

DOI: 10.19783/j.cnki.pspc.241758

# 基于 SMA-Adaboost 的单三相混联微网群孤岛检测方法

王灿<sup>1,2</sup>, 常文涵<sup>1</sup>, 张雪菲<sup>3</sup>, 席磊<sup>1</sup>, 杨楠<sup>1</sup>

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 湖北省微电网工程技术研究中心(三峡大学), 湖北 宜昌 443002; 3. 国网荆州供电公司, 湖北 荆州 434000)

**摘要:** 非计划孤岛事件对单三相混联微网群的稳定运行存在较大威胁, 及时检测出微网群的实际孤岛状况是确保其安全稳定运行的重要前提。然而, 传统孤岛检测方法存在检测盲区, 且较多弱相关或不相关电气特征量会对孤岛检测的准确性造成不利影响。为此, 提出一种基于改进自适应增强(adaptive boosting, Adaboost)学习器的单三相混联微网群孤岛检测方法。首先, 在 Adaboost 学习器中引入黏菌优化算法(slime mould algorithm, SMA)以改善分类能力、减弱扰动影响, 并采用群组自适应归一化(group switchable normalization, GSN)权重学习方式缩短检测耗时。其次, 基于所构建的 SMA-Adaboost 学习器建立孤岛检测模型。同时为提高孤岛检测模型的效率和准确度, 基于偏最小二乘法(partial least squares, PLS)提取出与孤岛状态强相关电气特征量。最后, 在基于改进 IEEE37 节点的单三相混联微网群中对所提方法的性能进行仿真验证。结果表明, 所提孤岛检测方法能够不受扰动信号和系统三相不平衡度的影响进行准确的孤岛检测, 与其他检测方法相比具有更强的准确性及泛化能力。

**关键词:** 非计划孤岛; 微网群; 孤岛检测; 自适应增强学习器

## An islanding detection method for hybrid single- and three-phase microgrid clusters based on SMA-Adaboost

WANG Can<sup>1,2</sup>, CHANG Wenhan<sup>1</sup>, ZHANG Xuefei<sup>3</sup>, XI Lei<sup>1</sup>, YANG Nan<sup>1</sup>

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 2. Hubei Provincial Engineering Technology Research Center for Microgrid (China Three Gorges University), Yichang 443002, China; 3. State Grid Jingzhou Power Supply Company, Jingzhou 434000, China)

**Abstract:** Unintentional islanding events pose a significant threat to the stable operation of hybrid single- and three-phase hybrid microgrid clusters. Timely and accurate detection of the actual islanding status is essential to ensure their secure and reliable operation. However, traditional islanding detection methods suffer from detection blind spots, and many weakly correlated or irrelevant electrical characteristics can adversely affect the accuracy of islanding detection. To address these issues, an islanding detection method for hybrid single- and three-phase microgrids based on the improved adaptive boosting (Adaboost) method is proposed. First, the slime mould algorithm (SMA) is introduced into the Adaboost learner to improve classification ability and reduce disturbance effects. Additionally, the weight learning method using group switchable normalization (GSN) is adopted to shorten the detection time. Then, an islanding detection model is established using the proposed SMA-Adaboost learner. To further enhance the efficiency and accuracy of the islanding detection model, electrical features strongly correlated with islanding status are extracted based on the partial least squares (PLS) method. Finally, the performance of the proposed method is validated through simulations on a hybrid single- and three-phase microgrid cluster based on the improved IEEE37-bus system. The results demonstrate that the proposed islanding detection method can accurately detect islanding without being affected by disturbance signals or three-phase system unbalance, and exhibits superior accuracy and generalization capability compared to existing detection methods.

This work is supported by the National Natural Science Foundation of China (No. 52107108).

**Key words:** unintentional islanding; microgrid cluster; islanding detection; adaptive boosting learner

## 0 引言

随着全球能源危机和环境污染日益严重, 关于

分布式发电技术的研究受到了广泛关注<sup>[1-2]</sup>。微电网能够对分布式发电装置进行有效的协同控制, 已成为高效利用分布式电源(distributed generation, DG)的主要形式之一<sup>[3-5]</sup>。微电网能以并网和孤岛两种运行方式工作, 其中孤岛运行方式分为计划孤岛与非

基金项目: 国家自然科学基金项目资助(52107108)

计划孤岛。当发生非计划孤岛时，微电网电压和频率将脱离主网控制，可能产生一些不良后果，如损坏电力设备性能、降低电能质量，甚至可能导致整个微电网系统停运<sup>[6]</sup>。因此需要对微电网的孤岛检测技术展开研究，迅速识别出非计划孤岛状态并采取措施改变逆变器的控制方式，这一研究对保证微电网及主网运行的可靠性和稳定性至关重要。

孤岛检测方法通常可分为主动式孤岛检测和被动式孤岛检测<sup>[7]</sup>两类。其中，主动式孤岛检测法通过给系统施加一定的小干扰信号，判断相关电气量的变化值来实现孤岛检测。文献[8]提出了一种改进最大重叠离散小波变换的孤岛检测方法，该方法能够准确检测电压扰动信号，相比于传统孤岛检测方法其抗噪能力有所加强。文献[9]通过向逆变器注入周期性扰动并将其分为两类来提高孤岛检测的速度。文献[10]引入反馈强度系数对传统下垂控制进行改进，在仿真中验证了所提方法能够在不同负荷条件下实现无盲区孤岛检测。文献[11]将无功功率扰动法与优化后的谐波电压检测法进行有机结合，在光伏配电网中实现了消除检测盲区、保证孤岛检测准确率的效果。尽管上述主动式孤岛检测法有效缩小了检测盲区，但其中添加的干扰信号会不可避免地给电能质量带来负面影响，并且不同强度的干扰信号可能对孤岛检测产生干扰。

为了避免主动式孤岛检测法在检测过程中的不利影响，众多学者对被动式孤岛检测法开展了研究。文献[12]提出一种新型被动式孤岛检测法，该方法以谐波电压检测和基波频率偏移作为判定孤岛的依据。文献[13]基于短路滤波装置检测电压谐波的变化，以实现孤岛状态识别。该方法的改造条件简单，易于实现且检测成本较低。文献[14]提出一种基于光伏并网点谐波电压突变的无功功率扰动孤岛检测方法。该方法能够在无需对逆变器实时注入扰动的情况下，实现快速的孤岛检测，同时确保输出电能质量不受影响。文献[15]采用小波变换从公共耦合点(point of common coupling, PCC)处采集信号并提取特征量，再通过反向传播(back propagation, BP)神经网络进行孤岛识别。该方法可使检测速度提高、检测盲区缩小，对电能质量的影响也较小。上述被动式孤岛检测法通过测量电网断开时 PCC 处的电压幅值、相位、频率等电气量的突变情况，实现了对孤岛现象的有效判断。然而，当 PCC 处参数变化较小时，这种被动式的孤岛检测方法将无法达到期望检测效果，甚至失效。

近年来，基于机器学习的孤岛检测方法被陆续提出。机器学习能够基于系统的历史数据生成各个

电气量阈值，并在此基础上根据当前微电网系统的运行数据识别其具体运行状态。文献[16]使用遗传算法优化了传统的 BP 神经网络，克服了其容易陷入局部最优的缺点，将优化后的 BP 神经网络的输出作为系统状态的判定结果。该方法在不同负荷特性情景下均能保持较快的检测速度和较低的误检率。文献[17]基于支持向量机提出一种具有在线增量学习能力的孤岛检测方法，该方法能够在保证孤岛检测准确率的同时有效提高其自适应性。针对一般智能孤岛检测方法数据集标签分布不均匀和决策可解释性欠缺的问题，文献[18]提出一种基于轻梯度提升机算法的孤岛检测方法。该方法通过 K 折交叉验证和基于决策树的 Shapley 值加性解释方法进行孤岛检测和分析，提高了模型的可信度。然而，以上研究并未考虑对与孤岛状态相关的 PCC 处多种电气特征量进行筛选提取。如果孤岛检测过程中包含较多弱相关或不相关的电气特征量，将会对检测结果的准确度造成一定的影响。

自适应增强(adaptive boosting, Adaboost)学习器是一种能够将多个弱分类器高效聚合成强分类器的学习器，因其具有自适应性强和能够避免过拟合的优势，在图像分类、故障诊断、孤岛检测等多个领域得到广泛应用。文献[19]使用盘面状态图像的提取特征作为 Adaboost 学习器的输入进行训练，构建了可以识别盘面未钝化或已钝化的图像分类器。文献[20]基于改进 Adaboost 学习器提出一种变压器故障诊断方法，通过融合多源故障信息构建诊断模型。该方法有效解决了高度冲突性故障信息的融合问题，并提高了故障诊断的准确率。文献[21]提出一种基于 Adaboost 学习器的智能被动式孤岛检测方法。该方法能够在避免传统检测方法无法确定电气量阈值问题的同时不引入干扰信号。然而，上述文献在应用 Adaboost 学习器的过程中仍然存在受扰动因素影响、训练样本特征较多情况下耗时过长、未考虑样本权重变化对算法性能的影响等不足。此外，单三相混联微网群作为微电网群系统发展的主流模式之一，具有运行方式灵活和促进资源优化配置的优势<sup>[22]</sup>。然而，上述文献未涉及针对单三相混联微网群这类系统在孤岛检测方面的研究。

综合以上分析，本文提出了一种基于改进 Adaboost 学习器的单三相混联微网群孤岛检测方法。首先将黏菌优化算法(slime mould algorithm, SMA)与群组自适应归一化(group switchable normalization, GSN)权重学习方式融入传统 Adaboost 学习器中，通过学习在 PCC 处测得的不同电气特征量实现对微网群孤岛状态的检测。之后，为了减少与孤岛状

