装的 MEG 最大数量;  $m_{q,s}$  为 MEG 在状态  $s$  下安装在位置  $q$  的数量。式(12)表示在位置  $q$  安装的 MEG 数量不能超出允许安装的最大数量;式(13)表示一个 MEG 同一时间只能安装在一个充电站;式(14)、式(15)表示 MEG 只能从一个安装位置移动到另一个安装位置。

在进行 MEG 调度的过程中,以上述预置模型的结果作为 MEG 的初始位置,调度目标是最小化网络中的失负荷<sup>[30]</sup>,即:

$$\min \sum_{t \in T_1} \sum_{i \in I} \omega_i (p_{i,t}^* - p_{i,t}) t \quad (16)$$

式中:  $p_{i,t}^*$  为节点  $i$  在  $t$  时刻的负荷需求;  $T_1$  为整个算例的时间分布;  $p_{i,t}$  为节点  $i$  在  $t$  时刻得到的恢复负荷。在调度时需要尽可能降低在途移动时间,故添加移动时间约束:

$$\sum_{\tau=t+1}^{\min(t+t_{q,i,s}, t_{\max})} m_{q,\tau,s} \leq (1 - m_{i,t,s}) \min(t_{q,i,s}, t_{\max} - t) \quad (17)$$

$$q \neq 1; t+1 \leq t_{\max}$$

式中:  $t_{q,i,s}$  为状态  $s$  下 MEG 前往节点  $i$  的位置  $q$  的通勤时间;  $m_{q,\tau,s}$  为状态  $s$  下  $\tau$  时刻位置  $q$  处所有待接入 MEG 总数;  $m_{i,t,s}$  为状态  $s$  下  $t$  时刻节点  $i$  处所有待接入 MEG 总数。若 MEG 在时间  $t_{\max}$  内没有到达目的地则不符合约束条件。  $t_{\max}$  的取值可以根据需要自由设定,文中设置为 2 h,即前往充电站的耗时超过 2 h 则判定 MEG 没有成功引导至断电充电站处。

### 2.2 充电层面的充电站推荐与路径规划

充电站故障后为了更好地满足 EV 充电需求,要将 EV 集群合理分配,保证在满足其充电需求的前提下维持 EVCN 的正常运行,即更科学的负荷空间分配,建立负荷分配优化模型为 EV 的充电站推

荐提供依据。该模型需要尽可能限制发电机的功率输入作为负荷分配的优化目标<sup>[31]</sup>,功率输入包含有功功率输入和无功功率输入两部分:

$$\min_{\theta, V, P_g, Q_g} \sum_{i \in I} h_{i, P_g} + h_{i, Q_g} \quad (18)$$

式中:  $\theta$  为电压相位角;  $V$  为电压幅值;  $P_g$  为发电机有功功率;  $Q_g$  为发电机无功功率;  $h_{i, P_g}$  为节点  $i$  有功功率输入值;  $h_{i, Q_g}$  为节点  $i$  无功功率输入值。该模型中设置如下约束:

$$B_P(\theta, V, P_g) = P_{\text{bus}}(\theta, V) + P_d - C_g P_g = 0 \quad (19)$$

$$B_Q(\theta, V, Q_g) = Q_{\text{bus}}(\theta, V) + Q_d - C_g Q_g = 0 \quad (20)$$

$$h_s(\theta, V) = |F_s(\theta, V)| - F_{\max} \quad (21)$$

$$h_t(\theta, V) = |F_t(\theta, V)| - F_{\max} \quad (22)$$

$$F(\theta, V) = \begin{cases} S(\theta, V) \\ P(\theta, V) \\ I(\theta, V) \end{cases} \quad (23)$$

$$H(V) = (CV)I^* \quad (24)$$

$$0.95\theta_i^{\text{ref}} \leq \theta_i \leq 1.05\theta_i^{\text{ref}} \quad (25)$$

