

基于雾计算负荷预测的低压无源台区 故障自愈重构恢复策略

刘音¹, 桂媛², 刘若溪², 宋一凡², 高杨³, 杨雯沁⁴, 王越⁴

(1. 国网北京市电力公司, 北京市 100031; 2. 国网北京市电力公司电力科学研究院, 北京市 100075; 3. 国网北京市电力公司丰台供电公司, 北京市 100073; 4. 中国农业大学信息与电气工程学院, 北京市 100083)

摘要:【目的】为提高低压台区的故障恢复智能化水平, 面向低压台区故障恢复问题, 提出了一种基于雾计算负荷预测的低压无源台区故障自愈重构恢复策略。【方法】首先, 为避免网络重构引发设备过载, 需要提前研判网络的负荷水平, 结合低压无源台区的典型结构和雾计算通信架构的特点, 设计了基于增量学习模型动态聚合的雾计算超短期负荷预测方法。该方法内嵌两个特性互补的超短期负荷预测模型, 通过动态加权的方式利用实时负荷进行模型增量学习, 并以故障事件触发的方式对低压负荷进行快速预测。此外, 基于所提的雾计算负荷预测, 提出了一种无线路参数的低压无源台区开关重构自愈恢复模型, 建模为混合整数二次规划问题。【结果】算例仿真结果表明, 所提雾计算负荷预测的平均绝对无标度误差主要受负荷突变的影响, 可控制在5~40之间, 相对误差处于1%~8%。【结论】在故障隔离后, 所提策略可有效完成单相负载的转供, 并在保持网络辐射运行和避免设备过载的同时, 尽可能维持相间负载均衡。

关键词: 低压台区; 故障自愈; 雾计算; 超短期负荷预测; 混合整数二次规划

中图分类号: TM733

文献标志码: A

文章编号: 1000-7229(2025)11-0035-12

DOI: 10. 12204/j. issn. 1000-7229. 2025. 11. 004

Post-fault Self-healing Reconfiguration Strategy for Low-Voltage Passive Station Areas Based on Fog Computing Load Prediction

LIU Yin¹, GUI Yuan², LIU Ruoxi², SONG Yifan², GAO Yang³,
YANG Wenqin⁴, WANG Yue⁴

(1. State Grid Beijing Electric Power Company, Beijing 100031, China; 2. State Grid Beijing Electric Power Company Electric Power Research Institute, Beijing 100075, China; 3. State Grid Beijing Electric Power Company Fengtai Power Supply Company, Beijing 100073, China; 4. College of Information and Electrical Engineering, China Agriculture University, Beijing 100083, China)

ABSTRACT: [Objective] To improve the intelligence level of fault recovery in low-voltage substations, a low-voltage passive substation post-fault self-healing strategy based on fog computing load prediction was proposed for the problem of low-voltage substation fault recovery. [Methods] First, to avoid equipment overload caused by network reconstruction, the load level of the network must be determined in advance. Combining the typical structure of low-voltage passive substations and the characteristics of fog computing communication architecture, a fog computing ultra-short-term load prediction method based on the dynamic aggregation of an incremental learning model was designed. This method embedded two ultrashort-term load prediction technologies with complementary characteristics. It used a real-time load for model incremental learning in a dynamic weighted manner and rapidly predicted low-voltage loads in a fault event-triggered manner. In addition, based on the proposed fog computing load prediction, a low-voltage passive substation switch reconstruction self-healing recovery model without line parameters was proposed and modeled as a mixed-integer quadratic programming problem. [Results] The simulation results showed that the average absolute scale-free error of the proposed fog computing load prediction was mainly affected by the load mutation that could be controlled between 5 and 40, and the relative error was between 1% and 8%. [Conclusions] The proposed post-fault self-healing strategy effectively completed the transfer of single-phase loads and

maintained the inter-phase load balance as much as possible, while maintaining the radial network operation and avoiding equipment overload.

This work is supported by the Science and Technology Project of State Grid Beijing Electric Power Company (No. 52022324000F).

KEYWORDS: low-voltage power station; fault recovery; fog computing; ultra-short-term load forecasting; mixed-integer quadratic programming

0 引言

低压配网低压台区负荷节点数量庞大、支线复杂,结合先进通信和智算技术进行低压配电自动化提升是当前新型电力系统建设的一项艰巨任务^[1]。考虑当前低压系统通信设施水平和环境干扰等因素,低压系统故障自愈从理论到实践面临诸多挑战,具有极强的研究价值和迫切的现实需求。

故障自愈需要全面感知低压输变电元件运行态势以及负荷短期发展趋势^[2],从而制定有效的开关和应急资源调度策略^[3-7]。结合低压配网的运行环境特点,通过在关键节点进行通信和自动开关改造,重构网络拓扑成为相对可行的一种手段,也引起一定程度的关注。文献[8]针对相间负载均衡问题,基于神经网络提出了一种中低压配网协调的网络重构方法,文献[9]面向低压光伏消纳问题,提出了一种多目标的联络开关优化配置方法,但均没有考虑低压故障修复期间负荷需求的变化以及低压线路参数的获取难度。

低压故障修复时间,一般可持续数小时,短期负荷需求变化对故障恢复策略具有显著影响^[3],目前的短期负荷预测技术主要包括传统数据驱动、人工智能以及混合预测三大类方法。传统的数据驱动法,以自回归积分滑动平均模型(auto regressive integrated moving average, ARIMA)^[10]和模态分解^[11]等方法为代表,人工智能方法则包括长短期记忆网(long short-term memory, LSTM)^[12]、卷积神经网络^[13]以及对抗神经网络^[14]等方法。这些方法的模型训练往往有赖于大量样本和计算资源,此外,大量研究已探讨了外部气象条件对负荷预测的重要性,但低压管理业务部门获取气象与低压负荷的关联数据现阶段还面临诸多困难,亟需一种依托存量数据开展负荷预测以指导故障自愈的方法。相比之下,近年来发展出的增量学习方法^[15],可以通过补充实时样本,以较少的计算资源获取高精度的短期负荷预测。站在通信和算力成本的角度,雾计算作为新一代边缘计算架构,以其低廉和高效的通信优势,与增量学习的部署环境需求具有较高的契合度^[16],应用于节点数量庞大且性质成分相对单纯的低压负荷预测问题具有

良好的前景。

通过上述文献总结可知,低压配网故障自愈恢复的研究方兴未艾。低压配网运行环境复杂,通信干扰强,需要兼顾通信成本和质量提出高效的负荷预测和自愈方法。面向该需求,本文提出一种基于雾计算负荷预测的低压无源台区自愈恢复策略。首先,结合低压无源台区的典型结构和雾计算通信架构,建立了一种基于增量学习模型动态聚合的雾计算负荷预测方法,该方法内嵌两个特性互补的 k 邻域超短期负荷预测模型,通过动态加权的方式利用实时负荷进行模型增量学习,并以故障事件触发的方式对故障修复期间的低压负荷进行快速预测。基于该雾计算负荷预测方法,同时考虑到低压线路阻抗参数不易获取的不利因素,所提策略设计了一种无线线路参数的低压无源台区开关重构自愈恢复模型,并表达为混合整数二次规划问题。最后,通过算例仿真展示了所提方法的应用效果。

1 基本概念与假设

首先明确本文研究的低压无源台区是指无分布电源低压并网的传统辐射状 380 V 运行台区,切合当前绝大多数城市低压配网的实际状况。其典型结构为,低压台区的范围起始于配变 400 V 低压侧,其出线经由出线柜(或者 JP 柜)分接至派接箱,再由派接箱引出至楼宇的光力柜,最终,光力柜的出线通过分支箱按相分配入户,每个箱/柜所在位置形成一个分支节点。按照电网部门的运行管理要求,派接箱一般仅装配刀熔开关,其余箱柜均可装配具有“遥测、遥信、遥控”(三遥)功能的断路器和低压监测通信单元,通过与融合终端信息交互和轻量化的边缘计算实现故障切断、故障隔离以及倒闸操作等高级功能。考虑上述低压台区的软硬件环境和数据获取条件,本文对于低压台区自愈恢复策略的研究参照经典结论并结合生产运行经验,对设备参数以及系统操作运行环境做出如下假设:

1) 鉴于低压被动台区的电压主要由上级电网辅以本地调压装置进行调控,节点电压在合理的供电半径内一般可控制在额定值附近运行,满足日常的波动负荷需求。为简化分析,本文假设低压节点电

压为额定值。

2)因节点电压假定为额定常数,低压馈线的线损与支路功率的平方近似成正比,该比例系数命名为支路线损系数,用 μ 表示:

$$\mu = \frac{\text{def } R}{U^2} \times 10^6 \quad (1)$$

式中: R 代表线路交流电阻,如150 mm²铜缆取0.117 Ω/km 、150 mm²铝绞线取0.19 Ω/km ; U 为节点额定电压(V),在低压配电网中常取额定相电压或线电压,因为在推导线损公式时,为简化计算,通常假定节点电压近似恒定且等于额定值;def表示“定义为”,用来表明右边的式子是对左边符号的正式定义。

3)负荷的功率因数为常数。

4)除派接箱外,其余同类型的配电箱/柜之间均可配置联络开关。

5)光力柜可以增配雾计算装置,用于收集户表上报的功率信息,并配置超短期负荷预测高级应用子模块。

2 故障自愈整体框架

面向故障恢复的网络拓扑重构属于临时性的供电保障措施,需要精确匹配设备带载能力与故障自愈期间低压负荷的短时动态变化,极力避免荷载能力弱的设备承担过重的负荷而造成二次停电。本章阐述所提雾计算通信架构,主要承担故障期间低压负荷的预测任务。以此为基础整体介绍以自动开关为调控手段的网络重构故障自愈执行逻辑。

2.1 雾计算框架

低压台区自愈的通信技术需要满足分布式、低延时、效率高的特点,雾计算是能够提供数据传输、计算以及存储的一种窄带边缘计算架构。本文提出的基于雾计算的低压台区自愈通信框架如图1所示。整体通信架构分为三层,分别为终端层、雾计算层以及云计算层。

终端层部署在用户表计端,用于周期性地采集用户功率、电压、电流等电气量,采用OpenADR协议,遵照IEEE 802.11 (WLAN)、IEEE 802.15 (WPAN)或者IEEE 802.15.4 (LR-WPAN)等标准,以无线组网加密传输方式发送至雾计算层。

雾计算层部署在光力柜,按需集成中央处理器、图形处理器以及硬盘等计算资源,作为汇集解密用户表计信息以及收发图文指令的中转站,可提供负荷电气量信息清洗、加密、特征提取、存贮等轻量计算高级应用服务,实现分布式计算、信息定制上传以及降低云端通信带宽和传输延时的枢纽作用。在信

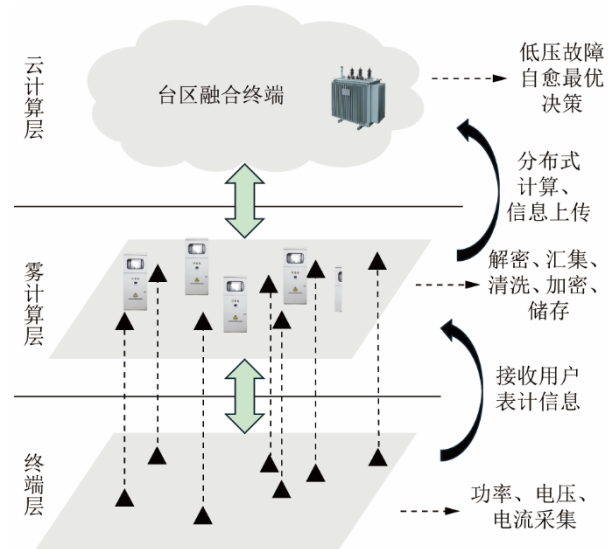


图1 基于雾计算的低压台区自愈恢复通信架构

Fig. 1 Communication framework of fog computing for self healing of a faulted low-voltage power supplying area

息传输上,除了载波通信外,可以考虑采用WiMAX、5G等长距宽带无线接入技术^[16]。

云计算层部署在台区融合终端,与光力柜雾计算单元进行通信,提供稳定可靠的信息存储和分布式计算任务分解等应用,主要执行低压故障自愈最优决策的高级应用,通过事件触发分布式雾计算,可靠快速完成故障隔离和开关状态决策的指令下发。

在物理链路层的构建上,为降低海量低压用户信息私有通信网的组建和维护成本,上述三个信息层之间的通信可租赁公网宽带,通过切片分网的方式模拟私有网络进行。

2.2 低压无源台区自愈恢复执行逻辑

基于上述雾计算通信架构,本文提出的低压无源台区自愈恢复策略主要面向配变低压侧出口至光力柜之间的故障,整体架构执行逻辑为,当保护跳开故障上游开关后,故障下游的光力柜监测单元触发“失压失流”事件信号,并广播至同台区的其他光力柜雾计算单元。收到事件信号的雾计算单元对本地保存的负荷样本进行预处理,并进行节点负荷功率预测,将结果上报至融合终端,由融合终端执行“低压开关重构自愈决策”,下达低压自动开关通断的部署指令^[17]。

所提雾计算架构的特点在于,雾计算任务和数据通信仅受故障判据和模型更新指令等事件触发,无故障发生的情况下,保持低功耗基础运算状态,如模型增量学习。考虑到故障自愈涉及网络状态调整,需要对故障期间开关上下游的负荷需求进行研判,而本文探讨的雾计算主要承担故障修复期间的节点负荷功率超短期预测。

3 低压无源台区自愈恢复策略

3.1 超短期负荷功率雾计算预测

采用雾计算负荷预测,需要考虑雾计算单元有限的浮点运算和数据存储能力,本文提出一种基于增量学习模型动态聚合的雾计算负荷预测方法。该方法内嵌两个相互独立的超短期负荷预测模型,为权衡雾计算的计算量、样本存储空间以及预测精度,本文选择文献[15]所提方法作为其中一个内嵌方法,并基于该方法派生出一种基于 k 邻域样本替换的超短期负荷预测方法,作为另外一个内嵌方法,分别用 f_k 和 $f_{k-\text{near}}$ 表示。两个内嵌模型根据实时负荷,独立在线开展增量学习,避免囤积大量样本和通信交互,各自的负荷预测值再经过动态加权聚合为最终输出的负荷预测结果^[18],本文采用的动态权重递进更新方法如式(2)所示。

$$\omega_{t+1} = \arg \min_{\omega_j \in \mathbb{R}^d} \sum_{j=1}^t \|\bar{f}_j - \omega_j^T f_j\|_2 \quad (2)$$

式中: t 为当前时刻索引; $f_j = [f_k, f_{k-\text{near},j}]$ 和 $\omega_j = [\omega_{k,j}, \omega_{k-\text{near},j}]$ 分别表示历史 j 时刻两个内嵌模型的独立预测值及其权重因子; \bar{f}_j 表示 j 时刻真实负荷值; ω_{t+1} 是 $t+1$ 时刻使用的权重因子向量; \mathbb{R}^d 表示实数域 d 维向量空间(此处 $d=2$,表示两个内嵌模型的权重维度)。

由式(2)计算出动态权重后,所提雾计算负荷预测对于故障恢复时段 T' 内输出的预测结果为 $\omega_{t+1}^T f_{t+i}, \forall i \in [1, \dots, T']$,其中 f_{t+i} 为在时刻 $t+i$ 的多模型预测值向量。

