

# 基于强化学习的混合元启发式暂态电压稳定特征选择方法及可解释性研究

甄永赞, 阮程

(新能源电力系统国家重点实验室(华北电力大学), 北京市 昌平区 102206)

## Reinforcement Learning-based Hybrid Element Heuristic Transient Voltage Stability Feature Selection and Its Interpretability

ZHEN Yongzan, RUAN Cheng

(State Key Laboratory of Alternate Electrical Power System With Renewable Energy Sources  
(North China Electric Power University), Changping District, Beijing 102206, China)

**ABSTRACT:** Under the development of new power systems, it is of great significance to extract the key response features strongly related to the stability of transient voltage with an effective feature selection for the studies of the mechanism of transient voltage instability and the potential security risks of the system. Therefore, a new feature selection method is proposed based on the composite framework of the improved filtering method and the hybrid element heuristic packaging method. The improved Max-Relevance and Min-Redundancy criterion of symmetric uncertainty value is firstly used to have a coarse screen of the features. Then the Q-learning reinforcement learning is integrated into the meta-heuristic optimization algorithm, and the exploitation and exploration compromise strategy is used to enhance the feature fine selection ability to obtain the optimal critical response feature subset. On this basis, the Shapley additive explanation is applied to comprehensively analyze the influences of each of the screening features on the transient voltage stability and the weak links of the system. The effectiveness of the proposed method is verified by an example of a new power system.

**KEY WORDS:** transient voltage stability; feature selection; reinforcement learning; hybrid element heuristics; Shapley additive explanation

**摘要:** 新型电力系统发展背景下, 使用有效的特征选择方法来提取与暂态电压稳定强相关的关键响应特征, 对研究暂态电压失稳机理与系统潜在安全隐患具有重要意义。为此, 提出一种基于改进过滤法与混合元启发式包装法的复合框架

进行特征选择的新方法。基于对称不确定性值改进的最大相关最小冗余性准则进行特征粗筛; 将 Q 学习强化学习融合至元启发式优化算法中, 并采用开发探索折衷策略以增强特征细选能力, 获取最优关键响应特征子集。在此基础上, 采用沙普利值加性解释归因理论综合分析各筛选特征对暂态电压稳定的影响与系统薄弱环节。新型电力系统算例验证了所提方法的有效性。

**关键词:** 暂态电压稳定; 特征选择; 强化学习; 混合元启发式; 沙普利值加性解释

**DOI:** 10.13335/j.1000-3673.pst.2022.2450

## 0 引言

风光等新能源电源并网规模持续增长<sup>[1]</sup>、传统发电机组退出引起的负荷中心“空心化”<sup>[2]</sup>及高比例电力电子设备投入<sup>[3]</sup>等新电网运行特性将会使暂态电压稳定问题更为突出, 反映系统稳定性的特征量也逐渐增多<sup>[4]</sup>。如何从超高维特征中获取与稳定性强相关且适用于新型电力系统的时空关键响应特征, 是亟待解决的问题。

特征选择是机器学习和统计学中的一项基本任务, 可以从原始高维特征集合中有效选择低维关键特征子集, 提升分类器评估精度<sup>[5]</sup>。其基本方法含过滤法、嵌入法及包装法 3 种。过滤法<sup>[6-7]</sup>使用基于统计度量创建的各特征相关分数筛选特征, 计算相对容易。然而, 过滤法仅根据特征与类标签的单一关联对特征进行排名, 因此倾向于忽略特征之间的相关性。嵌入法<sup>[8]</sup>根据在模型训练过程中的特征权重系数自动选择重要特征, 精度较高, 但存在过拟合与占用大量计算资源的问题。包装法<sup>[9]</sup>将分类算法集成到特征选择过程中, 根据分类效果来选

基金项目: 国家重点研发计划项目(响应驱动的大电网稳定性智能增强分析与控制技术)(2021YFB2400800)。

Project Supported by the National Key R&D Program of China (Response-driven Intelligent Enhanced Analysis and Control for Bulk Power System Stability) (2021YFB2400800).

择特征子集。由于直接优化了目标分类算法, 通常包装法较另外2种方法能够实现更好的分类性能与泛化能力。

事实上, 若原始特征集合维数为 $N$ , 则找到最优子集需要在 $2^N$ 量级中进行搜索, 计算相当困难。因此部分研究中开始采用基于元启发式的寻优方法<sup>[9-11]</sup>, 在合理时间内根据评估函数和停止准则找到较优特征子集, 并尝试应用于电力系统暂态稳定特征子集选择任务中<sup>[12-14]</sup>。尽管元启发式算法在解决特征选择问题方面效果良好, 但单一元启发式方法在面对超大规模的特征选择问题时依旧力不从心。近年来, 人工智能的快速发展为智能优化领域提供了新视角<sup>[15]</sup>, 结合智能优化组件的混合元启发式方法有望更好地应对上述挑战, 而目前在电力系统暂态电压稳定关键响应特征筛选中该方法鲜有涉及。