$$V_{\min} < V < V_{\max} \quad (26)$$

$$P_{g, \min} < P_g < P_{g, \max} \quad (27)$$

$$Q_{g, \min} < Q_g < Q_{g, \max} \quad (28)$$

式中:  $B_P(\theta, V, P_g)$  为有功功率的功率流;  $B_Q(\theta, V, Q_g)$  为无功功率的功率流;  $P_{\text{bus}}(\theta, V)$  为母线有功功率;  $Q_{\text{bus}}(\theta, V)$  为母线无功功率;  $P_d$ 、 $Q_d$  分别为用电设备消耗的有功功率、无功功率;  $C_g$  为发电机支路数;  $h_s(\theta, V)$  为支路首端的流量;  $h_t(\theta, V)$  为支路末端的流量;  $F_s(\theta, V)$  为支路首端的视在功率、有功功率以及电流流量;  $F_t(\theta, V)$  为支路末端的视在功率、有功功率以及电流流量;  $F_{\max}$  为支路视在功率、有功功率以及电流流量可取的最大值;  $S(\theta, V)$  为视在功率流量;  $P(\theta, V)$  为有功功率流量;  $I(\theta, V)$  为电流流量;  $H(V)$  为支路传递功率;  $I^*$  为支路电流的共轭;  $C$  为分支编号;  $\theta_i$  为节点  $i$  电压相位;  $\theta_i^{\text{ref}}$  为节点  $i$  电压相位参考值;  $V_{\max}$ 、 $V_{\min}$  分别为电压上、下限;  $P_{g, \max}$ 、 $P_{g, \min}$  分别为发电机有功功率上、下限;  $Q_{g, \max}$ 、 $Q_{g, \min}$  分别为发电机无功功率上、下限。式(19)、式(20)为电力网络的有功和无功功率平衡约束; 式(21)—式(23)为每条支路上的流量约束; 式(24)为网络中的分支情况约束, 反映该网络的信号传递能力; 式(25)、式(26)为参考节点的电压相位角约束以及节点电压幅值约束, 从而尽可能避免节点的电压偏移情况; 式(27)、式(28)限制了节点有功功率和无功功率的注入极限, 尽可能避免系统过载。

当因为充电站内部的级联故障导致充电站性

能下降的时候, 需要充电的 EV 用户便会就近选择其他充电站进行充电, 造成充电站附近的交通拥堵<sup>[32]</sup>。为避免交通拥堵问题, 建立交通流量的重分配模型。该模型以最小化正常道路  $k$  上的交通流量  $Z(k)$  为目标函数, 可用时间变量  $t$  描述道路上的流量情况。

$$\min Z(k) = \sum_{a \in A_1} \int_0^k t_a(w) dw \quad (29)$$

式中:  $w$  为交通网络中起点和终点构成的 O-D 对;  $a$  为道路选择的动作;  $k_a$  为动作  $a$  要经过的所有道路;  $t_a(w)$  为动作  $a$  下按道路走需要的时间;  $A_1$  为所有可执行的道路选择集合。针对该目标函数, 需要设置如下约束:

$$\sum_{a \in A} Z_{\text{in}} = Z_{\text{out}} \quad (30)$$

$$Z \geq 0 \quad (31)$$

式中:  $Z_{\text{in}}$ 、 $Z_{\text{out}}$  分别为流入、流出节点的流量。式(30)表示交通流量  $Z$  的进出平衡即流入节点的流量与流出节点的流量严格相等; 式(31)表示交通流量的非负特性。通过求解交通流量重分配模型可得到车辆在 2 个充电站之间流转所遇到的道路阻抗  $L_{i \rightarrow j}$ :

$$L_{i \rightarrow j} = \frac{Z(k_{i \rightarrow j})}{\sum_{j \in I} Z(k_{i \rightarrow j})} \quad (32)$$

式中:  $Z(k_{i \rightarrow j})$  为从节点  $i$  到节点  $j$  的道路流量。

负荷分配模型能够计算出最佳负荷分配, 求解过程中, 若结果收敛, 则当前负载情况正常, 无须进行负载消减; 若结果无法收敛, 则将该故障范围内所有节点的负载减轻 5% 后再次迭代, 直至模型收敛。