态弱相关或不相关的电气特征量对检测结果的干扰, 基于偏最小二乘法(partial least squares, PLS)对 PCC 处测得各类电气特征量进行了相关性分析和提取。算例结果表明, 所提孤岛检测方法能够在不同三相不平衡度下实现有效的孤岛检测, 并且在微电网面临并网干扰和线路故障事件时, 能够保持良好的识别效果。

## 1 微电网孤岛检测综述

微电网作为接纳分布式电源的小容量发-储-用型电网, 能够在并网或孤岛模式下运行。连接微电网与主电网的 PCC 处开关有主动断开和被动断开两种情况, 因此微电网的孤岛切换方式可分为计划孤岛和非计划孤岛。计划孤岛是指微电网在正常运行中, 能够通过针对性的策略使微电网从并网运行状态平稳过渡到孤岛运行状态; 非计划孤岛是指因气候影响、突发事件导致线路跳闸或断线等意外因素, 微电网进入预先计划外的并离网切换运行模式。非计划孤岛事件是未知的, 不在预先规划的计划之中, 一旦发生非计划孤岛将会对系统造成危害, 可能对电网工作人员和设备造成安全隐患。因此为应对非计划孤岛事件的发生, 微电网必须具有能够检测孤岛是否发生的能力。

### 1.1 孤岛检测基本原理

典型微电网群拓扑结构图如图 1 所示, 该结构主要由微电网系统、负荷及主电网 3 部分组成。孤岛检测的本质是通过电气量数据判断系统是否处于孤岛状态, 属于二状态分类问题(孤岛状态和非孤岛状态)。

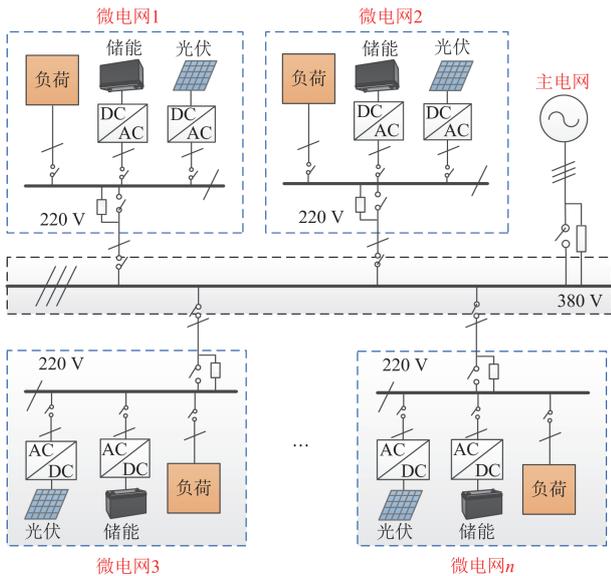


图 1 典型微电网群拓扑结构图

Fig. 1 Topology diagram of typical microgrid cluster

当主电网正常向微电网系统供电时, 系统功率满足平衡等式, 如式(1)和式(2)所示。

$$P + P_G = P_L \quad (1)$$

$$Q + Q_G = Q_L \quad (2)$$

式中:  $P$  和  $Q$  分别为微电网系统发出的有功功率和无功功率;  $P_G$  和  $Q_G$  分别为主网侧输出的有功功率和无功功率;  $P_L$  和  $Q_L$  分别为负荷消耗的有功功率和无功功率。

此时, 微电网系统的输出电压受主电网电压钳制, 因此 PCC 处电压等于主电网电压, 满足式(3)和式(4)。

$$P_L = \frac{U_{PCC}^2}{R} \quad (3)$$

$$Q_L = \frac{U_{PCC}^2}{\frac{1}{\omega_{PCC}L} - \omega_{PCC}C} \quad (4)$$

式中:  $U_{PCC}$  为 PCC 处的电压幅值;  $\omega_{PCC}$  为 PCC 处的电压角频率;  $R$ 、 $C$ 、 $L$  分别为电阻性负荷、电容性负荷和电感性负荷。

当并网断路器断开后, 微电网的输出功率将全部供给负荷, 有式(5)和式(6)所示关系式成立。

$$P = \frac{U_{PCC}'^2}{R} \quad (5)$$

$$Q = \frac{U_{PCC}'^2}{\frac{1}{\omega_{PCC}'L} - \omega_{PCC}'C} \quad (6)$$

式中:  $U_{PCC}'$ 、 $\omega_{PCC}'$  分别为并网断路器断开后 PCC 处的电压和角频率。

### 1.2 孤岛检测盲区

联立式(3)一式(6)可以得出

$$\frac{U_{PCC}'}{U_{PCC}} = \sqrt{\frac{P}{P_L}} \quad (7)$$

$$\omega_{PCC}' = \frac{-\frac{Q}{CU_{PCC}^2} + \sqrt{\left(\frac{Q}{CU_{PCC}^2}\right)^2 + \frac{4}{LC}}}{2} \quad (8)$$

由式(7)和式(8)可知, PCC 处的电压和角频率的变化受到功率差值的影响。当有功功率差值  $\Delta P$  和无功功率差值  $\Delta Q$  较大时, 电压和角频率会发生较大变化; 而当这两个差值较小或几乎为 0 时, 则满足条件  $P \approx P_L$  和  $Q \approx Q_L$ , 这时不存在 PCC 处电压和角频率的变化, 此类情况即为孤岛检测的盲区。传统被动检测法根据单个电气量的阈值来判断系统是否发生孤岛, 无法在检测盲区内进行有效检测。因此只根据 PCC 处电压和角频率的异常变化来实

现孤岛检测不够准确可靠, 需要结合其他方法并同时考虑多个电气量以准确判断系统的运行状态。

## 2 SMA-Adaboost 学习原理

### 2.1 Adaboost 学习器

机器学习算法通过采集 PCC 处的实际运行数据构成训练样本集合, 生成二分类模型, 随后将利用 PCC 处实时采集的电气量信息构建检测样本集合, 以对微电网系统的孤岛状态进行识别和分类。Boost 学习器能够对弱分类器(分类能力较差)进行处理合成复合强分类器(分类能力较强)。Adaboost 学习器是 Boost 学习器中比较具有代表性的一类学习器, 能够依据不同弱分类模型的精度赋予其在复合模型中的权重分配, 通过多次逐步迭代生成分类效果较好的强分类器。Adaboost 学习器的实现过程如图 2 所示, 其中“+”、“-”分别表示两个类别的样本, 在使用水平线和垂线作为分类器时先使用第一个弱分类器对训练样本进行分类。由图 2 可知, 单个弱分类器的分类效果欠佳, 存在部分样本误分类的情况。由于 Adaboost 学习器在复合形成强分类器的过程中是逐步分类形成弱分类器的, 形成当前弱分类器后才可形成下一个分类器。因此需要依据当前分类器的误差计算结果, 提高误判样本的分类权重(图中样本图标变大即表示权重增大), 纠正上一个弱分类器分类错误的样本。在确定弱分类器之后, 继续搜索误判样本点, 并根据优先保证原则选择下一个弱分类器。经过多次迭代后, 得出所需训练好的弱分类器个数, 最终由以上多个弱分类器复合形成强分类器。

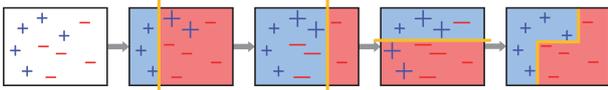


图 2 Adaboost 学习器的实现过程

Fig. 2 Implementation process of the Adaboost learner

Adaboost 学习器生成二分类模型的主要执行步骤如下所述。

#### 1) 确定输入

输入训练样本  $A_1 = \{(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k), \dots, (x_N, y_N)\}$ 。其中  $N$  为样本数量,  $x_k \in X$ ,  $X$  为训练样本集合;  $y_k \in Y$ ,  $Y$  为运行数据集的数据标签集合,  $y_k = 1$  表示正样本,  $y_k = -1$  表示负样本; 迭代次数为  $M$ ; 样本权重矩阵为  $\mathbf{H} = [\lambda_1, \lambda_2, \dots, \lambda_N]^T$ 。

#### 2) 初始化原始训练样本集合的权重

给定训练样本集合  $X$  中每个样本的权重, 在第一轮迭代训练中每行数据的权重满足平均分布, 即

$$\mathbf{H}^{(1)} = [\lambda_1^{(1)}, \lambda_2^{(1)}, \dots, \lambda_k^{(1)}, \dots, \lambda_N^{(1)}] \quad (9)$$

$$\lambda_k^{(1)} = \frac{1}{N}, k = 1, 2, \dots, N \quad (10)$$

式中:  $\mathbf{H}^{(1)}$  为第一轮初始样本的权重分布;  $\lambda_k^{(1)}$  为第一轮迭代训练中第  $k$  个数据的权重。

#### 3) 形成弱分类器

在第  $m$  轮迭代训练中, 使用当前权重矩阵  $\mathbf{H}^{(m)}$  进行样本集合训练学习, 得到弱分类器  $G(x, l, \psi, \delta)$ , 令  $G_m(x_k) = G(x, l, \psi, \delta)$ 。

$$G(x, l, \psi, \delta) = \begin{cases} 1 & \psi l(x) < \psi \delta \\ -1 & \psi l(x) \geq \psi \delta \end{cases} \quad (11)$$

式中:  $x$  为测试样本;  $l$  为特征计算函数;  $l(x)$  为测试样本  $x$  的特征值;  $\psi$  为偏置参数;  $\delta$  为阈值参数。