上述雾计算负荷预测方法中,由文献[15]改进而来基于 k 邻域样本替换预测方法,目的在于与文献[15]的负荷预测方法形成互补。主要体现在,对于趋势变化相对平缓的负荷序列,采用 k 邻域内的少量样本,经信息融合快速输出未来预测结果,保持较高的精度和预测效率;而当负荷序列突变时,由实时累计预测误差触发 k 邻域样本替换更新,从而“忘记”时间跨度长的历史样本,用最新的负荷实时值更新有限样本内的差异化特征。两个内嵌模型均利用实时数据进行增量自学习,在训练初期,两个方法的预测值基本相同。随时间推移,各自采用不同的机制更新训练样本,再根据两种方法预测误差的短期回溯表现,由式(2)持续优化学习两种方法的权重,从而维持整体预测性能的稳定。以下结合数据结构示意,详细阐述基于 k 邻域样本替换的负荷预测方法,如图2所示。




图2 “基于 k 邻域样本替换预测方法”的训练数据结构
Fig. 2 Training data structure of “load forecast method based on k -nearest samples with replacement”

图2中,给定某个节点的一组历史负荷功率序列,如 $[x_1, \dots, x_t]$,从任意一个样本出发,如 x_i ,连续截取其后 $p + T' - 1$ 个样本构成一个标签训练样本,记为 $L_i | x_i$,其中,包含 x_i 在内的前 p 个样本称为特征样本,记作 x_i ,而后 T' 个样本称为特征样本 x_i 的配对负荷真值,记作 L_i 。按照上述标签训练样本的定义,理论上可以从 $[x_1, \dots, x_t]$ 中提取出不超过 $t - p - T' + 1$ 个标签训练样本构成训练样本集合,即 $1 \leq i \leq t - p - T' + 1$ 。任意两个标签训练样本的相似程度由其特征样本欧拉距离所量化,数值越接近0,相似度越高。标签训练样本(或特征样本)的 k 邻域定义为与其相似度最高的 k 个其他标签训练样本(或特征样本)构成的集合。

参照上述定义,令 $K_{\text{cls}}(\mathbf{x})$ 代表与输入特征样本 \mathbf{x} 欧拉距离最近的历史特征样本 \mathbf{x}_{cls} 所关联的邻域样本个数,是需要预先指定的超参数; $\mathbf{x}_k(\mathbf{x}_{\text{cls}})$ 代表 \mathbf{x}_{cls} 的邻域中第 k 个历史特征样本; $L_{i,j}[\mathbf{x}]$ 代表与输入特征样本 \mathbf{x} 所配对的 j 时段历史负荷真值,则本文定义的负荷预测值 $f_{k-\text{near},j}(\mathbf{x})$ 计算表达式为:

$$f_{k-\text{near},j}(\mathbf{x}) = \frac{\sum_{k=0}^{K_{\text{cls}}(\mathbf{x})} w_k(\mathbf{x}_{\text{cls}}) L_{i,j}[\mathbf{x}_k(\mathbf{x}_{\text{cls}})] + w_{\text{cls}}(\mathbf{x}) L_{i,j}[\mathbf{x}_{\text{cls}}]}{\sum_{k=1}^{K_{\text{cls}}(\mathbf{x})} w_k(\mathbf{x}_{\text{cls}}) + w_{\text{cls}}(\mathbf{x})} \quad (3)$$

其中, $w_{\text{cls}}(\mathbf{x})$ 和 $w_k(\mathbf{x}_{\text{cls}})$ 的具体表达式为:

$$w_k(\mathbf{x}_{\text{cls}}) = \|\mathbf{x}_{\text{cls}} - \mathbf{x}_k(\mathbf{x}_{\text{cls}})\|_2 \quad (4)$$

$$w_{\text{cls}}(\mathbf{x}) = \|\mathbf{x}_{\text{cls}} - \mathbf{x}\|_2 \quad (5)$$

式(3)的内涵为,在给定的训练样本集合中,提取与 \mathbf{x} 相似度最高的特征样本 \mathbf{x}_{cls} 所关联邻域内标签样本 $\mathbf{x}_k(\mathbf{x}_{\text{cls}})$ 的配对负荷真值 $L_{i,j}[\mathbf{x}_k(\mathbf{x}_{\text{cls}})]$,按照邻域内特征样本与 \mathbf{x}_{cls} 的相似度(式(4)和式(5)),对 $L_{i,t}[\mathbf{x}_k(\mathbf{x}_{\text{cls}})]$ 和 $L_{i,t}[\mathbf{x}_{\text{cls}}]$ 进行归一化加权,作为给定特征样本 \mathbf{x} 的配对预测值。

将式(3)~(5)嵌入到式(2)中进行连续的负荷预测时,可根据实时负荷对其单独的预测误差进行监测,当误差越限时,可利用新获取的实时数据更新

标签训练样本库。鉴于时序数据的误差统计问题,本文采用如式(6)所示的平均绝对无标度误差^[18](mean absolute scaled error, MASE)。

$$e_{\text{MASE}} = \frac{\frac{1}{T'} \sum_{i=1}^{T'} |\omega_{t+1}^T f_{t+i} - L_{t+i}|}{\frac{1}{t-1} \sum_{i=1}^{t-1} |x_{i+1} - x_i|} \quad (6)$$

式中: e_{MASE} 为平均绝对无标度误差,用于衡量预测结果的精度; T' 为预测区间的长度; t 表示训练样本区间的长度,即用于建模的历史样本数; L_{t+i} 为真实负荷值在时刻 $t+i$ 的观测值。

基于 e_{MASE} ,设计样本更新的误差判据,如 $e_{\text{MASE}} > 15$,从而在维持训练样本库总量不变的前提下,通过误差判据触发特征样本邻域空间的增量学习,具体方式如下。

首先,将当前样本库 $[x_1, \dots, x_t]$ 中所有特征样本之间的相似度列写成矩阵形式,如下:

$$\mathbf{W}_t = \begin{bmatrix} 1 & w_{1,2} & \dots & w_{1,t} \\ w_{2,1} & 1 & \dots & w_{2,t} \\ \vdots & \vdots & \ddots & \vdots \\ w_{t,1} & \dots & \dots & 1 \end{bmatrix} = [w_1 \quad w_2 \quad \dots \quad w_t] \quad (7)$$

式中: \mathbf{W}_t 为样本相似度矩阵,其大小随样本库规模 t 动态扩展; $w_{i,j}$ 为 $\forall i \neq j \in [1, \dots, t]$ 代表特征样本 x_i 和 x_j 之间的相似度; w_i 为相似度矩阵的列向量。

将新到的实时样本 $\mathbf{x}_{T'} = [x_{t+1}, \dots, x_{t+T'}]$ 与当前样本库所有特征样本之间的相似度列写成向量形式,记作 $\mathbf{W}_{t,T'} = [w_{1,T'}, \dots, w_{t,T'}, 1]$,代入式(8)进行求解,如果矩阵范数的差值 $g(i^*) > 0$,则用 $[x_{t+1}, \dots, x_{t+T'} | x_{t+1-p}, \dots, x_t]$ 替换当前样本库中的 $L_{i^*} | \mathbf{x}_{i^*}$ 。

$$i^* = \arg \max_{1 \leq i \leq t} g(i) = |\mathbf{W}_{t,T'}| - |w_i| \quad (8)$$

当样本库发生替换后,为节省 \mathbf{W}_t 的计算开销,可以采用如下方式对 \mathbf{W}_t 进行最小更新。首先定义向量 $\vec{\mathbf{W}}_{i^*,T'} = [w_{1,T'}, \dots, w_{i^*-1,T'}, 1, w_{i^*+1,T'}, \dots, w_{t,T'}]$,然后用 $\vec{\mathbf{W}}_{i^*,T'}$ 和 $\vec{\mathbf{W}}_{i^*,T'}^T$ 分别替换 \mathbf{W}_t 中的第 i^* 列和第 i^* 行。