交通流量优化模型基于正常条件下道路的交通流利用 Frank-Wolf 算法进行问题优化与求解, 通过线性规划的最优解得到每条道路上的交通流。

上述供电与充电层面的韧性提升优化模型为利用智能导航进行 MEG 与 EV 的调度提供了理论依据。

### 3 基于 CNN 与 DQN 的智能导航模型

#### 3.1 基于 CNN 的环境感知

智能导航大模型<sup>[33]</sup>由基于 CNN 的环境感知和基于 DQN 的强化学习训练过程组成。CNN 环境特征提取过程如图 3 所示。

建立瞬时节点特征矩阵  $\mathbf{X}$ ,  $\mathbf{X} = (\mathbf{E}_{t,i}, \mathbf{C}_{t,i}, \mathbf{K}_{t,i}, \mathbf{P}_{t,i})$ , 其中  $\mathbf{E}_{t,i}$ 、 $\mathbf{C}_{t,i}$ 、 $\mathbf{K}_{t,i}$ 、 $\mathbf{P}_{t,i}$  分别为 EV、充电站、交通道路、电力系统负荷在时刻  $t$  时节点  $i$  上感知的特征




图3 基于 CNN 的环境感知示意

Fig.3 Schematic diagram of CNN-based environmental awareness

矩阵。

### 3.2 基于 DQN 的导航决策

将 EV 的智能导航决策过程视为马尔科夫过程<sup>[34]</sup>, 对状态空间、动作空间、状态转移概率、奖励函数、折扣因子等进行定义。 $t$  时刻的状态空间  $s_t$  定义如下:

$$s_t = (i_t, b_t, d_t^{\min}, p_t, g_t) \quad (33)$$

式中:  $i_t$  为当前所处的节点编号矩阵;  $b_t$  为 EV 剩余电量列矩阵;  $d_t^{\min}$  为当前节点到最近充电站的最短距离列矩阵;  $p_t$  为充电站节点的平均输出功率矩阵, 非充电站节点对应的位置取 0;  $g_t$  为 MEG 的可用状态矩阵, 文中假设所有的 MEG 均未损坏且用于发电的柴油储备充足, 其状态只包含空闲和使用中 2 种, 1 表示空闲可用, 0 表示占用中, 占用中的 MEG 不参与导航过程直至其结束当前作业。

动作空间  $A$  定义如下:

$$a_t \in N(i_t) \quad (34)$$

式中:  $a_t$  为  $t$  时刻需要执行的动作, 为动作空间中的元素;  $N(i_t)$  为当前节点  $i_t$  的相邻节点集合。建立的电量消耗模型表示为:

$$b_{t+1} = \max(b_t - \xi l(i_t, a_t), 0) \quad (35)$$

式中:  $b_t$ 、 $b_{t+1}$  分别为  $t$ 、 $t+1$  时刻的电池电量;  $\xi$  为单位距离的耗电量;  $l(i_t, a_t)$  为当前节点  $i_t$  选定动作  $a_t$  后需要走的长度。定义奖励函数  $R_a$ , 表达式为:

$$R_a = \begin{cases} 100 & \text{成功到达} \\ -100 & \text{电量耗尽未到达} \\ 2(d_{t,i}^{\min} - d_{t+1,i}^{\min}) - 5 \cdot \|(b_{t+1} < B_{\text{safe}})\| & \text{其他情况} \end{cases} \quad (36)$$

式中:  $d_{t,i}^{\min}$  为  $t$  时刻 MEG 到目标节点  $i$  的最短距离;  $d_{t+1,i}^{\min}$  为  $t+1$  时刻执行动作后 MEG 到达新位置时, 到目标节点  $i$  的最短距离;  $B_{\text{safe}}$  为 MEG 安全电量阈值。DQN 方法中的  $Q$  值更新过程为:

$$Q(s_t, a_t) = Q(s_t, a_t) + \gamma(R_{a+1} + \psi \max_a Q(s_{t+1}, a) - Q(s_t, a_t)) \quad (37)$$

式中:  $\gamma$  为学习率;  $R_{a+1}$  为根据路径选择给出的奖励;  $\psi$  为折扣系数。

每次决策时, DQN 根据当前状态计算每个动作的  $Q$  值, 使用贪心策略选择具有最大  $Q$  值的动作, 通过不断更新  $Q$  值函数完成路径优化<sup>[35]</sup>。

完成训练后的智能导航模型能够在给定起点和终点的情况下, 选择出导航的最优路径。采用用户的充电前等待时间比  $f_E$  评价模型的导航效果。

$$f_E = \frac{t_E}{t_{\text{ref}}} = \frac{\sum_{i \in I} (t_i^d + t_i^q)}{\sum_{i \in I} t_{\text{ref}}} \quad (38)$$