随后计算  $G_m(x_k)$  在训练样本集合中的分类误差率  $e_m$ 。

$$e_m = \sum_{k=1}^N \lambda_k^{(m)}, G_m(x_k) \neq y_k \quad (12)$$

式中:  $\lambda_k^{(m)}$  为第  $m$  轮迭代训练中第  $k$  个数据的权重。

根据分类误差率  $e_m$  得到当前轮次模型在复合强分类器中的权重  $\alpha_m$  为

$$\alpha_m = \frac{1}{2} \ln \frac{1 - e_m}{e_m} \quad (13)$$

由式(13)可知, 当前轮次训练器的分类误差率越小时, 其在复合强分类器中对应的权重越大。

#### 4) 更新原始训练样本集合的权重

根据式(14)对弱分类器的权重进行下一轮迭代训练的样本权重调整。

$$\mathbf{H}^{(m+1)} = [\lambda_1^{(m+1)}, \lambda_2^{(m+1)}, \dots, \lambda_k^{(m+1)}, \dots, \lambda_N^{(m+1)}]^T \quad (14)$$

$$\lambda_k^{(m+1)} = \frac{\lambda_k^{(m)}}{Z_m} \exp[-\alpha_m y_k G_m(x_k)] \quad (15)$$

式中:  $Z_m = \sum_{k=1}^N \lambda_k^{(m)} \exp[-\alpha_m y_k G_m(x_k)]$  为归一化因子, 其作用是保证权重之和为 1。

#### 5) 输出强分类器

构造所有弱分类器与其对应权重的线性加权组合, 即形成最终强分类器  $y(x)$ 。

$$y(x) = \text{sign} \left[ \sum_{m=1}^M \alpha_m G_m(x) \right] \quad (16)$$

式中:  $\text{sign}$  为符号函数。

## 2.2 SMA-Adaboost 学习器

传统 Adaboost 学习器虽然能够提高各个弱分类器的利用率, 具有较高的分类精度, 但是仍然存在以下不足: 1) 没有消除扰动因素和冗余特征的不

利影响; 2) 所采用的权重归一化方法会导致已正确分类样本的权重呈指数规律减少, 大幅降低算法性能; 3) 在训练样本和特征较多的情况下耗时过长, 系统仍然具有较高的复杂度。因此, 针对以上不足, 本文利用兼具动态搜索能力和不易陷入局部最优的 SMA 对 Adaboost 学习器进行改进, 得到训练好的最高性能分类器, 以提高其对样本的分类能力, 减弱扰动因素的影响。同时充分考虑样本权重变化对算法性能的影响, 通过 GSN 权重学习方式简化特征处理过程的计算冗余, 缩短算法耗时。

SMA 是一种模拟黏菌觅食行为变化的群体优化算法。在黏菌觅食过程中, 前端形成扇形, 黏菌之间相互连接成静脉网络, 如图 3 所示。该算法能够在保持较快收敛速度的同时防止陷入局部最优。利用数学模型描述 SMA 的两个阶段如下所述<sup>[23]</sup>。

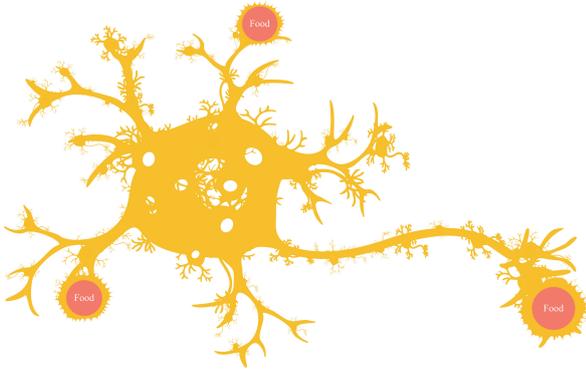


图 3 黏菌觅食形态示意图

Fig. 3 Schematic diagram of foraging morphology of slime molds

阶段 1: 探索食物。黏菌通过感知气味来接近食物, 并且质量随着接触到的食物浓度增加而增加, 其形成的静脉网络越粗。黏菌探索食物的位置更新模型为

$$x(t+1) = \begin{cases} r(u_B - l_B) + l_B & r < z \\ x_B(t) + v_B(Wx_m(t) - x_n(t)) & r \leq p \\ v_C x(t) & r > p \end{cases} \quad (17)$$

$$p = \tanh |S(u) - D_F|, \quad u = 1, 2, \dots, K \quad (18)$$

式中:  $x(t)$ 、 $x(t+1)$  分别为当前迭代和下一次迭代对应的黏菌位置;  $r$  为区间 $[0,1]$ 内的随机数;  $u_B$ 、 $l_B$  分别为搜索空间的上界和下界;  $z$  为转换概率, 参考文献<sup>[24]</sup>的实验验证结果, 取值为 0.03;  $p$  为动态转换概率;  $x_B(t)$  为当前探索到的食物浓度最高的坐标;  $x_m(t)$ 、 $x_n(t)$  为两个任意的黏菌坐标;  $W$  为黏菌质量参数(即个体黏菌的权重值);  $v_B$  为区间 $[-a, a]$ 内的取值, 其中参数  $a$  的计算公式如式(19)所示;  $v_C$  为从 1 到 0 满足线性递减的随机数;  $S(u)$  为  $x$  对

应的适应度值;  $u$  为黏菌种群的位置;  $D_F$  为当前优化过程中所得最佳适应度值;  $K$  为黏菌种群的规模大小。

$$a = \arctan h\left(-\frac{t}{T_{\max}} + 1\right) \quad (19)$$

式中:  $t$  为当前迭代次数;  $T_{\max}$  为最大迭代次数。

阶段 2: 获取食物。食物源的吸引会导致黏菌自身发生振荡, 改变细胞质在脉络中的流动, 从而促使黏菌不断接近食物源。黏菌在食物浓度较低时缓慢接近食物, 保持现有食物来源的情况下继续搜寻更加优质的食物源。通过  $W$ 、 $v_B$ 、 $v_C$  的协同作用模拟黏菌的选择性行为,  $v_B$  在区间 $[-a, a]$ 内随机振荡并随着迭代的进行不断增大并接近 0,  $v_C$  在区间 $[-1,1]$ 内振荡并最终趋于 0。黏菌质量参数  $W$  在不同食物浓度下的函数表达式为

$$W(S_r) = \begin{cases} 1 + r \lg\left(\frac{b_F - S(u)}{b_F - w_F} + 1\right), & 1 \leq i \leq \frac{N}{2} \\ 1 - r \lg\left(\frac{b_F - S(u)}{b_F - w_F} + 1\right), & \frac{N}{2} < i \leq N \end{cases} \quad (20)$$

$$S_r = F_{\text{sort}}(S(u)) \quad (21)$$

式中:  $\frac{N}{2}$  为  $S(u)$  在黏菌群体中排名前一半的部分;  $b_F$ 、 $w_F$  分别为当前迭代过程中获取的最佳适应度值和最差适应度值;  $F_{\text{sort}}$  表示对种群的适应度进行升序排列;  $S_r$  表示排序后的适应度值序列。

训练弱分类器  $G(x, l, \psi, \delta)$  是为了将其分类误差率  $e_m$  降到最小, 其中最重要的参数是偏置参数  $\psi$  和阈值参数  $\delta$ 。本文利用具有动态搜索能力且不易陷入局部最优特点的 SMA 对偏置参数  $\psi$  和阈值参数  $\delta$  进行有效优化, 具体步骤如下所述。

- 1) 初始化 SMA 的参数, 以 Adaboost 学习器的分类误差率  $e_m$  为 SMA 的目标函数, 对模型进行训练;
- 2) 利用目标函数计算适应度值并排序, 以排序结果为依据, 利用式(17)更新种群位置;
- 3) 计算种群适应度值, 更新最佳适应度值和黏菌最佳个体位置;
- 4) 判断是否满足最优条件, 若满足则输出最优结果, 否则执行步骤 2) 至步骤 4) 直至满足最优条件;
- 5) 完成所有迭代更新后, 通过最终输出的最佳个体位置得到 Adaboost 学习器的全局最佳参数优化结果;
- 6) 将优化后的参数输入 Adaboost 学习器, 得到训练好的最高性能二分类器。

另外, 集成批量归一化(batch normalization,

BN)<sup>[25]</sup>、实例归一化(instance normalization, IN)<sup>[26]</sup>和群组归一化(group normalization, GN)<sup>[27]</sup>3种归一化方法形成 GSN, 该权重学习方式可以实现模型精度提升、计算冗余度降低的效果。因此, 本文考虑样本权重变化对算法性能的影响, 将 GSN 引入 Adaboost 学习器中, 采用 GSN 权重学习方法替换 Adaboost 学习器的执行步骤 4)中原有的归一化方法, 具体如下。

$$\lambda_i^{(m+1)} = \gamma \frac{\lambda_i^{(m)} \exp[-\alpha_m \gamma_i G_m(x_i)] - \mu_{\text{GSN}}}{\sqrt{\sigma_{\text{GSN}}^2 + \nu}} + \zeta \quad (22)$$

其中

$$\mu_{\text{GSN}} = \varphi_{\text{BN}} \mu_{\text{BN}} + \varphi_{\text{IN}} \mu_{\text{IN}} + \varphi_{\text{GN}} \mu_{\text{GN}} \quad (23)$$

$$\sigma_{\text{GSN}}^2 = \varphi_{\text{BN}} \sigma_{\text{BN}}^2 + \varphi_{\text{IN}} \sigma_{\text{IN}}^2 + \varphi_{\text{GN}} \sigma_{\text{GN}}^2 \quad (24)$$