3.2 低压开关重构自愈恢复策略

低压开关状态重构以各光力柜雾计算单元对于故障修复期间的负荷预测曲线、低压台区当前开关状态以及故障持续区间作为输入,以最大恢复负荷为目标,生成低压遥控开关的最优运行状态决策^[19]。

3.2.1 优化目标

低压开关状态重构的优化目标设定为在尽可能维持三相功率均衡的情况下,低压台区总的失电负荷最小,即:

$$\min \sum_{t=1}^{T'} \left[\sum_{i=1}^{N_L} M(1 - k_{i,t}) L_{i,t} + \eta_{\text{AB},t} + \eta_{\text{BC},t} + \eta_{\text{CA},t} \right] \quad (9)$$

式中: N_L 代表低压台区分支节点数量; M 代表切负荷的惩罚系数;考虑到低压负荷不具备连续减载能力,引入 $k_{i,t}$ 代表节点 i 的负荷在 t 时刻的联网受电状态,即 $k_{i,t} = 1$ 表示联网取电, $k_{i,t} = 0$ 表示断网停电; $L_{i,t}$ 为节点 i 在时刻 t 的雾计算负荷预测,即 $L_{i,t} = \omega_{i,t}^T \mathbf{f}$; $\eta_{\text{AB},t}$ 、 $\eta_{\text{BC},t}$ 和 $\eta_{\text{CA},t}$ 为实现三相负载均衡而引入的辅助变量。

3.2.2 三相负载均衡约束

低压用户以单相供电居多,网络开关状态的调整可能涉及不同相之间的负荷转供转带,应尽可能时刻保持三相负载均衡。为此,设置约束 $\forall t \in \{1, \dots, T'\}$:

$$\eta_{\text{AB},t} \geq P_{\text{A},t}^T - P_{\text{B},t}^T, \quad \eta_{\text{AB},t} \geq P_{\text{B},t}^T - P_{\text{A},t}^T \quad (10)$$

$$\eta_{\text{CA},t} \geq P_{\text{C},t}^T - P_{\text{A},t}^T, \quad \eta_{\text{CA},t} \geq P_{\text{A},t}^T - P_{\text{C},t}^T \quad (11)$$

$$\eta_{\text{BC},t} \geq P_{\text{C},t}^T - P_{\text{B},t}^T, \quad \eta_{\text{BC},t} \geq P_{\text{B},t}^T - P_{\text{C},t}^T \quad (12)$$

式中:辅助变量 $\eta_{\text{AB},t}$ 、 $\eta_{\text{BC},t}$ 和 $\eta_{\text{CA},t}$ 的作用在于通过线性化的形式约束三相功率不平衡,再经由目标函数式(9)进行最小化,避免了直接对三相功率 $P_{\text{A},t}^T$ 、 $P_{\text{B},t}^T$ 、 $P_{\text{C},t}^T$ 的差值进行最小化时,需要构造绝对值或者平方项等非线性表达式的问题。

3.2.3 功率平衡约束

考虑到低压台区线路参数一般不易准确获取^[20],本文提出无线路参数功率近似平衡方程,如式(13)所示。

$$\sum_{m \in \varepsilon(n)} P_{m,n,t} + P_{n,t} = \sum_{m \in \varsigma(n)} P_{m,n,t} + l_{n,m,t} + k_{m,t} L_{n,t}, \quad \forall n \in \{1, \dots, N_L\}, \quad \forall t \in \{1, \dots, T'\} \quad (13)$$

式中: $P_{m,n,t}$ 代表跨接节点 m 和节点 n 的支路 t 时刻注入节点 n 的有功功率; $P_{n,t}$ 代表节点 n 的源荷注入功率; $\varepsilon(n)$ 和 $\varsigma(n)$ 分别代表以节点 n 作为功率接收和发送端节点的支路对侧端节点集合; $l_{n,m,t}$ 为计入支路损耗的辅助变量,需依照支路功率的实际传输方向进行约束。

$l_{n,m,t}$ 的具体原理结合图3说明如下:当定义支路功率以流入节点 n 为正方向时,若实际潮流方向与正方向一致(见图3(a)),则按照前文第一章内容所约定的假设,计支路损耗为 $l_{m,n} = \mu_{m,n} P_{m,n}^2$,其中 $\mu_{m,n}$ 为线路 (m,n) 的线损系数, $P_{m,n}$ 为线路 (m,n) 的有功功率;而当实际潮流方向反向时(见图3(b)),此时 $P_{m,n} < 0$,且包含了 $l_{m,n}$,功率损耗关系应为 $l_{m,n} = I_{n,m} = \mu_{m,n} (P_{m,n} + l_{m,n})^2$ 。因此,对于式(13)中 $l_{n,m,t}$ 的约束可通过big-M法具体实现如下。引入0-1辅助决策变量 $d_{n,m,t}, \forall m \neq n \in \{1, \dots, N_L\}, \forall t \in \{1, \dots, T'\}$,用于代表

支路实时功率方向,与规定正向一致时,取 $d_{n,m,t} = 1$; 否则,取 $d_{n,m,t} = 0$,具体为式(14)。




图 3 支路功率损耗与潮流方向关系示意图

Fig. 3 Schematic relationship between branch power loss and power flow direction

$$\frac{P_{n,m,t}}{2S_{m,n}} \leq d_{n,m,t} \leq \frac{P_{n,m,t}}{2S_{m,n}} + 1 \quad (14)$$

式中: $S_{m,n}$ 代表支路的额定视在功率。

基于 $d_{n,m,t}$ 的定义,上述对于 $l_{n,m,t}$ 的约束可以实现为:

$$\mu_{n,m} S_{m,n}^2 (d_{n,m,t} - 1) + \mu_{n,m} P_{n,m,t}^2 \leq l_{n,m,t} \leq \mu_{n,m} P_{n,m,t}^2 \quad (15)$$

$$-\mu_{n,m} S_{m,n}^2 (1 + S_{m,n})^2 d_{n,m,t} + \mu_{n,m} (P_{n,m,t} + l_{n,m,t})^2 \leq l_{n,m,t} \leq \mu_{n,m} (P_{n,m,t} + l_{n,m,t})^2 \quad (16)$$

当实时功率与参考方向一致时, $d_{n,m,t} = 1$,由式(15)限定 $l_{n,m,t} = \mu_{n,m} P_{n,m,t}^2$,而式(16)中第一项此时取值 $-\mu_{n,m} S_{m,n}^2 (1 + S_{m,n})^2$,可以保证包含 $l_{n,m,t} = \mu_{n,m} P_{n,m,t}^2$;反之, $d_{n,m,t} = 0$,由式(16)限定 $l_{n,m,t} = \mu_{n,m} (P_{n,m,t} + l_{n,m,t})^2$ 。同理,式(15)中第一项此时取值为 $-\mu_{n,m} S_{m,n}^2$,保证包含了 $l_{n,m,t} = \mu_{n,m} (P_{n,m,t} + l_{n,m,t})^2$ 。

此外,为说明本文所提的线损系数估计方法的精度,图4绘出了铜、铝两种不同导线材质下,5 km、10 kV 线路输送 100 kW 有功功率时的线损随传输功率因数的变化规律。可以看到,所提方法的估计结果随功率因数的提高迅速逼近真值,当功率因数在 0.95 以上时,线损误差不超过 9.8% (与导线材质无关)。

