

基于SSA-RF算法和余弦相似度的主动配电网 两阶段故障定位

罗翔,林栋,张振宇,王珏莹,蔡智萍,林若寅

(国网福建省电力有限公司电力科学研究院,福建 福州 350007)

摘要:为解决传统基于群智能优化算法的主动配电网故障定位方法执行效率低、容错性差的问题,提出一种基于SSA-RF算法与余弦相似度的主动配电网两阶段故障定位方法。首先,利用故障电流状态方程,通过单点及多点故障的随机模拟构建目标配电网的故障特征库;随后,提出一种融合麻雀搜索算法(SSA)的改进随机森林(RF)分类模型,通过模型的训练建立故障电流方向矩阵与故障点所在线路区段的高维映射关系,训练后的SSA-RF分类模型可用于故障线路区段的初步定位;最后,对定位到的故障区段,计算区段内相邻分段线路故障电流方向信息的余弦相似度,通过余弦相似度的突变点对故障线路进行精确定位。以修改后的IEEE 33节点测试配电网为例进行仿真实验,结果表明,所提两阶段故障定位方法相较于基于群智能优化算法的故障定位方法,具有更高的准确率和抗干扰性。

关键词:主动配电网;故障定位;两阶段模型;随机森林;余弦相似度

中图分类号:TM73 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqcd25981

Two-stage Fault Localization for Active Distribution Networks Based on SSA-RF Algorithm and Cosine Similarity

LUO Xiang, LIN Dong, ZHANG Zhenyu, WANG Jueying, CAI Zhiping, LIN Ruoyin

(State Grid Fujian Electric Power Research Institute, Fuzhou 350007, Fujian, China)

Abstract: To tackle the issues of low execution efficiency and poor fault tolerance in traditional fault localization methods for active distribution networks using swarm intelligence optimization algorithms, a two-stage fault location method was introduced based on the SSA-RF algorithm and cosine similarity. Firstly, the fault current state equation was used to create a fault feature database of the target distribution network by stochastically simulating single-point and multi-point faults. Next, an enhanced random forest (RF) classification model that integrates the sparrow search algorithm (SSA) was introduced. Through model training, a high-dimensional mapping correlation between the fault current direction matrix and the line segment containing the fault point was established. This trained SSA-RF classification model was utilized for the initial localization of the faulted line segment. Subsequently, cosine similarity of fault current direction information of neighboring segmented lines within the identified segment was computed for precise fault location. Experimental results on the modified IEEE 33-node test distribution network demonstrate that the proposed two-stage fault localization method achieves superior accuracy and anti-interference capabilities compared to fault location methods based on swarm intelligent optimization algorithms.

Key words: active distribution network; fault localization; two-stage model; random forest (RF); cosine similarity

随着屋顶光伏、小型风力发电机、燃料电池等分布式电源(distributed generation, DG)的持续并网,配电系统的结构愈加趋向于复杂化和智能

化^[1]。主动配电网的故障定位是配电自动化的核心组成部分之一,在配电自动化系统中,快速准确地识别和定位故障点对电力的连续供应和系

基金项目:国网福建省电力有限公司科技项目(521304230006)

作者简介:罗翔(1987—),男,硕士,高级工程师,主要研究方向为电力系统及其自动化,Email:luo_xiang_sgcc@163.com

统的稳定运行至关重要^[2]。

作为配电网线路故障检测与遥控单元,馈线终端单元(feeder terminal unit, FTU)可及时获取所在分段线路的故障发生时间、故障历时、故障电流方向等信息。考虑到DG并网后,对所在线路上下游故障电流有助增或衰减作用,如何在兼顾DG并网影响的前提下,充分挖掘FTU检测到的故障电流信息,提出适应主动配电网的故障定位方法,是当下的研究热点之一。由于DG对故障电流幅值的影响较为复杂,现有相关研究大都利用FTU检测到的故障电流方向信息,通过构造优化模型并利用群智能优化算法求解以实现故障线路的定位。基于群智能优化算法的故障定位方法以FTU检测到的故障电流方向信息和期望故障电流方向信息间偏差最小为目标构建优化模型,通过群智能算法对模型进行迭代求解,获取对应的故障位置信息^[3]。该方法模型定位准确度主要取决于所选用群智能算法本身性能,目前在主动配电网故障定位中常用的群智能算法主要包括蚁群算法^[4]、粒子群算法^[5]、遗传算法^[6]、免疫算法^[7]等。例如,文献[8]提出将分层模型与改进免疫算法相结合的主动配电网故障定位方法,上层对故障区段进行定位,下层对故障线路进行二次精确定位,该方法虽有效降低了搜索维度,但泛化能力不足;文献[9]采用记忆池与免疫算法的方法,在发生信息畸变情况下仍能保证较好的准确率,但对网络结构较为依赖,当现实情况与模型之间存在较大差距时准确率不高;文献[10]借鉴“黑盒方法”将复杂配电网简化为多个二端口网络,利用改进的秃鹰搜索算法提升故障定位的全局搜索能力,但面对多点故障时,难以兼顾定位的精度和速度;文献[11]在求解故障定位模型时,首先利用天牛须搜索算法生成高质量遗传种群,再融合改进遗传算子以提升求解算法的鲁棒性,具有较高的准确率,但在复杂问题求解过程中易陷入局部最优;文献[12]通过忽略不含DG的线路区段来降低故障定位时的计算维度,但缺少对于大规模DG接入下配电网网络动态重构问题的考虑,因此该方法的普适性较差;文献[13]引入多种群遗传算法对解空间协同搜索,兼顾局部最优解与全局最优解,具有较高的收敛速率,但在处理大规模配电网时需要更多的计算资源和更长的运行时间;文献[14]将矩阵算法与群智能算法相结合,利用矩阵算法对故障进行快速