式中:  $\gamma$  为初始化可学习缩放因子;  $\zeta$  为初始化可学习平移因子;  $\nu$  为超参数;  $\mu_{\text{GSN}}$ 、 $\sigma_{\text{GSN}}^2$  分别为经 GSN 处理得到的特征均值和特征方差;  $\varphi_{\text{BN}}$ 、 $\varphi_{\text{IN}}$  和  $\varphi_{\text{GN}}$  分别表示 BN、IN 和 GN 3 种归一化方法对应的权重;  $\mu_{\text{BN}}$ 、 $\sigma_{\text{BN}}^2$  分别为特征关于 BN 的均值和方差;  $\mu_{\text{IN}}$ 、 $\sigma_{\text{IN}}^2$  分别为特征关于 IN 的均值和方差;  $\mu_{\text{GN}}$ 、 $\sigma_{\text{GN}}^2$  分别为特征关于 GN 的均值和方差。

式(23)和式(24)中的权重学习方法公式为

$$\varphi_q = \frac{\ln(1 + \theta_q)}{\sum_{q \in \Omega} \ln(1 + \theta_q)} \quad (25)$$

式中:  $\varphi_q$  为权重值;  $\Omega = \{\text{BN}, \text{IN}, \text{GN}\}$ , 为归一化方法种类集合;  $q$  为选取的归一化方法种类;  $\theta_q$  为控制参数, 其值大于 0。其中, 对数函数的使用能够有效避免原 Adaboost 学习器中已正确分类样本的权重呈指数规律递减的问题。

综合以上分析, 本文所提 SMA-Adaboost 学习器结合了 SMA 算法在参数优化上的优势与 GSN 权重学习方式在权重更新方式上的改进, 二者协同作用可以有效提升 Adaboost 学习器的分类精度、泛化能力和计算效率, 其具体实现流程如图 4 所示。

### 3 基于SMA-Adaboost的单三相混联微网群孤岛检测方法

#### 3.1 基于 PLS 的电气特征量相关性分析

单三相混联微网群存在三相不平衡问题, 会对其各项电能指标产生影响。因此, 为应对并网三相电流不平衡度的影响以保证孤岛检测的准确性, 相比于一般类型的多微网孤岛检测, 本文还需考虑三

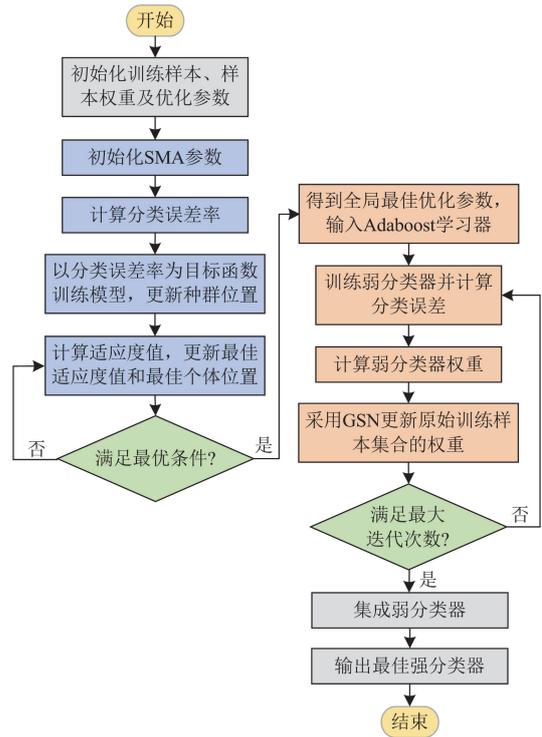


图 4 本文所提 SMA-Adaboost 学习器实现流程图

Fig. 4 Flowchart of the SMA-Adaboost learner proposed in this paper

相不平衡度与孤岛检测结果之间的关系。相关规定表明, 三相不平衡度不应超过 15%<sup>[28]</sup>。

孤岛电气特征量是由于孤岛效应发生后引起的, 受系统及其运行状态的影响。单三相混联微网群的基本孤岛电气特征量见表 1。

在智能被动式孤岛检测方法中, 孤岛电气特征量的选取将会直接影响孤岛检测的精度和速度。在机器学习中, 训练模型包含的特征量越多, 所需训练时间越长、计算要求越高。鉴于 PLS 法是一种多元统计数据分析方法, 能够将特征变量从高维空间投影到低维空间中, 以分析特征变量与目标变量之间的相关性<sup>[29]</sup>。因此, 本文采用 PLS 法对微网群的基本孤岛电气特征量进行重要程度排序, 筛选出变量投影重要性(variable importance in projection, VIP)指标超过 1 的电气特征量作为微网群孤岛检测的关键特征量。

根据 PLS 法进行 PCC 处电气特征量与单三相混联微网群孤岛状态相关性分析的具体步骤如下所述。

步骤 1: 建立由单三相混联微网群的基本孤岛电气特征量构成的数据集  $\mathbf{X}_{\text{PCC}}$  及微网群孤岛状态的数据集  $\mathbf{Y}_{\text{PCC}}$  分别为

表 1 单三相混联微网群的基本孤岛电气特征量  
Table1 Basic islanding electrical characteristics of the  
single/three-phase hybrid microgrid cluster

电气特征量	符号
电压	$U$
电压对时间的变化率	$dU/dt$
电压总谐波失真率	$U_{THD}$
电流	$I$
电流对时间的变化率	$dI/dt$
电流总谐波失真率	$I_{THD}$
频率	$f$
频率对时间的变化率	$df/dt$
阻抗	$Z$
阻抗对时间的变化率	$dZ/dt$
有功功率	$P$
有功功率对时间的变化率	$dP/dt$
无功功率	$Q$
无功功率对时间的变化率	$dQ/dt$
功率因数	$\cos\phi$
功率因数对时间的变化率	$d\cos\phi/dt$

$$\mathbf{X}_{PCC} = (x_{ij})_{b \times g} \quad (26)$$

$$\mathbf{Y}_{PCC} = (y_j)_{1 \times g} \quad (27)$$

式中:  $x_{ij}$  为第  $j$  个微电网样本的第  $i$  个特征值;  $g$  为样本总数;  $b$  为每个样本的电气特征维度;  $y_j \in \{0,1\}$ 。

步骤 2: 利用 PLS 法处理采集的基本电气特征量数据, 建立多元线性回归经验表达式如式(28)。

$$\hat{y}^* = a_1 x_1^* + a_2 x_2^* + \dots + a_b x_b^* \quad (28)$$

其中

$$a_i = \sum_{h=1}^d r(x_i; t_h) \omega_{ih} \quad (29)$$

式中:  $\hat{y}^*$  为预测值, 是通过多元线性回归模型预测的结果;  $x_b^*$  为标准化后的第  $b$  个输入特征变量;  $a_i$  为多元线性回归经验表达式的系数;  $d$  为提取出的主成分电气特征量总个数;  $r(x_i; t_h)$  为变量  $x_i$  与第  $h$  个主成分  $t_h$  之间的相关系数;  $\omega_{ih}$  为第  $h$  个主成分中第  $i$  个特征的系数分量。

步骤 3: 在式(28)、式(29)的基础上计算 VIP 值。具体公式如式(30)一式(32)所示。

$$V_i = \sqrt{\frac{g}{R_{\text{sum}}} \sum_{h=1}^d R_{y,h} \omega_{ih}^2} \quad (30)$$

$$R_{y,h} = \frac{1}{g} \sum_{j=1}^g r^2(y_j; t_h) \quad (31)$$

$$R_{\text{sum}} = \sum_{h=1}^d \left[ \frac{1}{g} \sum_{j=1}^g r^2(y_j; t_h) \right] \quad (32)$$

式中:  $V_i$  为变量  $x_i$  对应的 VIP 值;  $R_{y,h}$  为提取的第  $h$  个主成分对孤岛状态数据集  $\mathbf{Y}_{PCC}$  中因变量  $y_j$  的解释能力;  $R_{\text{sum}}$  为  $d$  个主成分电气特征量对  $y_j$  的累计解释能力;  $r(y_j; t_h)$  为第  $j$  个因变量  $y_j$  与提取的第  $h$  个主成分  $t_h$  之间的相关系数。

步骤 4: 将所得 VIP 值按照大小排序, 筛选出 VIP 值大于 1 对应的电气特征量。

在 PLS 法中, VIP 值能够衡量自变量对因变量的影响能力, 其值越大表示该电气特征量对孤岛状态的贡献程度更大, 即与孤岛检测的相关性越强, 因此可以提取出与孤岛检测强相关的电气特征量集合。

### 3.2 孤岛检测方法性能评价指标

为评价基于 SMA-Adaboost 的单三相混联微网群孤岛检测方法的检测性能, 本文采用孤岛检测时间、分类准确率、灵敏度、特异度、马修斯相关系数(Matthews coefficient, MCC)、曲线下面积(area under curve, AUC)构成的指标体系对孤岛检测方法进行性能评价。其中灵敏度衡量检测方法对实际为孤岛状态样本的识别能力, 特异度衡量检测方法对实际为非孤岛状态样本的识别能力, MCC 衡量检测方法在考虑误报与漏报下的综合分类性能, AUC 衡量检测方法对孤岛与非孤岛状态的整体区分能力。孤岛检测的二元分类混淆矩阵的形式如表 2 所示。

表 2 孤岛检测的二元分类混淆矩阵

Table 2 Binary classification confusion matrix of  
islanding detection

	实际为孤岛	实际为非孤岛
预测为孤岛	TP	FP
预测为非孤岛	FN	TN

在给定矩阵中, TP 和 TN 分别表示正确分类为孤岛和非孤岛, FN 和 FP 分别表示错误分类为孤岛和非孤岛。将  $1 - S_p$  作为横轴,  $S_e$  作为纵轴, 绘制接收者操作特性曲线(receiver operation characteristic curve, ROC), 计算 AUC 值。AUC 值越大, 说明分类算法的性能越优。各个评价指标计算公式如下。

$$F_{\text{ACC}} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{FP}} + N_{\text{FN}} + N_{\text{TN}}} \quad (33)$$

$$S_e = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (34)$$

$$S_p = \frac{N_{TN}}{N_{FP} + N_{TN}} \quad (35)$$

$$F_{MCC} = \frac{N_{TP} \times N_{TN} - N_{FP} \times N_{FN}}{\sqrt{(N_{TP} + N_{FP})(N_{TP} + N_{FN})(N_{TN} + N_{FP})(N_{TN} + N_{FN})}} \quad (36)$$