3.2.4 开关动作约束

为不失一般性,用 $\kappa_{m,n,t}$ 代表节点 m 和节点 n 间支路开关在时刻 t 的运行状态。 $\kappa_{m,n,0}$ 代表开关在故障隔离后的初始状态,将不存在自动开关以及故障隔离的支路共同构成的集合用 $F(T')$ 表示,由此,开关动作约束可表达为:

$$\kappa_{m,n,t} = 0, \forall t \in \{1, \dots, T'\}, \forall m, n \in F(T') \quad (17)$$

故障恢复期间,为避免低压开关频繁动作对用户造成二次停电,约定“所有开关在故障自愈时段 T' 内至多动作一次”。

$$-\kappa_{m,n,0} \leq \kappa_{m,n,t+1} - \kappa_{m,n,t} \leq 1 - \kappa_{m,n,0}, \forall t \in \{1, \dots, T' - 1\}, \forall m \neq n \in \mathbb{B} \quad (18)$$

式中: $\kappa_{m,n,t}$ 表示支路 (m,n) 在时段 t 的开关状态二进




图 4 不同功率因数和导线材质下损耗系数法估计的线损与精确值之间的对比关系($U = 1 \text{ p.u.}$)

Fig. 4 Comparative relationship between line loss via the proposed loss coefficient method and accurate value under different power factors and conductor materials plus ($U = 1 \text{ p.u.}$)

制变量, $\kappa_{m,n,t} = 1$ 代表开关闭合,支路处于投入状态, $\kappa_{m,n,t} = 0$ 代表开关断开,支路处于切除状态; \mathbb{B} 表示含开关支路所连接节点的集合。

同时,为了始终保持网络呈现辐射状运行,采用文献[21]的方法限定开关的组合状态,表达为式(19)。

$$O(\kappa_{m,n,t}) \leq 0, \forall t \in \{1, \dots, T'\}, \forall m \neq n \in \mathbb{B} \quad (19)$$

采用式(19)的辐射拓扑限定方法,其优势相较于虚拟线路拓扑约束法,非但不增加模型的辅助变量个数,也有助于缩减整数变量的可行域。所有环路 $O(\kappa_{m,n,t})$ 仅在开关、线路等设施建成后一次性完成离线识别即可,不占用在线计算资源。此外,还可以根据开关运行条件,增设三相开关联动约束。

3.2.5 边界条件

式(20)用于避免失电负荷复电后发生二次停电,式(21)表示受开关状态制约的支路有功约束, $\cos(\theta_{m,n})$ 为支路功率因数。

$$k_{m,t} \leq k_{n,t+1}, \forall i \in [1, \dots, N_L], \forall t \in [1, \dots, T' - 1] \quad (20)$$

$$-S_{m,n} \cos(\theta_{m,n}) \kappa_{m,n} \leq P_{m,n,t} \leq \kappa_{m,n} S_{m,n} \cos(\theta_{m,n}), \quad \forall m \neq n \in \{1, \dots, N_L\} \quad (21)$$

综上,本文提出的基于雾计算负荷预测的开关状态重构决策模型由式(9)~(21)构成,决策变量包括 $\kappa_{m,n}$ 、 $k_{m,t}$ 、 $P_{m,n,t}$ 、 $l_{n,m,t}$ 、 $d_{m,n,t}$ 和 $P_{n,t}$ 。注意到式(15)、式(16)包含二次非线性项,所提模型呈现出混合整数

二次规划问题的特征。现代商业求解器,如 Gurobi,通过内置高性能的双线性插值算法,可快速解算上述混合整数二次规划问题的高质量逼近甚至精确的全局最优解。

4 算例分析

4.1 算例条件与参数

考虑到不同低压配变若在低压供电区内进行互联,将掣肘于诸多实际因素,本算例仅考虑在同台区光力柜内以及柜与柜之间分别增设相间和母线联络开关(三相联动),如图 5 所示。 L_1-L_9 等 9 个单相低压负荷的信息收集与处理均在各自出线所在光力柜的雾计算单元内完成。当相电压取 220 V 时,同时假设所有单相线路均为 $4 \times 150 \text{ mm}^2$ 铜缆,根据式(1)可计算支路线损系数 $\mu = 2.42 \times 10^6 \text{ W} \cdot \text{kW}^{-2} \cdot \text{km}^{-1}$ 。线路长度统一设定为 3 km,单相支路和联络开关的额定视在功率取为 $100 \text{ kV} \cdot \text{A}$,线路功率因素取 0.9。低压配变和母线容量视为无穷大。

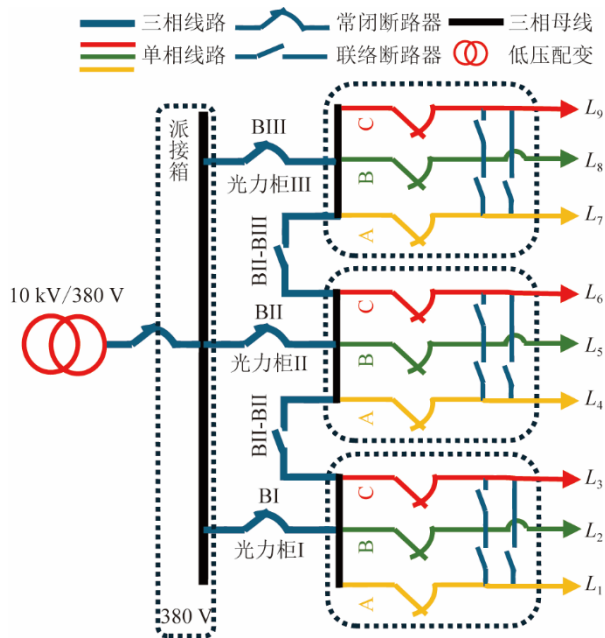


图 5 低压台区仿真测试系统

Fig. 5 Illustrative test system representing a low-voltage transformer-supplying district

基于雾计算负荷预测的低压开关重构自愈策略采用跨平台语言 Julia (Ver 1.10.4) 开发,并调用 Gurobi 求解混合整数二次规划问题。以下通过算例仿真论证所提雾计算负荷预测的精度,并展示和讨论开关重构自愈策略的应用效果。

4.2 负荷预测精度验证

截取开源数据文献[22]中 UTC 时间跨度为 2024 年 5 月 5 日至 2024 年 6 月 3 日“DEOK”地区 5 min 采样

间隔的负荷曲线,将时间戳相同的负荷数据取平均值后缩小为 $1/10^6$,用于模拟低压单相负荷(共计 8375 个数据点,如图 6 所示),用于验证本文所提雾计算超短期负荷预测方法的预测精度。以前置预测时间 4 h 为例,即 $T'=4 \text{ h}$,其他超参数设定包括 $t = 4T'$,初始权重 $\omega = [0.99, 0.01]$, $K_{\text{cls}}(\mathbf{x}) = 10$ 。总体而言, t 和 $K_{\text{cls}}(\mathbf{x})$ 越大,越有利于提高预测精度,但计算量也会随之增大。鉴于实际应用中的负荷样本特性和雾计算硬件计算能力存在差异,本文将 t 和 $K_{\text{cls}}(\mathbf{x})$ 视为超参数,可根据精度需要和计算效率通过试探法(trial and error)进行离线权衡。为了简化说明,将以下参与比较的算法分别命名为 M1、M2 和 M1&M2。其中, M1 方法代表原始的 k 邻域预测方法, M2 方法为改进的“基于 k 邻域样本替换预测方法”, M1&M2 是本文提出的“基于增量学习模型动态聚合的雾计算负荷预测方法”。