定位并校验,若校验不通过则利用灰狼算法对可疑故障点进行二次定位,具有良好的容错性和计算速度,但两种算法之间的协调配合较为困难。

由此可见,现有基于群智能算法的故障定位方法普遍存在算法收敛速度慢、准确性差和容错率低等问题,难以适用于多源主动配电网。为实现主动配电网故障的快速定位,保障其安全可靠运行,本文结合DG对故障电流方向的影响,提出一种基于SSA-RF算法与余弦相似度的主动配电网两阶段故障定位方法。首先,基于目标主动配电网运行拓扑,开展单点及多点故障的随机仿真模拟,结合故障电流状态方程构建目标配电网的故障特征库;随后,通过故障特征库完成对SSA-RF模型的离线训练,其中,随机森林(random forest, RF)算法用于建立故障电流方向矩阵和故障区段标签的高维映射关系,麻雀搜索算法(sparrow search algorithm, SSA)用于优化RF的决策树个数 T 和决策树层数 D ,以提高RF的泛化能力,该模型用于配电网故障区段的初步定位;最后,针对定位到的各故障区段,计算相邻线路经FTU检测到的故障电流方向信息的余弦相似度,通过余弦相似度突变位置实现故障区段内故障线路的精确定位。所提故障定位方法只需通过有限的离线故障仿真模拟即可建立故障电流方向矩阵和故障区段的映射关系,训练后的SSA-RF模型具有在线调用算力需求小、容错性强的特点,避免了基于群智能优化算法的故障定位方法可扩展性差、计算速度慢、抗干扰能力差等缺点。

1 两阶段故障定位策略总体框架

两阶段故障定位策略以FTU检测到的故障电流方向信息及DG并网状态信息为主要依据,经由故障定位功能模块实现对故障线路的识别,总体部署图如图1所示。

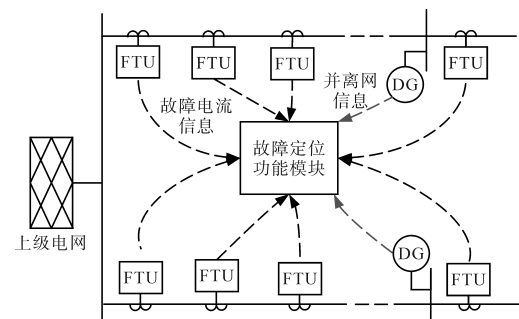


图1 两阶段故障定位策略实际部署图

Fig.1 Deployment diagram of two-stage fault localization strategy

考虑实际主动配电网线路分支较多、运行方式复杂多样,为避免传统故障定位方法求解速度慢、在线故障定位时效性差的问题,本文采用两阶段的故障定位方法,由第一阶段故障区段定位和第二阶段故障区段内具体故障线路的精确定位两部分共同构成,其总体策略框架如图2所示。

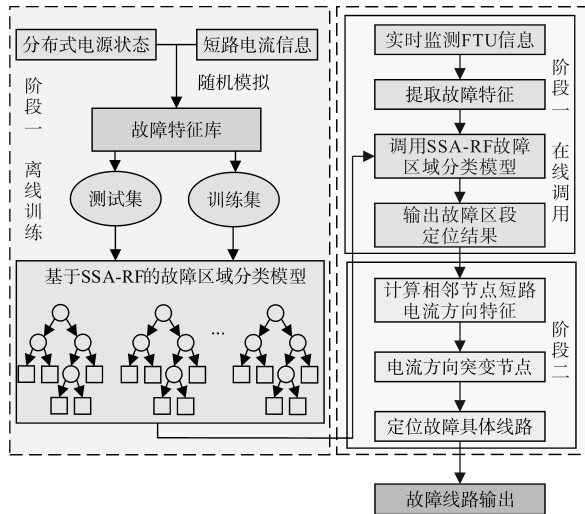


图2 两阶段故障定位总体策略框架

Fig.2 Diagram of the two-stage fault localization strategy

其中,阶段一由分类模型的离线训练和在线调用两部分构成,首先对目标区域配电网开展单点故障和多点故障场景的随机仿真模拟,结合故障电流方向判别函数,构建故障特征库,在此基础上完成对SSA-RF分类模型的离线训练,进而确立FTU检测故障电流方向信息与故障所在区段编号的高维映射关系;随后,从FTU实时监测信息中提取目标配电网的故障电流方向特征向量,并作为输入传递给训练好的SSA-RF模型,由模型快速识别故障发生区段,实现故障的初步定位。随后,阶段二针对阶段一确定的故障区段,计算每个分段线路与其相邻线路之间故障电流方向信息的余弦相似度,通过识别故障电流方向突变点,进而确定故障分段线路的具体位置。这种两阶段的故障定位策略既保证了定位的时效性,又提升了定位的准确性。