式中:  $t_i^d$ 、 $t_i^q$  分别为 EV 前往目标节点  $i$  的行驶时间和充电排队等待时间;  $t_E$  为用户充电前的等待时间;  $t_{\text{ref}}$  为用户充电前的等待时间的参考值, 可根据实际情况设定, 文中为了展示用户等待时间的具体值, 取  $t_{\text{ref}} = 1 \text{ min}$ 。

## 4 算例分析

### 4.1 系统参数

采用 Sioux falls 路网与 IEEE 33 节点配电系统<sup>[36]</sup>作为测试平台, 在原有拓扑基础上, 于 3、5、8、21、24、26 节点处增加充电站 (即 CS1—CS6), 充电站的具体参数如表 2 所示, 拓扑如图 4 所示。

表 2 充电站参数  
Table 2 Charging station parameters

充电站 编号	充电站 接入节点	最大 EV 充电数量	充电功率/ kW	路网 位置
CS1	24	40	60	36
CS2	26	20	120	25
CS3	3	24	100	44
CS4	21	30	80	56
CS5	5	40	60	62
CS6	8	40	60	47

### 4.2 基于级联效应的故障场景

寒潮具有影响范围大和移动速度较慢的特点, 图 5 为寒潮的影响范围和移动路径, 越靠近寒潮中心受到寒潮影响越强烈。其中  $x$  轴为东西方向,  $y$  轴为南北方向。

在此场景下, EVCN 中的充电桩故障会导致充电站性能下降, 如图 6 所示, 充电站中 30% 的充电桩故障将导致充电站供电中断。

按照上述模型进行 1 500 个时间步的仿真, 其中每个时间步对应 15 min。在仿真过程中, 寒潮对充电桩造成影响并经过级联效应传播, 产生不同的充电站断电场景, 在这 1 500 个时间步的仿真中 6 个充电站的断电时间甘特图如图 7 所示, 红色时间段为对应充电站断电的时间段。MEG 与 EV 的






图4 Sioux falls-IEEE 33 耦合系统  
Fig.4 Sioux falls-IEEE 33 system




图5 寒潮的移动路径和影响强度  
Fig.5 Movement path and influence intensity




图6 充电桩损坏对充电站性能的影响  
Fig.6 Effect of charging pile damage on the performance of charging station

协同调度将基于图7所示的动态场景进行。




图7 充电站损坏情况甘特图  
Fig.7 Gantt chart of the damage situation of charging stations

4.3 MEG 与 EV 的协同调度

在寒潮中,充电站发生故障,MEG从预置位置导航至故障充电站,接入电力系统参与负荷恢复,算例遵循EVCN整体恢复最优原则<sup>[37]</sup>。根据MEG的预置模型得到3台MEG在充电站故障发生前的预置位置分别为11、15、19节点,调度结果如表3所示,其中Δ表示MEG在前往作业地点的途中。

表3 MEG 实时调度  
Table 3 MEG real-time schedule

MEG	0	100	200	300	400
MEG1	11	Δ	CS1	Δ	CS2
MEG2	15	15	Δ	CS3	CS3
MEG3	19	19	19	19	Δ
MEG	500	600	700	800	900
MEG1	CS2	CS2	CS2	CS2	CS2
MEG2	CS3	Δ	CS5	CS5	CS5
MEG3	CS6	CS6	CS6	Δ	CS4

在对MEG进行供电调度的同时对有充电需求的EV进行充电调度,采样某一时刻的导航结果如图8所示。将EV从节点5导航至CS2的过程中出现了CS2的故障,导航针对该拓扑变化进行重新决策,将EV导航至未发生故障的CS1进行充电;将EV从16号节点到导航至CS4的过程中,50号道路出现拥堵,重新决策后选择47—20—18路径避开拥堵路段;将EV从21号节点导航至CS5的过程中,MEG完成了CS6的故障修复,重新决策后将更近的CS6作为目标充电站。文中提出的导航算法不局限于最短路径,在充电站推荐时能规避故障设备,路径规划时能避开拥堵路段,MEG修复完成后能及时进行目标充电站的更新。

4.4 EVCN 韧性提升

寒潮中EVCN供电层面的韧性下降主要反映在充电站充电功率的下降,文中在进行MEG与EV协同调度的同时对6个充电站的平均充电功率进行监测,并设置未引入MEG情况下的对照组,对