式中： $F_{ACC}$  为孤岛检测的分类准确率； $N_{TP}$  和  $N_{TN}$  分别为正确分类为孤岛和非孤岛的样本数量； $N_{FN}$  和  $N_{FP}$  分别为错误分类为孤岛和非孤岛的样本数量； $S_E$  为灵敏度； $S_p$  为特异度； $F_{MCC}$  为由混淆矩阵计算得到的 MCC 数值。

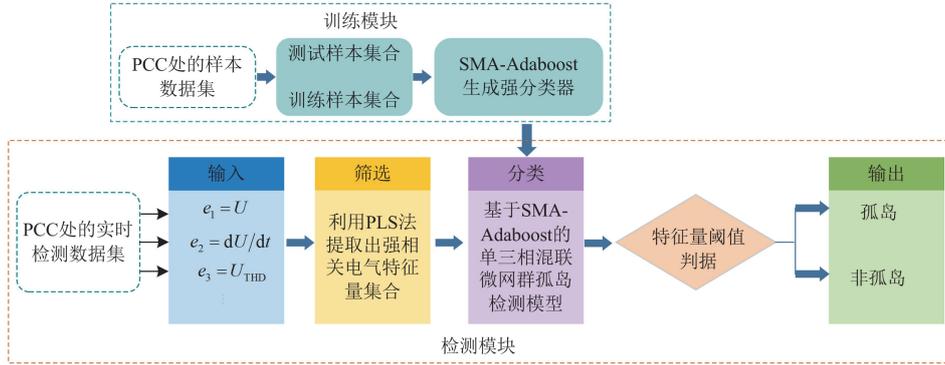


图 5 本文所提孤岛检测方法的结构

Fig. 5 Structure of the islanding detection method proposed in this paper

#### 4 仿真数据及结果分析

为了验证所提方法的有效性和优越性，本文在 MATLAB/Simulink 仿真软件中构建了基于改进 IEEE37 节点的单三相混联微网群模型，具体如图 6 所示。在仿真环境中，使用的处理器为 Intel(R) Core(TM) i7-6700 CPU@3.40 GHz，运行内存为 8 GB，操作系统为 64 位。单三相混联微网群中 DG、储能和负荷的参数信息见表 3，其余参数设置如下：电网电压为 220 V/50 Hz；RLC 负荷中  $R = 16.13 \Omega$ ， $L = 20.54 \text{ mH}$ ， $C = 493 \mu\text{F}$ ；RLC 负荷的谐振频率为 50 Hz；仿真均设置在 0.35 s 时刻主电网断开，发生非计划孤岛。根据前文所提孤岛检测标准规定，孤岛检测时间要求一般在 2 s 以内。

本文所有训练样本数据和检测样本数据均来自 PCC 处的采集数据，从孤岛发生时刻开始，采集连续 3 个周期内的电气特征量平均值。孤岛、并网干扰、线路故障等不同类型事件模拟的具体情况见表 4。在三相不平衡度取值区间  $[0, 0.15]$  内，以 5 kHz 的采样频率共生成 750 组数据。随机选取其中 70%(525 组)作为训练样本集合，用于训练基于

#### 3.3 所提孤岛检测方法的结构

本文采用 SMA-Adaboost 学习器对单三相混联微网群进行孤岛检测，其结构如图 5 所示，包括训练模块和检测模块。在训练模块中，经 PLS 法筛选得到的强相关电气特征量组成训练样本集合与测试样本集合，以该模块中基于 SMA-Adaboost 生成的强分类器构建微网群的孤岛检测模型。在检测模块中，以 PCC 处的实时检测数据集作为输入量进行特征筛选。最后通过孤岛检测电气特征量的阈值判据输出孤岛检测结果。

SMA-Adaboost 如图 6 所示的单三相混联微网群孤岛分类模型；将剩余 30%(225 组)的样本数据作为检测样本集合，对训练出的孤岛分类模型进行分类准确率的检验。

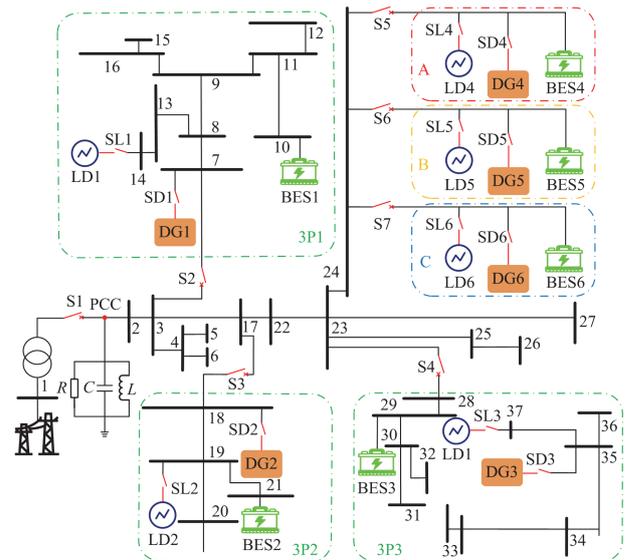


图 6 基于改进 IEEE37 节点的单三相混联微网群

Fig. 6 Single/three-phase hybrid microgrid cluster based on the improved IEEE37 node

表 3 单三相混联微网群参数信息

Table 3 Parameter information of the single/three-phase hybrid microgrid cluster

设备及编号	功率/kW
DG1—6	88.5; 102; 92.5; 77; 65; 45
BES1—6	92.5; 35; 173; 26; 51; 20
LD1—6	可调

表 4 不同类型事件模拟

Table 4 Simulation of different types of events

事件类型	事件情况
孤岛	断开 PCC
	断开 PCC 和 SL1
	断开 PCC 和 SL2
	断开 PCC 和 SL3
	断开 PCC 和 SL4
	断开 PCC 和 SL5
	断开 PCC 和 SD1
	断开 PCC 和 SD2
	断开 PCC 和 SD3
	断开 PCC 和 SD4
断开 PCC 和 SD5	
并网干扰	断开 SD1、SL1、SL2
	断开 SD2、SL2、SL3
	断开 SD3、SL3、SL4
	断开 SD4、SL4、SL5
	断开 SD5、SL1、SL4
	断开 SD4、SD5
线路故障	断开 SD1、SD2、SD3
	接入 SL6
	接入 SD6
线路故障	单相/两相/三相短路

为验证本文所提基于 SMA-Adaboost 学习器的孤岛检测方法的性能, 在搭建的单三相混联微网群模型中, 分别将其与其他 3 种不同孤岛检测方法进行仿真验证和对比分析。方法一: 文献[16]基于遗传算法及 BP 神经网络的孤岛检测方法; 方法二: 文献[18]基于 LightGBM 学习器的孤岛检测方法; 方法三: 文献[21]基于 Adaboost 学习器的孤岛检测方法。

#### 4.1 电气特征量相关性分析结果

本次仿真在前述数据划分的基础上, 将检测集进一步按约 1:1 比例划分为验证集和测试集, 分别包含 112 组和 113 组样本数据。其中, 验证集用于在训练过程中评估模型性能并辅助参数调整, 测试集则用于评估最终模型的性能。SMA-Adaboost 学习器采用迭代式优化机制, 训练阶段同一批样本会被

重复使用以不断优化参数配置。因此, 为保障训练过程的收敛性, 本次仿真将最大迭代次数设定为 100。

在初始生成的 750 组数据中, 使用 PLS 法对 PCC 处电气特征量与系统孤岛状态进行相关性分析, 不同三相不平衡度下的相关性分析结果如图 7 所示。采用 PLS 法得到的 VIP 值越大, 对应电气特征量与孤岛检测的相关性越强。从图 7 可知, 其中所有电气特征量的 VIP 值均随三相不平衡度的增大而减小。原因在于, 三相不平衡度的值增大导致其对 PCC 处电气特征量的影响加剧, 电气特征量与孤岛检测的相关性减弱, 检测难度增大。VIP 值大于 1 的电气特征量分别为电压  $U$ 、电压对时间的变化率  $dU/dt$ 、电压总谐波失真率  $U_{THD}$ 、电流对时间的变化率  $dI/dt$ 、电流总谐波失真率  $I_{THD}$ 、频率  $f$ 、频率对时间的变化率  $df/dt$ 、有功功率对时间的变化率  $dP/dt$ , 说明这些电气特征量与系统孤岛状态的相关性较强。其中电压总谐波失真率  $U_{THD}$ 、电流对时间的变化率  $dI/dt$ 、电流总谐波失真率  $I_{THD}$ 、频率  $f$ 、频率对时间的变化率  $df/dt$  的 VIP 值大于 1.2, 说明这些电气特征量与系统孤岛状态的相关性非常强, 且其 VIP 值随三相不平衡度的增大呈现更加明显的变化。而其余电气特征量的 VIP 值均小于 1, 即与系统孤岛状态的相关性较弱。因此本文采用上述 8 个 VIP 值大于 1 的电气特征量组成孤岛检测强相关的电气特征量集合, 作为系统运行状态的判据。