图 6 原始低压负荷模拟曲线

Fig. 6 The original low-voltage load simulating data series

仿真实验过程如下,首先选择原始低压负荷曲线的前 70% 作为初始训练样本,每次实验以当前训练样本最后 t 个数据作为特征样本,预测其后 T' 时段的负荷(共计 240 个预测点),并与实际值进行比较,求取 e_{MASE} 。一次仿真结束后,方法 M1 的训练样本向前步进一个数据点,而方法 M2 按照自身的误差出现越限情况,即 $e_{\text{MASE}} > 15$,判断是否有必要更新训练样本。方法 M1&M2 仅需要按照 M1 和 M2 的历史回溯误差表现根据式(2)更新权重。其后,特征样本也向前步进一个数据点,重复上述仿真实验过程,直至遍历到原始负荷曲线的最末尾数据。将上述完整实验过程中三种预测方法产生的 MASE 汇总于图 7。以 M1 的预测误差为基准参考,可以清晰地观察到, M2 方法因引入了增量学习的机制,训练样本随误差变化动态更新,某些时刻的预测性能优于 M1 方法,但

整体预测误差波动比较明显。造成二者预测误差表现差异显著的原因在于, M1 方法训练样本虽然也是动态变化的, 但只截取最新的负荷曲线, 不记忆早期样本特征, 而 M2 方法是以初始样本作为基准, 按照误差阈值有选择地替换训练样本, 力图维持有限样本的差异化。

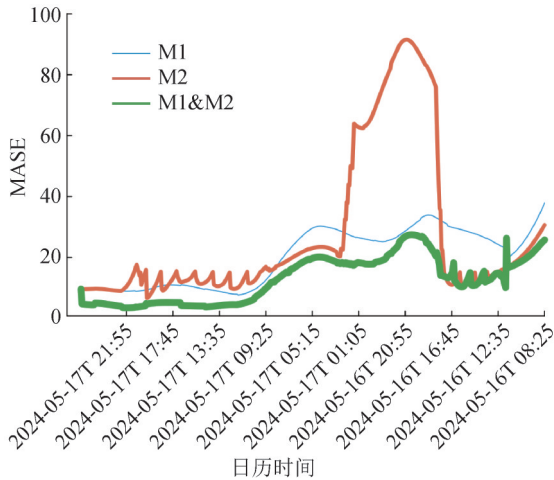


图 7 三种预测方法误差随预测时间前向步进的变化

Fig. 7 MASE of the three compared forecasting methods against stepping-forward time instances.

而 M1&M2 方法通过权重优化跟踪内嵌 M1 和 M2 的误差变化, 如图 8 所示, 始终赋予历史误差较小方法更高的权重, 整体的误差表现明显优于任何一种单一方法, 单点预测的最大绝对误差为 547.51 W。最后需要说明的是, M1 和 M2 方法均需维持 t 个样本, 所提方法 M1&M2 共需维持 $2t$ 个样本, 在本算例中, $2t = 8T' = 8 \times 240 = 1290$ 个, 内存占用甚低。

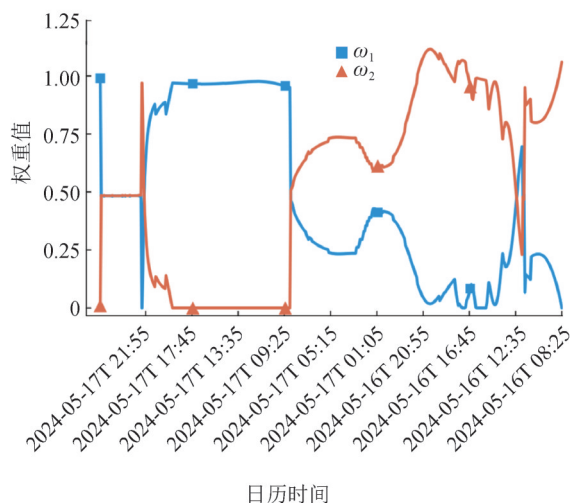


图 8 所提方法的优化权重随预测时间前向步进的变化

Fig. 8 Optimized weighting parameter values of the proposed method against stepping-forward time instances

再截取同一时段其他 8 个地区的负荷曲线, 重复上述仿真实验过程, 三种方法的预测误差汇总于图 9, 这 8 个地区缩写对应美国主要的电力公司或电网运营商, 多见于 PJM 电力市场的成员单位中。其中, AEP (American Electric Power) 是美国最大的电力公司之一, 总部位于俄亥俄州; AEP 子公司 AP (Appalachian Power) 主要服务弗吉尼亚州和西弗吉尼亚州的阿巴拉契亚地区, 而 ATSI (American Transmission Systems, Inc.) 则负责俄亥俄州及周边的输电网络。位于伊利诺伊州的 COMED (Commonwealth Edison) 是芝加哥地区的主要供电商, 隶属于 Exelon 集团; DAYTON (Dayton Power & Light Company, 现名 AES Ohio) 则是俄亥俄州代顿市的电力供应商。DOMINION (Dominion Energy) 总部在弗吉尼亚州, 是覆盖美国东部多个州的大型能源公司; DUQUESNE (Duquesne Light Company) 服务宾夕法尼亚州匹兹堡地区; 而 EKPC (East Kentucky Power Cooperative) 则是一家电力合作社, 主要为肯塔基州农村地区供电。

仿真结果进一步佐证了所提方法的精度优势, 且具有良好的鲁棒性。通过综合比较发现, 预测误差较大的时段与原始负荷突变时刻基本一致。究其原因, 本文所提的增量学习方法仅保存固定长度的近期历史样本, 无法从中预知突增突减幅度较大的负荷特征, 稍逊于长短期记忆网以递归方式保存更加久远样本特征的能力, 但却在计算和通信资源的消耗上占据明显优势。上述仿真实验结果表明, 本文所提的雾计算超短期负荷预测方法在占用较低存储和计算资源下, 能够通过增量学习的方式, 保持较高的负荷预测精度。

在计算时长方面, 现阶段主流的时序负荷预测方法, 如长短期记忆网、深度学习等, 需要足量的历史数据以及算力作为算法效率保障。鉴于雾计算存储空间和浮点运算能力方面的限制, 为实现算法的公平比较, 除文献[15]的方法外, 再选择一种对算力要求不高的极限学习机预测方法^[23]参与比较分析, 两种方法应用于滚动超短期负荷预测的 CPU 耗时以及 MASE 对比如图 10 和图 11 所示。可以看到, 所提方法的整体计算效率明显占优。建立这种优势的原因在于, 参与比较的极限学习机方法, 需要更多的矩阵运算, 且在增量学习过程中, 不能很好地区分当前负荷和早期负荷的时序特征。而所提方法的增量学习机制基于计算量较低的信息融合技术, 且引入了式(8)的轻量化矩阵更新范式, 所以在预测耗时和精度上都取得了更好表现。




图9 三种预测方法对于不同地区标识的负荷预测平均绝对无标度误差

Fig. 9 MASE's of the three compared forecasting methods applied to differentiated load curves by area identifiers

4.3 故障自愈仿真

图 5 中,假设短路发生在 2024 年 5 月 26 日 21:55,位置为派接箱和三个光力柜之间,上述 9 条负荷

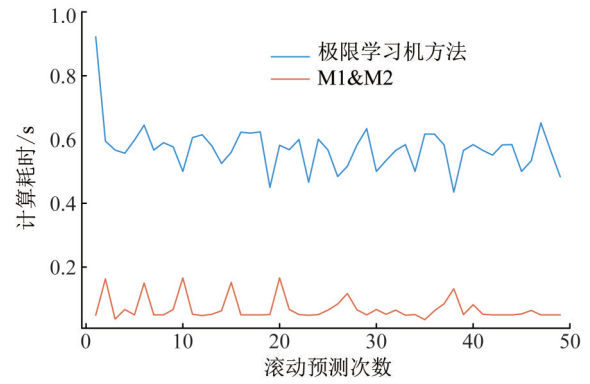


图 10 所提 M1&M2 方法与基于极限学习机的预测方法应用于滚动超短期负荷预测的 CPU 耗时对比

Fig. 10 CPU time consumption of the proposed M1&M2 against the extreme machine learning based method, both methods are applied to the rolling ultra short term load forecasts