图 8 协同调度路径规划结果

Fig.8 Result of collaborative scheduling path planning

比如图 9 所示。可见,在未引入 MEG 的情况下, EVCN 的供电中断时间较长,部分时间段出现了 6 个充电站都无法工作的情况,给 EV 的充电造成不便。引入 MEG 后,6 个充电站的供电中断持续时间均被控制在 100 个时间步以内,将寒潮给 EVCN 带来的不利影响控制在较低水平。




图 9 引入 MEG 前后充电站充电功率变化曲线

Fig.9 Charging power change curves of charging stations before and after MEG introduction

EVCN 充电层面的韧性下降主要反映在用户充电困难,因交通拥堵和充电排队导致的充电前等待时间较长。文中对测试的 1 500 个时间步内所有 EV 的充电前等待时间进行统计并设置未引入 MEG 的对照组,具体如图 10、图 11 所示。如图 10 所示,未引入 MEG 时用户的充电前等待时间明显较长,甚至有部分用户的充电前等待时间达到了 400 min。由图 11 可以看出,引入 MEG 后用户的充电前等待时间被缩短,基本被控制在 60 min 以内。




图 10 引入 MEG 前 EV 用户的充电前等待时间

Fig.10 The waiting time before charging for EV users before MEG introduction




图 11 引入 MEG 后 EV 用户的充电前等待时间

Fig.11 The waiting time before charging for EV users after MEG introduction

为分析文中基于 DQN+CNN 的智能导航方案的优越性,设置引入 MEG 但用传统最短路径导航方法的用户充电前等待时间作为对照组,如图 12 所示。可见,最短路径导航方法下,用户的充电前等待时长对比未引入 MEG 的情况有明显缩短,但相比于 DQN+CNN 的智能导航方法,用户的充电前等待时长明显更长,少部分用户的充电前等待时长超过 120 min,充电体验较差。最后,对该协同导航模型在不同的拓扑网络中进行了多场景验证,均能保证收敛性和决策的准确性。




图 12 最短路径导航法下用户的充电前等待时间

Fig.12 The waiting time before charging for EV users using the shortest path navigation method



## 5 结论

文中提出一种基于智能导航的 EVCN 韧性提升策略, 通过兼顾供电层面和充电层面实现充电站的供电恢复和 EV 的充电恢复。首先基于 EVCN 中基础设施的级联效应分析寒潮的影响以及 EVCN 中的故障传播原理, 建立基于级联效应的故障传播模型, 定性定量分析寒潮中多种因素对故障概率的影响。然后将 MEG 供电作业导航与 EV 充电导航相结合, 在恢复供电的同时保证 EV 充电需求的满足。经过对比算例得出如下结论:

(1) 寒潮中, 充电桩故障概率上升的主要原因是级联效应导致的转移负载, 因此可从供电层面进行功率补偿和从充电层面进行负荷分配优化来提升 EVCN 韧性;

(2) 引入 MEG 后能够实现充电站断电后的供电恢复, 减少充电站断电的持续时间, 从供电层面提升充电网络的韧性;

(3) 利用 DQN+CNN 的智能导航方法对 MEG 与 EV 进行协同导航, 为用户规避故障充电站和拥堵路段, 在 MEG 完成供电恢复后能为 EV 快速修改更优的目标充电站, 减少用户的充电前等待时间, 从充电层面提升充电网络的韧性。

在实际应用中, 可将文中模型本地部署在充电站中, 路网数据可利用 open street map 网站进行实地数据导入, 并录入充电站的相关数据。将 EV 的导航系统接入模型后即可实现充电站的推荐与引导。

在后续研究中, 可将寒潮对电力线路等电网部件的影响加入级联效应体系中, 建立更加完整准确的级联效应模型并尝试对智能导航模型进行轻量化迁移以进一步提升模型的实用性。

### 致 谢

本文得到江苏省研究生科研与实践创新计划项目(SJCX25\_0722)资助, 谨此致谢!