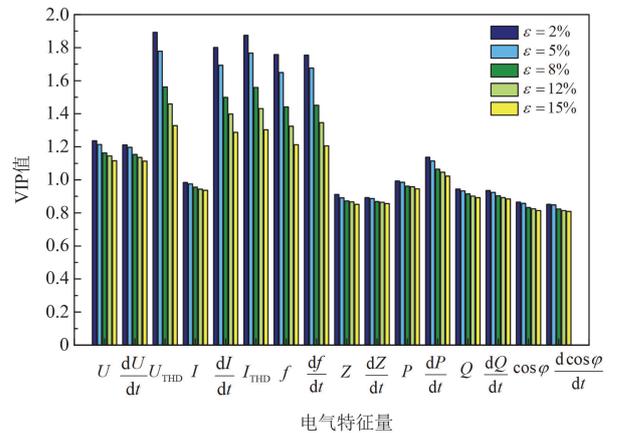


图 7 PCC 处电气特征量与系统孤岛状态相关性分析结果

Fig. 7 Analysis results of correlation between electrical characteristic quantities at PCC and system islanding state

#### 4.2 不同三相不平衡度下的孤岛检测结果

采用 SMA-Adaboost 学习器对生成的强相关电气特征量集合进行训练得到最佳强分类器, 并应用于单三相混联微网群仿真模型进行实时孤岛检测模拟。微网群系统处于不同类型事件时, 三相不平衡

度值会发生变化,因此需要验证三相不平衡度值对本文所提孤岛检测方法的影响,分析不同三相不平衡度值下对应孤岛检测结果的准确性。在三相不平衡度值 $\varepsilon$ 分别为2%、8%和15%的情况下本文所提方法的孤岛检测结果如图8所示。其中孤岛检测信号为0表示检测为非孤岛,为1表示检测为孤岛。当单相三相混联微网群在0.35s时突然进入孤岛状态,经过一定时间检测为孤岛状态后并网断路器断开,系统形成电力孤岛,并网电流变为0,随后PCC处电压开始衰减直至为0。由图8可知, $\varepsilon$ 分别为2%、8%和15%时,本文所提孤岛检测方法分别经过0.114s、0.130s、0.161s检测出微网群的孤岛状态,孤岛检测信号由0变为1。因此可以得出结论:本文所提孤岛检测方法在不同三相不平衡度(满足其值不超过15%的要求)的情况下都能得出较为准确的孤岛检测结果,其检测时间随着三相不平衡度的增大略有变长的规律,但均小于我国标准规定的孤岛检测时间0.2s。其原因在于,本文所提方法利用SMA优化Adaboost学习器的参数寻优过程,增强了全局搜索能力并有效避免局部最优,从而显著提升了强分类器的性能。因此,在检测过程中存在上述扰动因素时,该方法仍能准确识别出微网群系统的孤岛状态。

在不同三相不平衡度条件下,本文所提孤岛检测方法和方法一、方法二、方法三对应的孤岛检测时间如表5所示。由表5可知,相比于方法一、方法二和方法三,本文所提方法在不同三相不平衡度值情况下的检测时间均为最短。在三相不平衡度值为2%时,本文所提方法的孤岛检测时间分别比方法一、方法二、方法三缩短17.39%、13.64%、11.63%。在三相不平衡度值为8%时,本文所提方法的孤岛检测时间分别比方法一、方法二、方法三缩短17.20%、

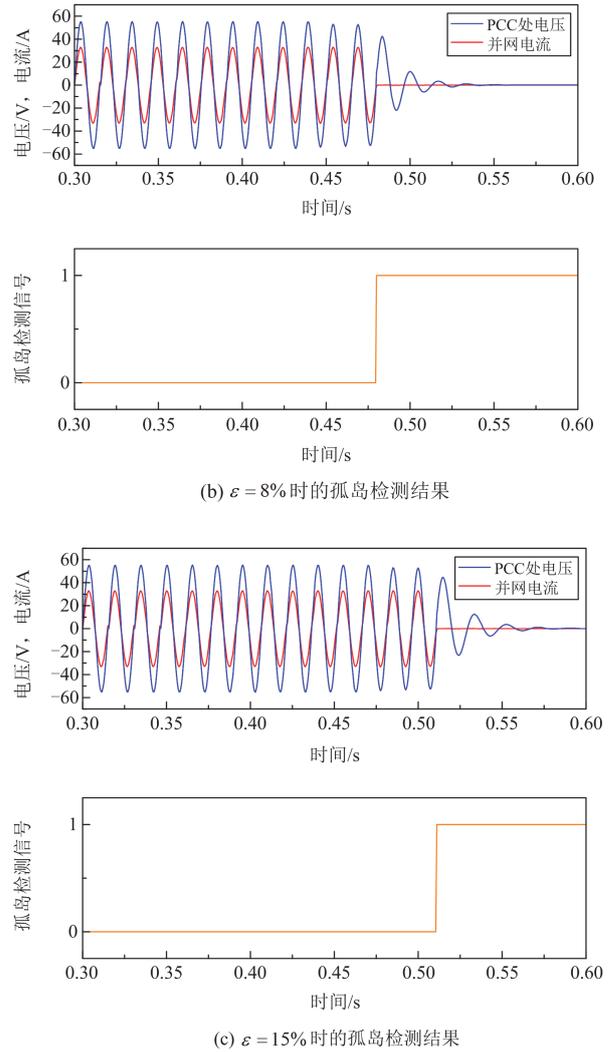


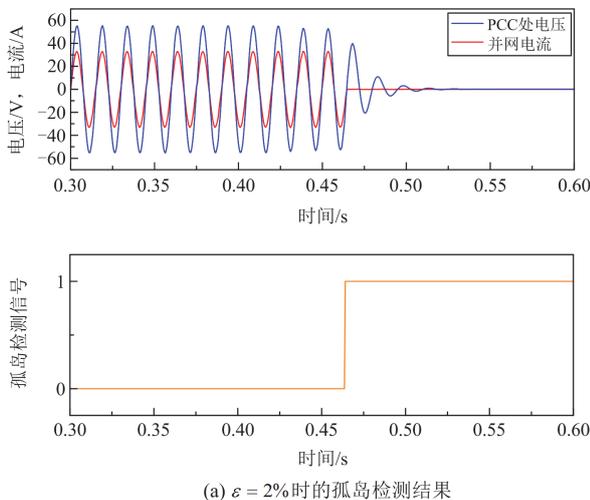
图8 不同三相不平衡度下的孤岛检测结果  
Fig. 8 Islanding detection results under different three-phase unbalance degrees

表5 不同检测方法的孤岛检测时间

Table 5 Islanding detection time of different detection methods

方法	三相不平衡度		
	2%	8%	15%
本文所提方法	0.114	0.130	0.161
方法一	0.138	0.157	0.187
方法二	0.132	0.154	0.184
方法三	0.129	0.148	0.186

15.58%、12.16%。在三相不平衡度值为15%时,本文所提方法的孤岛检测时间分别比方法一、方法二、方法三缩短11.05%、9.55%、8.52%。在三相不平衡度值由2%升高至15%时,4种孤岛检测方法的时间跨度分别为0.047s、0.049s、0.052s和0.057s,本



(a)  $\varepsilon = 2\%$ 时的孤岛检测结果

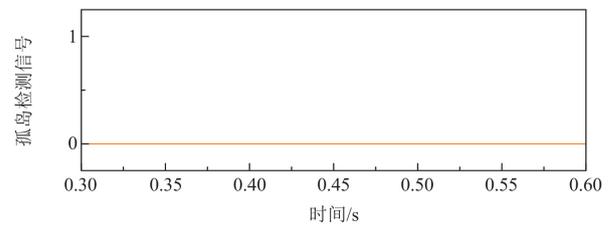
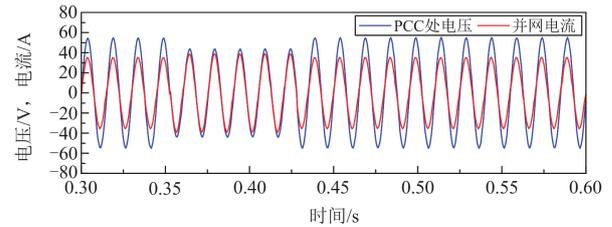
文所提算法的孤岛检测时间跨度分别比方法一、方法二、方法三减少 4.08%、9.62%、17.54%。这说明 4 种孤岛检测方法的耗时都随着三相不平衡度值的增大而增大, 但本文所提方法受其影响最小, 耗时增加最少。这是因为三相不平衡度的值增大时, 电气特征量与孤岛检测的相关性减弱导致相应 VIP 值减小, 检测难度增大, 最终使得检测耗时增加。方法一、二、三均未进行电气特征量的筛选, 同时也未充分考虑三相不平衡度对检测的干扰影响, 所以在同样三相不平衡度下的检测耗时更长, 检测耗时增幅受三相不平衡度的影响更大。而本文在对系统进行孤岛检测之前, 基于 PLS 法提取出与孤岛状态强相关的电气特征量, 剔除了较多弱相关和不相关电气特征量, 极大地简化了孤岛电气特征量数据集的规模, 此外还将 SMA 引入 Adaboost 学习器, 避免了三相不平衡度的干扰影响, 采取 GSN 权重学习方式更新样本权重, 降低了冗余度, 最终达到了缩短检测时间的效果。