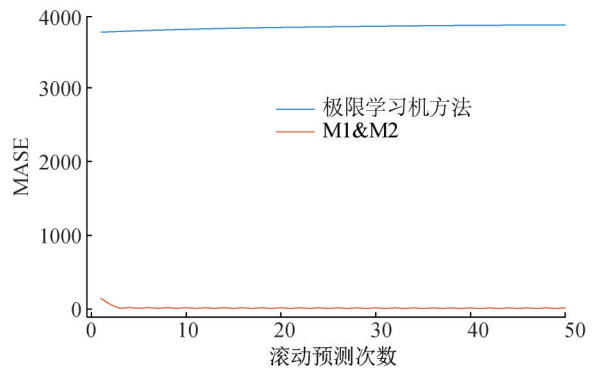


图 11 所提 M1&M2 方法与基于极限学习机的预测方法应用于滚动超短期负荷预测的 MASE 对比

Fig. 11 MASE of the proposed M1&M2 against the extreme machine learning based method, both methods are applied to the rolling ultra short term load forecasts

在对应时刻的预测曲线,分别对应故障下游的 L_1-L_9 故障自愈期间的负荷需求。所有联络开关故障自愈的初始时刻均处于断开状态,应用本文所提的“低压开关重构自愈恢复策略”,经离线环路识别,该拓扑共包含 32 767 个潜在环路。开关优化状态见表 1。从表中结果可见,总体上光力柜故障后,通过光力柜之间的三相母联开关(BI-BII 和 BII-BII)以及柜内的单相开关(L1-L2、L1-L3、L2-L3、L4-L5、L4-L6、L5-L6、L7-L8、L7-L9 以及 L8-L9)相互配合,可以完成单相负载的转供,并在保持网络辐射运行的同时,尽可能维持相间负载均衡。如光力柜 I 高压开关跳开后,从第 3 个恢复时段开始, A、B 两相负载因预测值较低,通过闭合 L1-L3、L2-L3,将其均衡给 C 相转带,同理,当故障造成光力柜 II 高压开关跳开时,因光力柜 BIII 的负载相对较重,算法没有选择闭合 BII-BII 的母联开关,仍然选择闭合 BI-BII,联络开关的决策状态

表 1 低压开关故障自愈重构优化结果

Table 1 Optimized operation status of low-voltage circuit breakers under the proposed self-healing strategy

开关编号	光力柜 I 故障				光力柜 II 故障				光力柜 III 故障			
	1 h	2 h	3 h	4 h	1 h	2 h	3 h	4 h	1 h	2 h	3 h	4 h
BI	○	○	○	○	-	-	-	-	-	-	-	-
BII	-	-	-	-	○	○	○	○	-	-	-	-
BIII	-	-	-	-	-	-	-	-	○	○	○	○
BI- BII	-	-	-	-	-	-	-	-	○	○	○	○
BII- BIII	○	○	○	○	○	○	○	○	-	-	-	-
BIA	-	-	○	○	-	-	○	○	-	-	-	-
BIB	-	-	○	○	-	-	○	○	-	-	-	-
BIC	-	-	-	-	-	-	-	-	-	-	-	-
BIIA	-	-	-	-	-	-	-	-	-	-	-	-
BIIB	-	-	-	-	-	-	-	-	-	-	-	-
BIIC	-	-	-	-	-	-	-	-	-	-	-	-
BIIIA	-	-	-	-	-	-	-	-	-	-	-	-
BIIBB	-	-	-	-	-	-	-	-	-	-	-	-
BIIBC	-	-	-	-	-	-	-	-	-	-	○	○
L1-L2	○	○	○	○	○	○	○	○	○	○	○	○
L1-L3	○	○	-	-	○	○	-	-	○	○	○	○
L2-L3	○	○	-	-	○	○	-	-	○	○	○	○
L4-L5	○	○	○	○	○	○	○	○	○	○	○	○
L4-L6	○	○	○	○	○	○	○	○	○	○	○	○
L5-L6	○	○	○	○	○	○	○	○	○	○	○	○
L7-L8	○	○	○	○	○	○	○	○	○	○	○	○
L7-L9	○	○	○	○	○	○	○	○	○	○	○	○
L8-L9	○	○	○	○	○	○	○	○	○	○	-	-

注：“○”表示该开关在对应时段处于闭合(投运)状态；“-”表示该开关在对应时段保持断开状态。

与光力柜 I 保持一致。同时注意到,如果不进行短期负荷预测,而采用常数负荷模型,开关决策结果在 1~4 h 内显然应维持不变,而表 1 的仿真结果表明,故障恢复期间的负荷波动对于开关的动作时序决策确会产生影响,这一现象与文献[3]的结论趋同,显示出短期负荷预测对于低压故障自愈的重要意义。

5 结 论

本文提出了一种基于雾计算架构的低压无源台区故障自愈恢复策略。该策略基于雾计算的通信架构,包含了增量学习模型动态聚合雾计算负荷预测方法,以较低的样本存储对故障期间的负荷功率进行快速预测。通过实际数据的仿真对比表明,所提雾计算负荷预测的平均绝对无标度误差主要受负荷突变的影响,可控制在 5~40 之间,相对误差处于 1%~8%。结合该方法对于低压台区节点负荷预测的能

力,建立了一种无低压线路参数的低压开关自愈恢复策略,通过算例验证了所提策略在故障隔离后,可有效完成单相负载的转供,并在保持网络辐射运行和避免设备过载的同时,尽可能维持相间负载均衡。

作为一种新兴的边缘计算架构,本文对雾计算架构下的低压配网故障重构问题开展了理论研究。雾计算的优势还有待结合软硬件条件进行持续而深入的探索,譬如,低压故障重构策略的具体执行,如何考虑数据安全、通信质量与环境干扰的交互问题是本文后继工作努力攻克的方向。

利益冲突声明 (Conflict of Interests):

所有作者声明不存在利益冲突。

作者贡献声明 (Authors' Contributions):

刘音进行了研究设计和项目统筹;桂媛完成实验并分析数据;刘若溪参与了数据收集和初步分析;