2 主动配电网故障特征库构建

故障特征提取阶段,针对主动配电网中的短路故障,聚焦于故障电流方向这一核心特征,通过FTU实时监测故障信息特征,获取短路故障发生时各分段线路故障电流流向;同时,考虑到主动配电网中DG的存在,还需考虑其在短路故障

中对其所在支路乃至整个配电网故障电流方向的影响。因此,为充分挖掘不同故障情况下主动配电网各FTU监测点故障电流方向特征与故障点位置的相关性,需对目标配电网开展单点、多点故障的随机仿真模拟,利用故障电流方向判别函数解析故障发生时电流方向变化规律,获取故障样本,构建包含多元故障状况的故障电流方向特征库,为下一步SSA-RF分类模型的离线训练提供数据样本支撑。作为故障特征库构建的关键环节,本节重点介绍用于故障特征提取的配电网线路故障状态指标和故障电流方向判别函数。

2.1 配电网线路故障状态指标

当配电网中某一区段发生故障时,FTU立即响应,通过内置的电流、电压传感器和其他检测元件实时捕捉故障时刻的电气参数变化,控制中心接收到这些信息后进行进一步的故障确认、故障定位。

主动配电网中任意线路*i*的故障状态由指标 S_i 表示,当 $S_i=0$ 时表示线路*i*无故障;当 $S_i=1$ 时表示线路*i*有故障发生。考虑到DG的并/离网状态对故障电流方向的影响,由指标 S_{gi} 表示线路*i*处DG的并/离网状态。当线路*i*处不存在DG接入或所接入DG为离网状态,则 $S_{gi}=0$;否则, $S_{gi}=1$ 。

当DG接入配电网后,DG所在支路上流过的故障电流方向趋向复杂化。而传统配电网故障电流方向仅使用0和1表示,无法反映DG向故障点短路电流的注入作用。因此,本文用指标 SL_i 表示线路*i*流过的故障电流方向,当线路*i*处检测到的故障电流是由系统电源侧流向线路*i*所在支路末端时为正向故障电流方向(即 $SL_i=1$),反之,则为负向故障电流方向(即 $SL_i=-1$);若未检测到故障电流,则 $SL_i=0$ 。针对含DG接入的主动配电网,当线路*i*下游有DG接入时,若其上游线路发生故障,则 $SL_i=-1$,若其下游线路发生故障,则 $SL_i=1$;当线路*i*上游有DG接入时,若其上游线路发生故障,则 $SL_i=0$,若其下游线路发生故障,则 $SL_i=1$ 。因此,线路*i*故障电流方向只受其下游DG的影响。

由此可见,主动配电网任意线路*i*流过的故障电流方向由电网拓扑、故障点所在位置以及DG的并离网状态三个因素共同决定。

2.2 故障电流方向判别函数

为进一步量化电网拓扑、故障点所在位置和DG并离网状态对任意线路*i*故障电流方向指标 SL_i 的影响,本节提出了故障电流方向判别函数,

如下式所示:

$$\begin{cases} SL_i = SL_{dw,i} - SG_i(1 - SL_{dw,i})SL_{up,i} \\ SL_{dw,i} = \prod_i^{m_{1,i}} S_i \\ SL_{up,i} = \prod_i^{m_{2,i}} S_i \\ SG_i = \prod_i^{n_i} S_{g,i} \end{cases} \quad (1)$$

式中: $SL_{dw,i}, SL_{up,i}$ 分别为线路*i*下游区域和上游区域故障状态(若故障,则为1,否则为0); SG_i 为线路*i*下游是否有DG并网(若有DG并网则为1,否则为0); $m_{1,i}, m_{2,i}$ 分别为线路*i*下游分段线路总数目和线路*i*上游分段线路总数目; n_i 为线路*i*下游DG的总数目; Π 为逻辑或。

对于任意线路*i*,从其所在位置到系统电源侧为上游,从其所在位置到线路*i*所在分支末端为下游。

借助式(1),可实现目标主动配电网复杂运行工况下单点、多点短路故障的大规模仿真模拟以及各故障下故障电流方向信息的快速提取,提高了主动配电网故障特征库构建的效率。

3 主动配电网两阶段故障定位

3.1 阶段一:基于SSA-RF算法的故障区段定位

RF算法是一种集成学习算法,通过构建并结合多个随机生成的决策树来提高模型的预测能力和稳定性,具有抗过拟合、并行化训练等优点,广泛应用于分类、回归、特征选择等问题。