### 参考文献:

- [1] 孙毅, 彭杰, 武光华, 等. 电动汽车充电网络的软件定义理论、架构及关键技术[J]. 供用电, 2024, 41(12): 33-46.
- SUN Yi, PENG Jie, WU Guanghua, et al. Software-defined theory, architecture, and key technologies of electric vehicle charging networks[J]. Distribution & Utilization, 2024, 41(12): 33-46.
- [2] 张新松, 朱晨旭, 李大祥, 等. 考虑截获交通流量与充电行驶距离的电动汽车充电网络规划[J]. 电力系统保护与控制, 2024, 52(17): 40-50.
- ZHANG Xinsong, ZHU Chenxu, LI Daxiang, et al. Electric

vehicle charging network planning considering captured traffic flows and charging driving distance[J]. Power System Protection and Control, 2024, 52(17): 40-50.

- [3] 刘嘉彦, 李祖坤, 李畅, 等. 电动汽车与电力-交通耦合网互动: 综述与展望[J]. 电力科学与技术学报, 2024, 39(5): 12-24.
- LIU Jiayan, LI Zukun, LI Chang, et al. Interaction between electric vehicles and power-transportation coupled networks: current status, challenges and development trends[J]. Journal of Electric Power Science and Technology, 2024, 39(5): 12-24.
- [4] 程杉, 王豪杰, 徐其平, 等. 含超大功率充电的多类型充电设施两阶段选址定容方法[J]. 电力系统保护与控制, 2024, 52(23): 33-44.
- CHENG Shan, WANG Haojie, XU Qiping, et al. Two-stage siting and capacity determination method for multi-type charging facilities with ultra-high-power charging[J]. Power System Protection and Control, 2024, 52(23): 33-44.
- [5] MOTOAKI Y, YI W Q, SALISBURY S. Empirical analysis of electric vehicle fast charging under cold temperatures[J]. Energy Policy, 2018, 122: 162-168.
- [6] LI B D, CHEN Y, WEI W, et al. Routing and scheduling of electric buses for resilient restoration of distribution system[J]. IEEE Transactions on Transportation Electrification, 2021, 7(4): 2414-2428.
- [7] SHEZAN S A, ISHRAQUE M F, AHMAD K, et al. Performance evaluation of constant voltage and reactive power control strategies for renewable-integrated grid-connected EV charging stations[J]. IEEE Transactions on Industry Applications, 2025, 61(6): 8712-8721.
- [8] 胡晓伟, 宋帅, 邱振洋, 等. 寒区电动公交充电站选址及定容规划研究[J]. 交通运输系统工程与信息, 2024, 24(2): 281-292.
- HU Xiaowei, SONG Shuai, QIU Zhenyang, et al. Location and capacity planning of electric bus charging station in cold regions[J]. Journal of Transportation Systems Engineering and Information Technology, 2024, 24(2): 281-292.
- [9] 焦治杰, 许寅, 刘翌, 等. 寒潮天气下考虑电动汽车参与灵活调节的电网优化调度方法[J]. 电力系统自动化, 2025, 49(4): 116-127.
- JIAO Zhijie, XU Yin, LIU Zhao, et al. Optimal scheduling method for power grid considering participation of electric vehicles in flexible regulation during cold wave weather[J]. Automation of Electric Power Systems, 2025, 49(4): 116-127.
- [10] GHAREBAGHI S, CHAUDHURI N R, HE T, et al. Dynamic modeling and mitigation of cascading failures in power grids with interdependent cyber and physical layers[J]. IEEE Transactions on Smart Grid, 2024, 15(3): 3235-3247.
- [11] BAHRAMI A, YAN M Y, SHAHIDEPOUR M, et al. Enhancing the power system resilience to ice storms[C]//2023 IEEE Power & Energy Society General Meeting (PESGM). Orlando, FL, USA. IEEE, 2023: 1-5.
- [12] KALOTI S A, CHOWDHURY B H. Toward reaching a consensus on the concept of power system resilience: defini-