#### 4.3 抗干扰性能分析

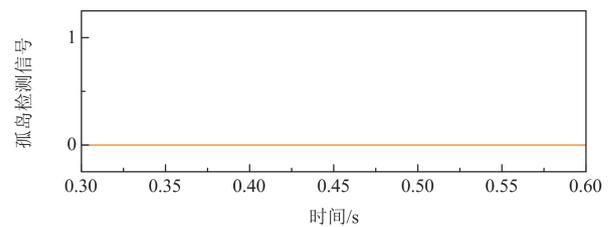
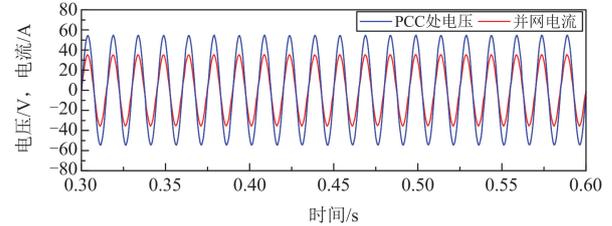
在微网群处于同样的三相不平衡度下, 设置以下两种场景以进一步分析所提孤岛检测方法的抗干扰性能。场景一:  $t = 0.35$  s 时刻并网状态下并网电压幅值暂降 20%; 场景二:  $t = 0.35$  s 时刻并网状态下在电网电压中加入 3% 的二次谐波和 2% 的三次谐波扰动。图 9(a) 为场景一的孤岛检测结果。在该场景下, 微网群的初始状态为并网状态, 在  $t = 0.35$  s 时刻其并网电压突然降低 20%, 直至 0.43 s 时刻恢复为初始幅值大小。由图 9(a) 可知, 当并网电压暂降 20% 时, 并网电流幅值有所增大, 输出功率增大。这是由于微网群处于并网运行状态, 并网电压即为 PCC 处电压, 为了维持系统恒定的有功功率输出, 逆变器在控制系统的调节作用下使并网电流增大。因此在 0.35~0.43 s 期间, 微网群处于一个新的稳定运行状态。在 0.43 s 时刻并网电压恢复为初始幅值后, 逆变器再次在控制系统的调节作用下使并网电流减小, 微网群重新达到初始的稳定运行状态。在该场景下, 本文所提孤岛检测方法在 0.30~0.60 s 期间的检测信号为 0, 检测结果为微网群处于非孤岛状态。因此在场景一下本文所提孤岛检测方法没有发生误判。

图 9(b) 为场景二的孤岛检测结果。在该场景下, 微网群的初始状态仍然为并网状态, 在  $t = 0.35$  s 时刻向电网电压加入 3% 的二次谐波和 2% 的三次谐波扰动, 直至 0.43 s 时刻停止加入谐波扰动。由图 9(b) 可知, 谐波扰动对并网电流的影响较小, 并没有引起明显的电流畸变。另外, 由于微网群依然处于并网状态, PCC 处电压受主电网电压的钳制作用, 几

乎不受谐波扰动的影响。在该场景下, 本文所提孤岛检测方法在 0.30~0.60 s 期间的检测信号为 0, 检测结果为微网群处于非孤岛状态。因此在场景二下本文所提孤岛检测方法同样没有发生误判。由以上孤岛检测的仿真结果和分析可知, 本文所提孤岛检测方法具有良好的识别效果。场景一和场景二均属于孤岛检测存在干扰因素的场景, 而本文所提孤岛检测方法通过 SMA 优化 Adaboost 学习器的参数后, 使学习器的抗干扰能力有所提升。



(a) 场景一的孤岛检测结果



(b) 场景二的孤岛检测结果

图 9 不同场景的孤岛检测结果

Fig. 9 Islanding detection results in different scenarios

#### 4.4 孤岛检测方法的性能对比分析

本文在微网群处于同一三相不平衡度且无扰动因素的情况下将所提孤岛检测方法与方法一、方法二、方法三进行对比分析。采取孤岛检测分类准确率(accuracy, ACC)、灵敏度  $S_E$ 、特异度  $S_P$ 、马修斯相关系数(Matthews correlation coefficient, MCC)以及 ROC 曲线下面积(area under the ROC curve, AUC)值作

为孤岛检测方法的性能评价指标。不同方法的孤岛检测性能如图 10 所示。

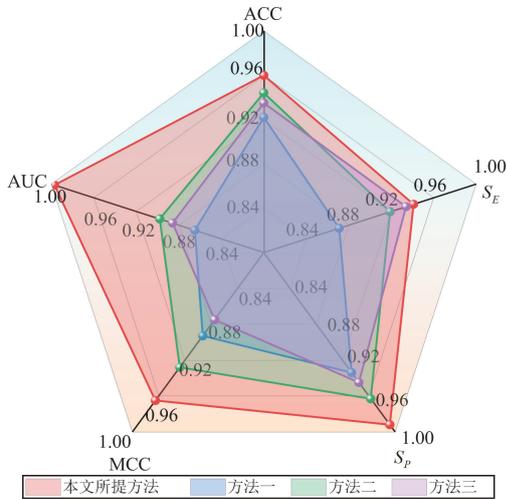


图 10 不同方法的孤岛检测性能

Fig. 10 Islanding detection performance of different methods

由图 10 可知，本文所提孤岛检测方法在 5 个性能评价指标上均优于方法一、方法二、方法三，这是因为本文在 Adaboost 学习器中引入 SMA 和 GSN 权重学习方式，使得最终所得孤岛检测方法具有更强的泛化能力和稳定性。其中，在 ACC 评价指标上，本文所提方法的评价效果最好，即孤岛检测的分类准确率最高为 0.96，相比于方法一、方法二、方法三分别提高了 3.8%、1.6%、2.5%。在  $S_e$  和  $S_p$  评价指标上，本文所提方法的评价效果仍然最好，其次是方法二和方法三，方法一的评价效果最差。其原因在于：方法一没有进行孤岛状态强相关电气特征量的提取；方法二仅对 PCC 处采集到的电气特征量进行了简单的数学处理；方法三考虑并提取出了显著影响孤岛状态的典型特征量。相比于以上方法，本文所提方法通过 PLS 法对与微网群孤岛状态相关性较强的电气特征量进行提取，大大减弱了弱相关电气特征量对孤岛检测判断的影响，提高了检测方法的灵敏度和特异度。在 MCC 评价指标上，MCC 范围在 -1 到 +1 之间，+1 表示分类完全一致，-1 表示分类完全不一致，0 表示随机。本文所提方法的 MCC 最大，说明其分类效果最好。其余方法的 MCC 按大小排序依次是方法二、方法一、方法三，原因在于：方法二通过分层抽样的 K 折交叉验证和引入正则项系数实现了方法检测速度和准确率的小幅提高；方法一采用遗传算法优化 BP 神经网络的局部最优不足，孤岛检测速度和分类准确率有所提高；方法三选取合适的电气特征量后基于 Adaboost 学习器进行孤岛检测，但传统 Adaboost

学习器仍然存在不足，因此分类效果不如本文所提方法。在 AUC 值评价指标上，AUC 值越接近 1，则表明方法性能越好。本文所提方法的 AUC 值最接近 1，其次是方法二、方法三、方法一，分别比本文所提方法低了 9.9%、11.1%、13.2%。

## 5 结论

为了能够在单三相混联微网群发生非计划孤岛时进行可靠的孤岛检测，本文提出了一种基于改进 Adaboost 的单三相混联微网群孤岛检测方法。首先，基于 SMA 和 GSN 提出一种 SMA-Adaboost 学习器，并利用该学习器建立单三相混联微网群的孤岛检测模型。其次，基于 PLS 对 PCC 处的电气特征量进行特征提取，从原始 16 种电气特征量中提取了 8 种与单三相混联微网群孤岛状态强相关的电气特征量。最后，将本文所提孤岛检测方法分别与基于遗传算法及 BP 神经网络的孤岛检测方法、基于 LightGBM 学习器的孤岛检测方法、基于 Adaboost 学习器的孤岛检测方法在由多种事件构成的检测样本中进行了对比，同时在并网电压暂降、注入谐波扰动的场景下分析了该方法的抗干扰性能。仿真结果表明，本文所提孤岛检测方法能够不受三相不平衡度和扰动因素的影响，实现对单三相混联微网群孤岛状态的准确检测，在孤岛检测分类准确率、灵敏度等各个性能评价指标方面均为最优。

## 参考文献

- [1] 杨帆, 杨志淳, 陈鹤冲, 等. 基于低频扰动的多分布式电源孤岛检测方法[J]. 电力系统保护与控制, 2024, 52(16): 132-140.  
YANG Fan, YANG Zhichun, CHEN Hechong, et al. Islanding detection method for multiple distributed power sources based on low-frequency disturbances[J]. Power System Protection and Control, 2024, 52(16): 132-140.
- [2] 邱星宇, 吴毓峰, 王梓耀, 等. 计及并网频率约束的微电网容量优化配置方法[J]. 电力系统保护与控制, 2023, 51(21): 166-177.  
QIU Xingyu, WU Yufeng, WANG Ziyao, et al. Optimal configuration method of microgrid capacity considering grid connection and islanding frequency constraints[J]. Power System Protection and Control, 2023, 51(21): 166-177.
- [3] YANG Wang, TANG Junmiao, SI Jiandong, et al. Power quality enhancement in islanded microgrids via closed-loop adaptive virtual impedance control[J]. Protection and Control of Modern Power Systems, 2023, 8(1): 1-10.
- [4] 米阳, 钱翌明, 张浩杰, 等. 考虑通信异常的直流微电