由于RF算法通常采用经验设定的参数值,如决策树数量和特征数,并不适用于所有数据集,导致模型性能及泛化能力受到很大程度的限制,针对这些问题,本文采用SSA寻找最优的决策树数目*T*和树的层数*D*。SSA是由薛建凯^[15]等人在2020年提出的一种新型智能优化算法,麻雀在觅食过程中被分为发现者、加入者和侦察者,根据角色特征定制相应的位置更新规则。

发现者的个体位置更新公式如下式所示:

$$X_{ij}^{t+1} = \begin{cases} X_{ij}^t \cdot \exp\left(\frac{-i}{\alpha \cdot t_{\max}}\right) & R < ST \\ X_{ij}^t + Q \cdot L & R \geq ST \end{cases} \quad (2)$$

式中: t 为当前迭代次数; t_{\max} 为最大迭代次数; X_{ij}^t 为第*i*个麻雀在第*j*维中的位置; α, Q 为随机数; R, ST 分别为预警值和安全值; L 为所有元素为1

的 $1 \times d$ 阶矩阵。

加入者的个体位置更新公式如下式所示:

$$X_{ij}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{ij}^t}{t^2}\right) & i > n/2 \\ X_p^{t+1} + |X_{ij}^t - X_p^{t+1}| \mathbf{A}^+ \cdot \mathbf{L} & \text{其他} \end{cases} \quad (3)$$

式中: X_{worst} 为全局最差位置; X_p 为发现者最优位置; \mathbf{A} 为 $1 \times d$ 阶矩阵,其元素随机为1或-1,且 $\mathbf{A}^+ = \mathbf{A}^T(\mathbf{A}\mathbf{A}^T)^{-1}$ 。

侦察者的个体位置更新公式如下式所示:

$$X_{ij}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta |X_{ij}^t - X_{\text{best}}^t| & f_i > f_g \\ X_{ij}^t + K \frac{|X_{ij}^t - X_{\text{worst}}^t|}{(f_i - f_w) + s} & f_i = f_g \end{cases} \quad (4)$$

式中: X_{best} 为当前全局最优位置; β 为步长控制参数,值为服从(0,1)正态分布的随机数; K 为 $[-1,1]$ 内的随机数; f_i, f_g, f_w 分别为当前麻雀的个体适应度、全局最优、全局最差适应度; s 为非0最小常量。

利用每个种群中麻雀个体表征RF的决策树数量*T*和层数*D*,将分类性能作为适应度函数进行迭代优化,分别基于式(2)~式(4)更新发现者、加入者、侦察者的个体位置,三者协同完成解空间搜索。当达到最大迭代次数 t_{\max} 时,输出全局最优的超参数组合并重构RF模型,最终通过测试集验证SSA-RF模型的预测性能,SSA-RF模型超参数自适应优化流程图如图3所示。

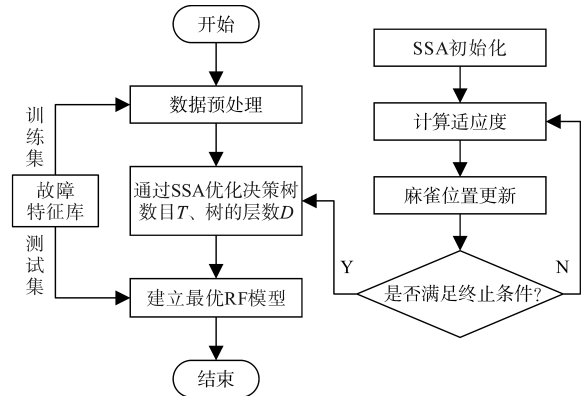


图3 SSA-RF模型超参数自适应优化流程图

Fig.3 Flowchart of adaptive optimization of hyperparameters for SSA-RF model

优化后的SSA-RF模型可通过在线调用的方式用于故障区段的快速定位。具体为:将FTU实时监测到的故障电流方向信息输入到训练好的SSA-RF模型中,RF中每棵决策树依据各自构建原则,分别利用故障电流的方向特性独立解析,对故障发生的具体区段进行判断,最终经由多数

表决机制,所有的决策树共同投票输出故障区段。

3.2 阶段二:基于余弦相似度的故障线路定位

余弦相似度是衡量两个非零向量之间相似度的数学方法,其原理如图4所示。通过计算两个高维向量的夹角余弦值来评估它们的方向是否相近,广泛应用于诸如文档相似度计算、图像分析等领域。

n 维向量 $A=(A_1,A_2,\dots,A_n)$ 和 $B=(B_1,B_2,\dots,B_n)$ 的余弦相似度计算公式如下:

$$\cos(\mathbf{A},\mathbf{B}) = \frac{\sum_{i=1}^n A_i \cdot B_i}{\sqrt{\sum_{i=1}^n A_i^2} \cdot \sqrt{\sum_{i=1}^n B_i^2}} \quad (5)$$