宋一凡协助实验操作和数据整理;高扬参与了文献调研和资料收集;杨雯沁协助论文写作和格式规范;王越参与了论文修订和校对工作。所有作者均阅读并同意了论文终稿内容

6 参考文献

- [1] 王浩成, 宋厚营, 于佳. 新型电力系统终端通信网优化方案研究[J]. 山东电力技术, 2024, 51(2): 56-66.
WANG Haocheng, SONG Houying, YU Jia. Research on optimization scheme for new power system terminal communication network[J]. Shandong Electric Power, 2024, 51(2): 56-66.
- [2] 张弘喆, 丛伟, 王瑞梅, 等. 基于Bhattacharyya系数和Pearson相关系数的交直流混联电网电压波形相似度纵联保护方法[J]. 山东电力技术, 2024, 51(12): 19-26.
ZHANG Hongzhe, CONG Wei, WANG Ruimei, et al. Longitudinal protection method of AC/DC hybrid power grid for voltage wave similarity using Bhattacharyya coefficient and Pearson correlation coefficient[J]. Shandong Electric Power, 2024, 51(12): 19-26.
- [3] 袁林涛, 孙媛媛, 刘振, 等. 基于潮流变向点的配电网低压分布式光伏无功影响及优化[J]. 山东电力技术, 2023, 50(8): 11-19, 41.
YUAN Lintao, SUN Yuanyuan, LIU Zhen, et al. Influence and optimization of low-voltage distributed photovoltaic reactive power in active distribution network based on the power flow reverse point[J]. Shandong Electric Power, 2023, 50(8): 11-19, 41.
- [4] 范馨予, 黄媛, 吴疆, 等. 考虑源网荷储协同优化的配电网韧性提升策略[J]. 电力建设, 2023, 44(4): 63-73.
FAN Xinyu, HUANG Yuan, WU Jiang, et al. Resilience promotion strategy for distribution network considering source-network-load-storage coordination [J]. Electric Power Construction, 2023, 44(4): 63-73.
- [5] 张晓丹. 基于深度学习的低压台区故障隔离及自愈调度方法[J]. 电脑编程技巧与维护, 2024(2): 128-130.
ZHANG Xiaodan. Fault isolation and self-healing scheduling method for low-voltage substation based on deep learning [J]. Computer Programming Skills & Maintenance, 2024(2): 128-130.
- [6] 王长伟, 招永锦, 吴晗, 等. 考虑新型配电元件多状态可靠性模型的配电网可靠性评估[J]. 供用电, 2023, 40(4): 74-82.
WANG Changwei, ZHAO Yongjin, WU Han, et al. Reliability evaluation of distribution network considering multi-state reliability model of new distribution components [J]. Distribution & Utilization, 2023, 40(4): 74-82.
- [7] 沈兴杰, 陈沛, 高群, 等. 考虑多种故障场景的柔性互联低压配电网故障恢复方法[J]. 机械与电子, 2024, 42(3): 17-25.
SHEN Xingjie, CHEN Pei, GAO Qun, et al. A fault recovery method for flexible interconnected low-voltage distribution network considering multiple fault scenarios [J]. Machinery & Electronics, 2024, 42(3): 17-25.
- [8] 周燕, 刘卫民, 陈帆, 等. 不同光伏渗透率下考虑需求响应的配电网储能双层规划[J]. 高压电器, 2024, 60(10): 64-77.
ZHOU Yan, LIU Weimin, CHEN Fan, et al. Bi-level planning of energy storage in distribution network considering demand response under different penetration rates of photovoltaic [J]. High Voltage Apparatus, 2024, 60(10): 64-77.
- [9] 王尚斌, 苑丽伟, 方莹, 等. 计及新能源波动的分布式储能分层控制策略[J]. 山东电力技术, 2024, 51(9): 74-84.
WANG Shangbin, YUAN Liwei, FANG Ying, et al. Distributed energy storage layered control strategy considering renewable energy fluctuations[J]. Shandong Electric Power, 2024, 51(9): 74-84.
- [10] 李军, 梁宵, 梁嘉城, 等. 基于ARIMA-GM改进算法的建筑负荷预测[J]. 电气自动化, 2023, 45(6): 59-61.
LI Jun, LIANG Xiao, LIANG Jiacheng, et al. Building load forecasting based on improved ARIMA-GM algorithm [J]. Electrical Automation, 2023, 45(6): 59-61.
- [11] 叶永盛, 徐燕龙, 李阳, 等. 基于相似周和模态分解的融合模型电动汽车负荷预测[J]. 电网技术, 2025, 49(5): 1910-1919.
YE Yongsheng, XU Yanlong, LI Yang, et al. Electric vehicle load forecasting with fusion model based on similar weeks and mode decomposition [J]. Power System Technology, 2025, 49(5): 1910-1919.
- [12] 李丽芬, 张近月, 曹旺斌, 等. 基于双重注意力时间卷积长短期记忆网络的短期负荷预测[J]. 系统仿真学报, 2025, 37(8): 2004-2015.
LI Lifen, ZHANG Jinyue, CAO Wangbin, et al. Short-term load forecasting based on dual-attention temporal convolutional long short-term memory network [J]. Journal of System Simulation, 2025, 37(8): 2004-2015.
- [13] 孟衡, 张涛, 王金, 等. 基于多尺度时空图卷积网络与Transformer融合的多节点短期电力负荷预测方法[J]. 电网技术, 2024, 48(10): 4297-4311.
MENG Heng, ZHANG Tao, WANG Jin, et al. Multi-node short-term power load forecasting method based on multi-scale spatiotemporal graph convolution network and Transformer [J]. Power System Technology, 2024, 48(10): 4297-4311.
- [14] LIU Y S, LIANG Z C, LI X. Enhancing short-term power load forecasting for industrial and commercial buildings: a hybrid approach using TimeGAN, CNN, and LSTM [J]. IEEE Open Journal of the Industrial Electronics Society, 2023, 4: 451-462.
- [15] MELGAR-GARCÍA L, GUTIÉRREZ-AVILÉS D, RUBIO-ESCUADERO C, et al. A novel distributed forecasting method based on information fusion and incremental learning for streaming time series[J]. Information Fusion, 2023, 95: 163-173.
- [16] MASSRUR H R, FOTUHI-FIRUZABAD M, DEHGHANIAN P, et al. Fog-based hierarchical coordination of residential aggregators and household demand response with power distribution grids: part I: solution design [J]. IEEE Transactions on Power Systems, 2025, 40(1): 85-98.
- [17] KERCKHOVE S, KOIRALA A, D' HULST R, et al. Reconfiguration to increase photovoltaic hosting capacity in low voltage distribution grids [C]//2023 International Conference on Smart Energy Systems and Technologies (SEST). IEEE, 2023: 1-6.
- [18] HYNDMAN R J, KOEHLER A B. Another look at measures of forecast accuracy [J]. International Journal of Forecasting, 2006, 22(4): 679-688.
- [19] 张伟骏, 李智诚, 陈大玮, 等. 配网侧分布式储能系统的随机优

化配置和选址方法[J]. 高压电器, 2023, 59(7): 125-135.

ZHANG Weijun, LI Zhicheng, CHEN Dawei, et al. Stochastic optimal configuration and site selection method of grid-side distributed energy storage system [J]. High Voltage Apparatus, 2023, 59(7): 125-135.

[20] DEKA D, KEKATOS V, CAVRARO G. Learning distribution grid topologies: a tutorial[J]. IEEE Transactions on Smart Grid, 2024, 15(1): 999-1013.

[21] MAHDAVI M, ALHELOU H H, GOPI P, et al. Importance of radiality constraints formulation in reconfiguration problems [J]. IEEE Systems Journal, 2023, 17(4): 6710-6723.

[22] PJM Interconnection. Data miner 2-five minute load forecast [DB/OL]. (2024-07-19)[2024-12-19]. https://dataminer2.pjm.com/feed/very_short_load_frctst.

[23] CHUPONG C, PLANGKLANG B. Incremental learning model for load forecasting without training sample [J]. Computers, Materials & Continua, 2022, 72(3): 5415-5427.

收稿日期: 2025-01-16 修回日期: 2025-03-06

作者简介:

刘音(1972),男,硕士,高级工程师,主要从事电力设备运行、检修分析与管理工作;

桂媛(1988),女,硕士,高级工程师,主要从事配电网智能诊断技术研究工作;

刘若溪(1984),男,博士,高级工程师,主要从事配电网设备运维、自动化等技术研究工作;

宋一凡(1992),女,硕士,高级工程师,主要从事配电网自动化与运行控制技术研究;

高杨(1991),男,硕士,工程师,主要从事电力工程组织与管理、设备运行工作;

杨雯沁(2001),女,硕士研究生,主要研究方向为低压配电网拓扑识别以及配电网的智能化应用与发展;

王越(1982),男,工学博士,副教授,通信作者,博士生导师,从事电力系统可靠性与运行风险管控、非线性优化控制与智能决策研究, E-mail:wyue@cau.edu.cn。

(编辑 魏希辉)

广告目次

封二 2026年《电力建设》期刊征订通知

封三 节能低碳公益广告

封底 浙江华云电力工程设计咨询有限公司

前插1 国网电力科学研究院武汉南瑞有限责任公司