- 网储能单元分布式协调控制研究[J]. 电力系统保护与控制, 2023, 51(13): 50-59.
- MI Yang, QIAN Yiming, ZHANG Haojie, et al. Distributed coordinated control of a DC microgrid energy storage unit considering abnormal communication[J]. Power System Protection and Control, 2023, 51(13): 50-59.
- [5] HAN Haiteng, XU Yiteng, WU Chen, et al. Nash equilibrium-based two-stage cooperative operation strategy for multi-microgrids considering uncertainty[J]. Protection and Control of Modern Power Systems, 2024, 9(6): 42-57.
- [6] 李锡林, 查晓明, 田震, 等. 频率突变影响下基于 Lyapunov 法的孤岛微电网暂态稳定性分析[J]. 电工技术学报, 2023, 38(增刊 1): 18-31, 55.
- LI Xilin, ZHA Xiaoming, TIAN Zhen, et al. Lyapunov based transient stability analysis of islanded microgrid under the influence of frequency abrupt change[J]. Transactions of China Electrotechnical Society, 2023, 38(S1): 18-31, 55.
- [7] 李文龙, 张新慧, 彭克, 等. 基于锁频环控制的多逆变器孤岛检测方法[J]. 高电压技术, 2023, 49(12): 5217-5227.
- LI Wenlong, ZHANG Xinhui, PENG Ke, et al. Multi-inverter islanding detection method based on frequency-locked loop control[J]. High Voltage Engineering, 2023, 49(12): 5217-5227.
- [8] 曾文入, 王维博, 周超, 等. 应用能量算子和改进 MODWT 的孤岛检测算法研究[J]. 电子测量与仪器学报, 2020, 34(2): 53-59.
- ZENG Wenru, WANG Weibo, ZHOU Chao, et al. Research on islanding detection algorithm based on energy operator and modified MODWT[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 53-59.
- [9] 周林, 谢星宇, 郝高锋, 等. 一种新型的无功功率扰动孤岛检测方法[J]. 太阳能学报, 2020, 41(2): 275-283.
- ZHOU Lin, XIE Xingyu, HAO Gaofeng, et al. A novel reactive power disturbance islanding detection method[J]. Acta Energetica Solaris Sinica, 2020, 41(2): 275-283.
- [10] 贺超, 王冕, 陈国柱. 基于下垂控制的孤岛检测方法及其改进策略[J]. 电力自动化设备, 2015, 35(6): 87-92.
- HE Chao, WANG Mian, CHEN Guozhu. Islanding detection based on droop control and its improvement strategy[J]. Electric Power Automation Equipment, 2015, 35(6): 87-92.
- [11] 戴志辉, 何静远, 于礼瑞, 等. 基于谐波电压突变的无功功率扰动孤岛检测方法[J]. 电机与控制学报, 2023, 27(3): 10-20.
- DAI Zhihui, HE Jingyuan, YU Lirui, et al. Island detection method of reactive power disturbance based on harmonic voltage mutation[J]. Electric Machines and Control, 2023, 27(3): 10-20.
- [12] 陈永华, 唐冠军, 王森, 等. 基于谐波电压与基波频率的被动式孤岛检测方法[J]. 电力系统自动化, 2019, 43(14): 200-206.
- CHEN Yonghua, TANG Guanjun, WANG Sen, et al. Passive islanding detection method based on harmonic and fundamental frequency[J]. Automation of Electric Power Systems, 2019, 43(14): 200-206.
- [13] 朱时雨, 郑涛, 罗美玲, 等. 基于滤波装置短路的孤岛检测法在分布式发电系统中的应用[J]. 电力系统保护与控制, 2015, 43(19): 106-111.
- ZHU Shiyu, ZHENG Tao, LUO Meiling, et al. Islanding detection method based on short-filtering device for DG system[J]. Power System Protection and Control, 2015, 43(19): 106-111.
- [14] 邓聪, 江亚群, 黄纯. 基于不同次数谐波下品质因数一致性的孤岛检测方法[J]. 电力自动化设备, 2020, 40(12): 204-213, 224.
- DENG Cong, JIANG Yaqun, HUANG Chun. Islanding detection method based on consistency of quality factor under different harmonic orders[J]. Electric Power Automation Equipment, 2020, 40(12): 204-213, 224.
- [15] 谢东, 张兴, 曹仁贤. 基于小波变换与神经网络的孤岛检测技术[J]. 中国电机工程学报, 2014, 34(4): 537-544.
- XIE Dong, ZHANG Xing, CAO Renxian. Islanding detection based on wavelet transform and neural network[J]. Proceedings of the CSEE, 2014, 34(4): 537-544.
- [16] 余运俊, 袁国瑛, 万晓凤, 等. 基于遗传算法及 BP 神经网络的混合孤岛检测方法[J]. 可再生能源, 2018, 36(5): 701-706.
- YU Yunjun, ZHONG Guoying, WAN Xiaofeng, et al. A hybrid islanding detection method based on genetic algorithm and BP neural network[J]. Renewable Energy Resources, 2018, 36(5): 701-706.
- [17] 张沛超, 陈琪蕾, 李仲青, 等. 具有增量学习能力的智能孤岛检测方法[J]. 电力自动化设备, 2018, 38(5): 83-89.
- ZHANG Peichao, CHEN Qilei, LI Zhongqing, et al. Intelligent islanding detection method with incremental learning capability[J]. Electric Power Automation Equipment, 2018, 38(5): 83-89.
- [18] 朱春霖, 余成波. 基于 LightGBM 算法的光伏并网系统孤岛检测及其集成的可解释研究[J]. 电力自动化设备, 2023, 43(7): 80-86, 150.
- ZHU Chunlin, YU Chengbo. Islanding detection of grid-connected photovoltaic system based on LightGBM algorithm and its integrated interpretability analysis[J]. Electric Power Automation Equipment, 2023, 43(7): 80-86, 150.
- [19] 李泽林, 刘成颖. 基于 Adaboost 算法的环抛机盘面钝

- 化程度分类[J]. 清华大学学报(自然科学版), 2021, 61(9): 986-993.
- LI Zelin, LIU Chengying. Passivation classification of a continuous polishing machine disk based on the AdaBoost algorithm[J]. Journal of Tsinghua University (Science & Technology), 2021, 61(9): 986-993.
- [20] 刘云鹏, 付浩川, 许自强, 等. 基于 AdaBoost-RBF 算法与 DSMT 的变压器故障诊断技术[J]. 电力自动化设备, 2019, 39(6): 166-172.
- LIU Yunpeng, FU Haochuan, XU Ziqiang, et al. Transformer fault diagnosis technology based on AdaBoost-RBF algorithm and DSMT[J]. Electric Power Automation Equipment, 2019, 39(6): 166-172.
- [21] 贾科, 宣振文, 林瑶琦, 等. 基于 Adaboost 算法的并网光伏发电系统的孤岛检测法[J]. 电工技术学报, 2018, 33(5): 1106-1113.
- JIA Ke, XUAN Zhenwen, LIN Yaoqi, et al. An islanding detection method for grid-connected photovoltaic power system based on Adaboost algorithm[J]. Transactions of China Electrotechnical Society, 2018, 33(5): 1106-1113.
- [22] ZHAO Zhuoli, XU Zhirong, GUO Juntao, et al. Multi-time scale regional autonomous operation strategy for multi-microgrids with three-phase/single-phase hybrid structure[J]. IEEE Access, 2020, 8: 85923-85938.
- [23] 黄鹤, 高永博, 茹锋, 等. 基于自适应黏菌算法优化的无人机三维路径规划[J]. 上海交通大学学报, 2023, 57(10): 1282-1291.
- HUANG He, GAO Yongbo, RU Feng, et al. 3D path planning of UAV based on adaptive slime mould algorithm optimization[J]. Journal of Shanghai Jiao Tong University, 2023, 57(10):1282-1291.
- [24] LI Shimin, CHEN Huiling, WANG Mingjing, et al. Slime mould algorithm: a new method for stochastic optimization[J]. Future Generation Computer Systems, 2020, 111: 300-323.
- [25] 汪小昆, 吴忠贤, 孙晔, 等. 基于叶绿素荧光成像技术的番茄苗热害胁迫智能识别方法[J]. 农业工程学报, 2022, 38(7): 171-179.
- WANG Xiaochan, WU Zhongxian, SUN Ye, et al. Intelligent identification of heat stress in tomato seedlings based on chlorophyll II fluorescence imaging technology[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(7): 171-179.
- [26] 唐浩漾, 王燕, 宋聪, 等. 基于空洞 U-Net 网络的乳腺细胞图像分割算法[J]. 光电子·激光, 2021, 32(5): 470-476.
- TANG Haoyang, WANG Yan, SONG Cong, et al. Breast cell image segmentation algorithm based on dilated U-Net network[J]. Journal of Optoelectronics-Laser, 2021, 32(5): 470-47.
- [27] 金立生, 郭柏苍, 王芳荣, 等. 基于改进 YOLOv3 的车辆前方动态多目标检测算法[J]. 吉林大学学报(工学版), 2021, 51(4): 1427-1436.
- JIN Lisheng, GUO Bocang, WANG Fangrong, et al. Dynamic multiple object detection algorithm for vehicle forward based on improved YOLOv3[J]. Journal of Jilin University (Engineering and Technology Edition), 2021, 51(4): 1427-1436.
- [28] 许志荣, 杨苹, 彭嘉俊, 等. 应对脱离配电网情况的单三相多微网组合分析及切换控制[J]. 电力自动化设备, 2017, 37(9): 1-9.
- XU Zhirong, YANG Ping, PENG Jiajun, et al. Combination analysis and switching control of multiple single/three phase microgrids for active separation from distribution network[J]. Electric Power Automation Equipment, 2017, 37(9): 1-9.
- [29] 石翠翠, 刘媛华. 基于 PLS-MI 组合的天牛须搜索 BP 神经网络模型对汽油辛烷值的预测性能[J]. 石油炼制与化工, 2021, 52(9): 90-97.
- SHI Cuicui, LIU Yuanhua. BP neural network model optimized by beetle antennae search algorithm based on PLS-MI for forecasting gasoline octane number[J]. Petroleum Processing and Petrochemicals, 2021, 52(9): 90-97.

收稿日期: 2024-12-30; 修回日期: 2025-04-10

作者简介:

王 灿(1987—), 男, 通信作者, 博士, 副教授, 研究方向为微电网协同控制与优化运行、高比例新能源电力系统运行与控制; E-mail: xfcancan@163.com

常文涵(2001—), 女, 硕士研究生, 研究方向为微电网孤岛检测与协同控制。E-mail: whccc12345@163.com

(编辑 魏小丽)