为避免式(5)分母为零,将未流过故障电流的线路状态指标 SL_i 设为 $-\varepsilon$, ε 为较小的常数。余弦相似度的结果严格位于闭区间 $[-1, 1]$ 内,值越接近 1,表示两个向量越正相关,值越接近 -1,则表示两个向量越负相关,值为 0 表示两个向量无关。未发生故障的两条相邻线路各自 FTU 检测到的故障电流方向相同,对应的余弦相似度为 1。若相邻两条线路中任何一条发生故障,无论 DG 是否并网,求得的余弦相似度均为 -1。借助该方法,可在阶段一故障区段定位的基础上,对阶段二具体故障线路进行精确定位。




图4 余弦相似度原理图

Fig.4 Principle diagram of cosine similarity




图5 测试电网拓扑图

Fig.5 Test power grid topology

4 仿真算例

4.1 仿真算例基本信息

为验证本文提出方法的准确性,选取修改后的 IEEE 33 节点作为测试配电网,其电网拓扑如图 5 所示。该测试电网中共有三个 DG 接入, DG1~ DG3 的并/离网状态分别由开关 K1~K3 控制,开关 K1~K3 的四种 0-1 状态对应四种故障场景;同时,当任意 DG 所在支路发生短路故障时,该 DG 会向故障点注入短路电流。此外,除去主干线路 L1 和 L2 外,剩余线路共被分为 B1~B5 五个区域,各区域包含的线路如图 5 所示。仿真环境为 Windows 64 位操作系统,处理器 Inter (R) Core(TM) i7-7700 CPU @3.6GHz 64GB 内存。

故障特征库通过在五个区域内随机产生单点和多点故障,批量生成 496 组故障样本。依据故障线路所在区段,所有故障特征样本分为 15 种不同类型,由标签 C1~C15 表示,各类故障所在区段编号组合及对应线路集如表 1 所示。

表1 基于线路区段的故障分类

Tab.1 Fault classification based on section of line

标签	区段	线路集	标签	区段	线路集
C1	B1	L30~L33	C9	B1, B5	L6~ L17, L30~ L33
C2	B2	L18~L21	C10	B2, B3	L3~ L5, L18~ L21
C3	B3	L3~L5	C11	B2, B4	L18~ L21, L22~ L29
C4	B4	L22~L29	C12	B2, B5	L6~ L17, L18~ L21
C5	B5	L6~L17	C13	B3, B4	L3~ L5, L22~ L29
C6	B1, B2	L18~ L21, L30~ L33	C14	B3, B5	L3~ L5, L6~ L17
C7	B1, B3	L3~ L5, L30~ L33	C15	B4, B5	L6~ L17, L22~ L29
C8	B1, B4	L22~ L29, L30~ L33		—	—

随后结合故障电流方向判别函数,即可得到各故障场景下对应的故障电流方向矩阵,构建包




图7 故障线路L5和L25的余弦相似度梯度图

Fig.7 Gradient map of cosine similarity for faulty lines L5 and L25

4.2.3 算法对比

考虑到主动配电网故障定位可通过群智能算法或机器学习算法实现,前者通过构建优化模型及其迭代求解来实现故障定位,属于单层故障定位方法,后者则通过构建故障电流方向信息与对应故障区段标签的高维映射关系来实现故障定位,采用本文所提两阶段故障定位框架。为验证本文所提故障定位方法相比基于群智能优化算法故障定位方法以及基于机器学习算法故障定位方法的优越性,分别选取包括粒子群算法(PSO)、灰狼优化算法(GWO)^[16]和鲸鱼优化算法(WOA)^[17]在内的群智能优化算法,以及包括支持向量机(SVM)、BP神经网络(BPNN)、长短时记忆网络(LSTM)、极限核学习机(ELM)在内的机器学习算法作为对比对象。基于群智能优化算法的故障定位方法以FTU量测的故障电流方向为输入信息,构建下式所示目标函数^[18],通过该模型的迭代求解获取故障线路位置信息。

$$\min f = \sum_{i=1}^N |SL_i - SL_i^*| + 0.5 \sum_{i=1}^N |S_i| - 100 \quad (6)$$

式中: SL_i, SL_i^* 分别为线路*i*所安装FTU实际检测到的故障电流方向和期望故障电流方向,期望故障电流方向由式(1)计算获取。

基于机器学习算法的故障定位方法借助目标配电网的故障特征库完成分类模型的离线训练,通过在线调用训练好的分类模型开展故障线路的区段定位。为此,本文采用交叉验证方法,将故障样本库中数据集拆分为训练集与测试集,其中,数据集的70%作为训练集,用于分类器的训练,而剩余样本数据集作为测试集,用于对模型的准确率评价,为了减少模拟环境对仿真结果的影响,每个故障定位模型重复运行20次,最终得到准确率的中位值作为该模型的最终准确率。