- tions, assessment frameworks, and metrics[J]. *IEEE Access*, 2023, 11: 81401-81418.
- [13] LI S L, MA Z J, CHOI T M. Post-disaster distribution system restoration with logistics support and geographical characteristics[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(7): 9011-9020.
- [14] 王苏杭, 李建林, 李雅欣, 等. 锂离子电池系统低温充电策略[J]. *储能科学与技术*, 2022, 11(5): 1537-1542.  
WANG Suhang, LI Jianlin, LI Yaxin, et al. Research on charging strategy of lithium-ion battery system at low temperature[J]. *Energy Storage Science and Technology*, 2022, 11(5): 1537-1542.
- [15] NARMADHA S, VIJAYAKUMAR V. Spatio-temporal vehicle traffic flow prediction using multivariate CNN and LSTM model[J]. *Materials Today: Proceedings*, 2023, 81: 826-833.
- [16] DING T, ZENG Z Y, BAI J W, et al. Optimal electric vehicle charging strategy with Markov decision process and reinforcement learning technique[J]. *IEEE Transactions on Industry Applications*, 2020, 56(5): 5811-5823.
- [17] XING Q, XU Y, CHEN Z, et al. A graph reinforcement learning-based decision-making platform for real-time charging navigation of urban electric vehicles[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(3): 3284-3295.
- [18] AQUINO J, PRADO J C D, NAZARIPOUYA H, et al. Enhancing power grid resilience against ice storms: state-of-the-art, challenges, needs, and opportunities[J]. *IEEE Access*, 2023, 11: 60792-60806.
- [19] KUMAR K, RITHVIK G, MITTAL G, et al. Impact of fast charging and low-temperature cycling on lithium-ion battery health: a comparative analysis[J]. *Journal of Energy Storage*, 2024, 94: 112580.
- [20] 南斌, 徐成司, 董树锋, 等. 考虑多充电模式的充电桩优化控制策略[J]. *电力工程技术*, 2021, 40(5): 2-9.  
NAN Bin, XU Chengsi, DONG Shufeng, et al. Optimized control strategy of charging piles considering multiple charging modes[J]. *Electric Power Engineering Technology*, 2021, 40(5): 2-9.
- [21] 刘秀兰, 陈熙, 张倩, 等. 充电桩充电模块功率器件故障诊断研究综述[J]. *高压电器*, 2024, 60(7): 191-200.  
LIU Xiulan, CHEN Xi, ZHANG Qian, et al. Review of power device fault diagnosis for charging module of charging pile[J]. *High Voltage Apparatus*, 2024, 60(7): 191-200.
- [22] 薛撬, 李军求, 肖焱升, 等. 低温环境下车用锂电池预加热策略研究[J]. *汽车工程*, 2023, 45(11): 2014-2022.  
XUE Qiao, LI Junqiu, XIAO Yansheng, et al. Research on the preheating strategy of lithium batteries under subzero temperature for electric vehicles[J]. *Automotive Engineering*, 2023, 45(11): 2014-2022.
- [23] WU Y, ZENG B. Properties related with conditional expectation for a non-homogeneous Poisson Process[J/OL]. *Journal of the Operations Research Society of China*, 2024. [2025-03-12]. <https://doi.org/10.1007/s40305-023-00527-8>.
- [24] 盛锐, 唐忠, 薛佳诚. 多指标下 EV 充电站服务能力动态评价方法[J]. *中国电机工程学报*, 2021, 41(14): 4891-4904.  
SHENG Rui, TANG Zhong, XUE Jiacheng. Dynamic evaluation method of EV charging station service capability under multi indicators[J]. *Proceedings of the CSEE*, 2021, 41(14): 4891-4904.
- [25] 李可萌, 王毅, 闪鑫, 等. 基于任意概率分布建模与改进混沌多项式展开的概率潮流方法[J]. *电力系统自动化*, 2024, 48(18): 167-176.  
LI Kemeng, WANG Yi, SHAN Xin, et al. Probabilistic power flow method based on arbitrary probability distribution modeling and improved polynomial chaos expansion[J]. *Automation of Electric Power Systems*, 2024, 48(18): 167-176.
- [26] TRENTADUE G, LUCAS A, OTURA M, et al. Evaluation of fast charging efficiency under extreme temperatures[J]. *Energies*, 2018, 11(8): 1937.
- [27] ZHU X Q, MATHER B, MISHRA P. Grid impact analysis of heavy-duty electric vehicle charging stations[C]//2020 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT). Washington, DC, USA. IEEE, 2020: 1-5.
- [28] 李英量, 白博旭, 朱琦, 等. 基于电动汽车充电站的不平衡配电网自愈及优化运行[J]. *电力建设*, 2024, 45(6): 37-46.  
LI Yingliang, BAI Boxu, ZHU Qi, et al. Self-healing and optimal operation of unbalanced distribution network based on electric vehicle charging station[J]. *Electric Power Construction*, 2024, 45(6): 37-46.
- [29] CAO Y P, ZHOU B, CHUNG C Y, et al. Resilience-oriented coordinated topology reconfiguration of electricity and drainage networks with distributed mobile emergency resources[J]. *IEEE Transactions on Smart Grid*, 2025, 16(1): 786-800.
- [30] THAPA J, OLOWOLAJU J, BENIDRIS M, et al. Power system reliability assessment under electric vehicle and photovoltaic uncertainty[J]. *IEEE Transactions on Industry Applications*, 2025, 61(2): 2248-2257.
- [31] BAŠKARAD T, HOLJEVAC N, KUZLE I, et al. Estimation of area frequency response in island operation mode by utilizing interconnected power system measurements[J]. *IEEE Transactions on Power Systems*, 2025, 40(2): 1649-1661.
- [32] ZHANG T Z, TANG D F, FAN P Y, et al. A probabilistic graphical model for predicting cascade failures of electric vehicle charging networks caused by hurricanes[J]. *IEEE Transactions on Smart Grid*, 2025, 16(1): 627-639.
- [33] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(9): 3848-3858.
- [34] LIANG Z P, YANG R T, WANG J G, et al. Dynamic constrained evolutionary optimization based on deep Q-network[J]. *Expert Systems with Applications*, 2024, 249:

123592.

Wuhan: Wuhan University, 2021.

- [35] YAO G Y, ZHANG N, DUAN Z H, et al. Improved SARSA and DQN algorithms for reinforcement learning[J]. *Theoretical Computer Science*, 2025, 1027: 115025.
- [36] MIRZAHOSSEIN H, NAJAFI P. Enhancing transportation accessibility: evaluating the impact of route guidance systems and connected autonomous vehicles[J]. *Transportation Research Interdisciplinary Perspectives*, 2024, 26: 101172.
- [37] 符竞. 城市电动汽车公共充电网络服务质量分析与优化方法研究[D]. 武汉: 武汉大学, 2021.
- FU Jing. Service quality analysis and optimization strategies for urban electric vehicle public charging networks[D].

作者简介:



王晗

王晗(1999), 男, 硕士在读, 研究方向为电力-交通耦合网络、电动汽车充电网络韧性提升(E-mail: [231812106@njnu.edu.cn](mailto:231812106@njnu.edu.cn));

汤迪霏(1986), 男, 博士, 副教授, 研究方向为电力-交通耦合网络的运行与规划、新能源汽车的负荷建模及 V2G 技术、电力系统优化运行、感应电压有源抑制技术等;

旷嘉庆(2001), 男, 硕士在读, 研究方向为电力-交通耦合网络、电动汽车可靠性。

## Resilience enhancement scheme of electric vehicle charging networks in extremely cold weather via intelligent navigation

WANG Han, TANG Difei, KUANG Jiaqing, ZHANG Mingxiao, WANG Peng

(School of Electrical and Automation, Nanjing Normal University, Nanjing 210046, China)

**Abstract:** Temperature declines are induced by cold waves, leading to reduced electric vehicle (EV) range and triggering failures in charging infrastructure. As a result, charging demand cannot be met, and the resilience of the EV charging networks (EVCN) is compromised. To address this issue, a resilience enhancement scheme based on intelligent navigation is proposed. The impacts of cold waves on the EVCN are comprehensively analyzed. The failure mechanisms and cascading characteristics of charging stations under cold wave conditions are investigated, and historical data are processed to establish a cascading failure model. To enhance supply-side resilience, mobile emergency generators are navigated to faulty stations for power compensation using a navigation model trained via graph reinforcement learning. In parallel, the same model is utilized to recommend suitable charging stations and optimize routing for EVs in need of charging, thereby improving resilience from the demand side. Through case studies, cascading load increases are identified as the primary cause of failures during cold waves. The proposed collaborative navigation approach ensures stable power delivery and rapid recovery under fault conditions, while reducing waiting times and fulfilling users' charging demand.

**Keywords:** electric vehicle (EV); charging network; mobile emergency generator (MEG); graph reinforcement learning; intelligent navigation; resilience of charging network

(编辑 方晶)