本文所提两阶段故障定位方法中阶段一SSA-RF模型测试得到的混淆矩阵如图8所示,图8中对角线数字表示各预测故障分类与真实故障分类相同时对应的样本数目,预测故障分类坐标轴各分类标签对应的百分比值表示被正确预测

为该故障分类的样本数目占被预测为该故障分类样本总数目的百分比;真实故障分类坐标轴各分类标签对应的百分比值表示被正确预测为该故障分类的样本数目占该故障分类真实样本总数目的百分比。由图8可知,SSA-RF模型可实现所有故障样本的准确定位。

100%	C1	3																	
100%	C2		3																
100%	C3			2															
100%	C4				11														
100%	C5					23													
100%	C6						5												
100%	C7							4											
100%	C8								10										
100%	C9									14									
100%	C10										4								
100%	C11											10							
100%	C12												14						
100%	C13													7					
100%	C14															11			
100%	C15																	29	
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15			
		100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
		预测故障分类																	

图8 15种故障区段测试集混淆矩阵

Fig.8 Confusion matrix of 15 faulty section test sets

表5中进一步列出了本文所提方法与基于群智能优化算法以及基于机器学习算法故障定位方法在测试电网单点及多点故障线路定位时的准确率和在线定位所需时间上的性能对比结果。由表5可知本文所提方法故障定位准确率为100%,在线故障定位时间小于1s。基于机器学习的故障定位方法准确率在76%~97%,整体高于基于群智能优化算法的故障定位方法,且由于采用了分类模型的离线训练,基于机器学习的故障定位方法在线故障定位时间均在2s以内。相比之下,基于群智能算法的故障定位方法准确率在73%~77.4%,且由于其在线故障定位需要通过对优化模型的在线迭代计算实现,对应的在线故障定位时间在58~130s。

由此可见,本文所提的两阶段故障定位方法在对所选测试配电网故障定位的准确率和在线定位时间有明显的优势,可在保证故障定位准确率的同时,实现故障线路的快速定位。相较于BPNN,SVM,LSTM和ELM等常见分类模型,本文所提出的SSA-RF分类模型由于具备超参数自适应优化能力,泛化能力更强,在对所选测试配电网的故障线路识别时具有更高的准确率和较低的在线识别时间,综合性能最优。

为进一步直观对比本文所提方法相对基于

表5 故障线路定位结果对比分析表

Tab.5 Comparison analysis table of faulty circuit localization results

故障定位方法	分类结果			
	正确识别数/个	准确率/%	在线故障定位时间/s	
群智能优化算法	PSO	362	73.0	130.20
优化算法	GWO	384	77.4	58.46
	WOA	372	75.0	65.74
机器学习	SVM	446	89.90	0.054
习算法	BPNN	379	76.51	1.834
	LSTM	483	97.38	0.239
	ELM	484	97.58	0.049
本文方法		496	100	0.264

群智能优化算法故障定位方法在准确率和在线故障定位算力需求方面的优势,图9和图10展示了单点和多点故障下故障定位优化模型目标函数 f 的收敛曲线。对比分析得知,群智能优化算法对故障定位优化模型的求解性能取决于算法本身,WOA和GWO的收敛速度要显著快于PSO,且当发生多点故障时,PSO更易陷入局部最优,进而导致故障线路误判。而本文所提方法在线故障定位时,可直接调用离线训练好的分类模型,精准输出故障线路位置。




图9 线路L7发生故障时基于群智能算法的故障定位方法的目标函数 f 收敛曲线

Fig.9 The convergence curves of the objective function f of the fault localization method based on swarm optimization algorithms when fault occurs at line L7

4.3 容错性分析

FTU设备工作环境较为复杂且不可控,会导致FTU设备在传输故障电流方向信息时,出现相关数据丢失和数据畸变等现象,即FTU信号发生异常。因此,为进一步验证本文所提两阶段故障

表6 不同异常FTU信号个数对不同故障定位方法准确率的影响统计

Tab.6 The influence of different numbers of abnormal FTU signals on the accuracy of different fault localization methods

方法	不同异常FTU信号个数下的故障定位准确率/%							
	0	1	2	3	4	5	6	
PSO	[71.2 75.3]	[38.8 64.4]	[32.9 58.6]	[20.6 43.8]	[11.5 38.8]	[4.8 31.6]	[0.2 22.3]	
GWO	[76.0 80.1]	[60.8 72.1]	[50.2 64.5]	[36.4 52.9]	[28.3 46.8]	[22.2 42.7]	[13.1 40.0]	
WOA	[72.5 77.2]	[66.3 74.1]	[60.2 73.3]	[52.1 64.9]	[34.7 49.1]	[26.2 40.1]	[16.2 34.3]	
本文方法	[100 100]	[91.3 99.3]	[84.7 96.7]	[82.7 94.7]	[74.7 91.2]	[69.3 90.7]	[65.3 86.0]	




图10 线路L9和L25均发生故障时基于群智能算法的故障定位方法的目标函数 f 收敛曲线

Fig.10 The convergence curves of the objective function f of the fault localization method based on swarm optimization algorithms when fault occurs at lines L9 and L25

定位方法的抗干扰能力,在表1中定义的15种故障类型基础上随机生成异常FTU信号,且信号异常FTU数目从0逐渐增加至6;将含有FTU异常信号的故障电流方向信息传递给训练后的SSA-RF模型并判断其是否能准确识别故障区段,重复该过程200次,并对得到的准确率结果进行统计分析,统计结果如图11和表6所示。由图表可知,随着FTU异常信号个数的持续增加,本文所提方法和基于群智能优化算法故障定位方法的准确率均不断下降。相比之下,本文方法对FTU异常信号的抗干扰能力显著强于基于群智能优化算法故障定位方法,当FTU异常信号个数不超过三个时,故障定位的准确率均在82%以上。




图11 FTU异常信号对不同故障定位方法准确率的影响

Fig.11 The impact of the abnormal signal of FTU on the accuracy of different fault localization methods

5 结论

本文提出了一种基于SSA-RF算法和余弦相似度的主动配电网两阶段故障定位方法。首先,利用故障电流状态方程,通过单点及多点故障的随机模拟构建目标配电网的故障特征库;随后,提出融合SSA算法的改进RF分类模型,用于故障线路区段的初步定位;最后对定位到的故障区段,利用余弦相似度突变点精确定位具体故障线路。得到结论如下:

1)与传统配电网故障定位应用的群智能优化算法相比,本文提出的方法首先对配电网线路划分区段,可有效降低后续具体故障分段线路的搜索维数,缩短了故障定位时间,提高了故障定位效率。

2)在对目标主动配电网进行阶段一故障区段定位时,本文提出的SSA-RF分类模型相较于其他传统分类模型训练用时短、分类精度高,对测试配电网的故障区段定位准确率可达100%。

3)本文综合考虑了不同FTU异常信号个数对所提两阶段故障定位方法准确率的影响。在FTU出现信号异常的情况下,对比传统群智能优化算法,本文所提方法具有更好的容错性,更切合实际应用。

参考文献

- [1] 马钊,安婷,尚宇炜.国内外配电网前沿技术动态及发展[J].中国电机工程学报,2016,36(6):1552-1567,1768.
MA Zhao, AN Ting, SHANG Yuwei. State of the art and development trends of power distribution technologies[J]. Proceedings of the CSEE, 2016, 36(6): 1552-1567, 1768.
- [2] TENG J H, HUANG W H, LUAN S H. Automatic and fast faulted line-section location method for distribution systems based on fault indicators [J]. IEEE Transactions on Power Systems, 2014, 29(4): 1653-1662.
- [3] 宋晓辉,高菲,刘雯静,等.基于智能算法的配网单相接地故障辨识[J].电气自动化,2020,42(3):49-51,79.
SONG Xiaohui, GAO Fei, LIU Wenjing, et al. Intelligent algorithm-based identification of single-phase earth faults in the distribution network[J]. Electrical Power System & Automation, 2020, 42(3): 49-51, 79.
- [4] 张颖,周韧,钟凯.改进蚁群算法在复杂配电网故障区段定位中的应用[J].电网技术,2011,35(1):224-228.
ZHANG Ying, ZHOU Ren, ZHONG Kai, et al. Application of improved ant colony algorithm in fault-section location of complex distribution network[J]. Power System Technology, 2011, 35(1): 224-228.
- [5] 马少飞,胡俊,刘强,等.基于粒子群算法的配电网故障定位研究[J].智慧电力,2018,46(9):83-87.
MA Shaofei, HU Jun, LIU Qiang, et al. Fault location of distribution network based on particle swarm optimization[J]. Smart Power, 2018, 46(9): 83-87.
- [6] 颜景斌,夏赛,王飞,等.基于改进遗传算法的有源配电网故障定位分析[J].电力系统及其自动化学报,2019,31(6):107-112.
YAN Jingbin, XIA Sai, WANG Fei, et al. Analysis of fault location for active distribution network based on improved genetic algorithm[J]. Proceedings of the CSU-EPSA, 2019, 31(6): 107-112.
- [7] 高峰阳,李昭君,袁成,等.量子计算和免疫优化算法相结合的有源配电网故障定位[J].高电压技术,2021,47(2):396-406.
GAO Fengyang, LI Zhaojun, YUAN Cheng, et al. Fault location for active distribution network based on quantum computing and immune optimization algorithm[J]. High Voltage Engineering, 2021, 47(2): 396-406.
- [8] 李卫彬,童欣,黄超,等.基于分层定位模型的含DG配电网故障定位方法研究[J].电力系统保护与控制,2022,50(24):160-166.
LI Weibin, TONG Xin, HUANG Chao, et al. A fault location method for a distribution network with DG based on a hierarchical location model[J]. Power System Protection and Control, 2022, 50(24): 160-166.
- [9] 杨莉,周年荣,李川,等.含DG配电网故障定位的免疫二进制萤火虫算法[J].化工自动化及仪表,2021,48(3):253-258.
YANG Li, ZHOU Nianrong, LI Chuan, et al. IBFA for fault location of DG-included power distribution network[J]. Control and Instruments in Chemical Industry, 2021, 48(3): 253-258.
- [10] 杨国华,冯骥,柳萱,等.基于改进秃鹰搜索算法的含分布式电源配电网分区故障定位[J].电力系统保护与控制,2022,50(18):1-9.
YANG Guohua, FENG Ji, LIU Xuan, et al. Fault location of a distribution network hierarchical model with a distribution generator based on IBES[J]. Power System Protection and Control, 2022, 50(18): 1-9.
- [11] 邱彬,罗添元,宁博,等.基于BAS-IGA的含分布式电源配电网故障定位[J].电力系统及其自动化学报,2021,33(2):8-14.
QIU Bin, LUO Tianyuan, NING Bo, et al. Fault location of distribution network with distribution generations based on BAS-IGA[J]. Proceedings of the CSU-EPSA, 2021, 33(2): 8-14.
- [12] 陶维青,杨刚,丁明,等.改进模因算法在含DG配电网故障定位中的应用[J].电子测量与仪器学报,2016,30(2):265-273.
TAO Weiqing, YANG Gang, DING Ming, et al. Application of improved memetic algorithm for fault location in distribution network with DG[J]. Journal of Electronic Measurement and Instrument, 2016, 30(2): 265-273.
- [13] 刘鹏程,李新利.基于多种群遗传算法的含分布式电源的配电网故障区段定位算法[J].电力系统保护与控制,2016,44

- (2):36-41.
- LIU Pengcheng, LI Xinli. Fault-section location of distribution network containing distributed generation based on the multiple-population genetic algorithm[J]. Power System Protection and Control, 2016, 44(2):36-41.
- [14] 梅飞,陈子平,裴鑫,等. 基于矩阵算法的有源配电网故障定位容错方法[J]. 电力工程技术, 2022, 41(6):109-115.
- MEI Fei, CHEN Ziping, PEI Xin, et al. Fault-tolerant method for fault location of active distribution network based on matrix algorithm[J]. Electric Power Engineering Technology, 2022, 41(6):109-115.
- [15] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020(8):1, 22-34.
- [16] 甄永琦,蒋伟. 改进灰狼算法在配电网故障定位中的应用[J]. 计算机应用与软件, 2020, 37(11):200-205.
- ZHEN Yongqi, JIANG Wei. Application of improved grey wolf algorithm in distribution network fault location[J]. Computer Applications and Software, 2020, 37(11):200-205.
- [17] 樊群才,胡箭,廖艳萍,等. 基于改进鲸鱼优化算法的分布式电源接入配电网继电保护的整定优化研究[J]. 电力科学与技术学报, 2024, 39(2):74-79.
- FAN Quncai, HU Jia, LIAO Yanping, et al. Research on setting optimization of relay protection for distributed power access based on improved whale optimization algorithm[J]. Journal of Electric Power Science and Technology, 2024, 39(2):74-79.
- [18] 郑聪,周海峰,郑东强,等. 基于改进多元宇宙算法的主动配电网故障定位方法研究[J]. 电力系统保护与控制, 2023, 51(2):169-179.
- ZHENG Cong, ZHOU Haifeng, ZHENG Dongqiang, et al. An active distribution network fault location method based on improved multi-universe algorithm[J]. Power System Protection and Control, 2023, 51(2):169-179.

收稿日期:2024-06-07

修改稿日期:2024-07-01

(上接第50页)

- the grid-connected inverter for high-penetration new energy generation[D]. Hefei :Hefei University of Technology, 2020.
- [13] 黄河遥,王鲁杨,吴嘉明,等. 基于虚拟同步机的微电网不平衡工况下改进控制策略[J]. 电气传动, 2022, 52(14):45-51, 58.
- HUANG Heyao, WANG Luyang, WU Jiaming, et al. Improvement of control strategy based on virtual synchronous generator under unbalanced under unbalanced condition of microgrid[J]. Electric Drive, 2022, 52(14):45-51, 58.
- [14] 王晨丞,蒲丽娟,杜斌,等. 基于新型模糊自适应惯量VSG的微网频率波动抑制[J]. 电气传动, 2022, 52(5):14-20.
- WANG Chencheng, PU Lijuan, DU Bin, et al. Novel fuzzy adaptive inertia based virtual synchronous generator for microgrid frequency fluctuation attenuation[J]. Electric Drive, 2022, 52(5):14-20.
- [15] 李春,马凡,胡祺. 独立电力系统中基于模式切换的虚拟同步发电机控制方法[J]. 高压技术, 2022, 48(9):3474-3483.
- LI Chun, MA Fan, HU Qi. Virtual synchronous generator control method based on mode switching in Isolated power system [J]. High Voltage Engineering, 2022, 48(9):3474-3483.

收稿日期:2023-10-09

修改稿日期:2023-11-16