此外, 特征选择在暂稳分析中的另一重要作用是减少关键响应特征的分析工作量, 促进数据可视化与理解。文献[12]从模型评估的影响角度对所选特征进行了分析, 但未能进一步挖掘时空重要特征并分析潜在失稳机理; 文献[6]采用 Fisher 得分法特征分析工具分析关键响应特征, 但仅给出了特征重要度排名, 同样未能分析特征对稳定性的定性影响; 文献[16]采用 LIME 可解释性分析工具对具体样本稳定性进行了定量预测, 但该方法只能做到局部分析某一样本, 无法对特征全局可解释性进行分析。因此, 选取有效的可解释性分析工具, 对关键响应特征特性深入剖析具有重要意义。

针对目前电力系统暂态电压稳定过程中关键响应特征选取及可解释性分析所存在的问题, 本文提出一种基于改进式过滤法与混合元启发式包装法复合框架进行特征选择的新方法。采用等分滑窗样本构造法以充分捕获时空候选特征; 使用对称不确定性值改进最大相关最小冗余性准则进行特征粗筛, 快速降低特征维数; 将强化学习集成至元启发式优化算法中, 在特征重要性排名引导下进行特征细选, 同时改进算法开发与探索动作策略, 使初始适应度、收敛速度及最终适应解得到改善, 获得用于暂稳评估的最优特征子集, 提升在线评估效果。此外以沙普利值加性解释方法(Shapley additive explanations, SHAP)为可解释性分析工具, 基于中国电科院电压崩溃(China Electric Power Research Institute-Voltage Collapse, CEPRI-VC)分析算例, 定性与定量分析了各筛选特征对暂态电压稳定的影响, 能够为排除系统潜在隐患提供参考。

## 1 等分滑窗时空样本构造法

基于响应驱动的暂态电压稳定评估关键在于学习特征量与样本标签之间的映射关系。因此, 构建全面的原始备选特征集合是暂稳评估的重要基础。随着电网中广泛部署相量测量单元(phasor measurement unit, PMU), 暂态事件发生后系统可以同步获取大量 PMU 数据, 做到实时捕获电气量状态并实时判稳。基于 PMU 流式数据的优势, 在样本集构建过程中若能选取故障前、故障期间和故障后的响应数据, 可以充分考虑历史特征对评估带来的影响, 提取暂态时序演化过程特征信息, 提升评估效果<sup>[17]</sup>。文献[18]提出一种故障前加故障后滑动时窗样本构建方法以捕获时序特征信息。然而, 连续相邻断面的暂态特征因时序变化不明显, 特征间信息差异较小, 不利于分类模型的评估。受其启发, 本文在文献[18]所提方法的基础上进行改进, 提出一种等间隔式滑动时窗样本构造方法, 以增强时序特征信息利用效率。同时, 选择包含新型电网特性电气量作为空间特征, 时空联合构建原始备选特征集合, 尽可能全面覆盖暂态响应时空特征信息。

如图 1 所示, 特征时序采样断面设置为每周期一次。时序样本长度固定为 4 断面, 其中故障前稳态特征 1 个断面, 故障后暂态特征 3 个断面。将滑动时窗自故障发生时刻起至评估时刻断面约等分 3 份, 每个暂态特征分别取每份最后一个时刻断面, 并随时序评估不断向前滑动时窗, 构成“固稳滑暂”时序特征。暂态起点判断方法与文献[18]相同。空间维度应充分考虑新型电力系统特殊之处。除传统电网常用电气量外, 本文将新能源与直流接入对系统暂态电压稳定的影响也考虑在内。备选电气量包括: 1) 火电机组出力与功角、新能源出力、主网传输线潮流和负荷功率; 2) 母线电压幅值、相位



图 1 等分滑窗时空样本构造示意

Fig. 1 Spatial and temporal sample structure of equipartition sliding window

与频率变化量；3) 直流参量，包括送受端正负极触发延迟角、直流电流、直流电压、熄弧角、换相角、直流功率等。此外当电网规模较为庞大时，可以基于电压等级分层体系进行代表性选取。

## 2 基于复合筛选框架的特征选择

同时考虑时空特征时会使备选特征集维数过高，若直接应用于暂稳评估会限制模型分类精度与泛化能力，同时不利于关键响应特征的分析工作。为建立高维时变响应特征和系统稳定性的低维映射关系，本文提出一种基于两阶段复合筛选框架的暂态电压稳定关键响应特征选择方法，对原始备选特征量进行时空降维简化。方法整体流程框图如图2所示，包含以下步骤：

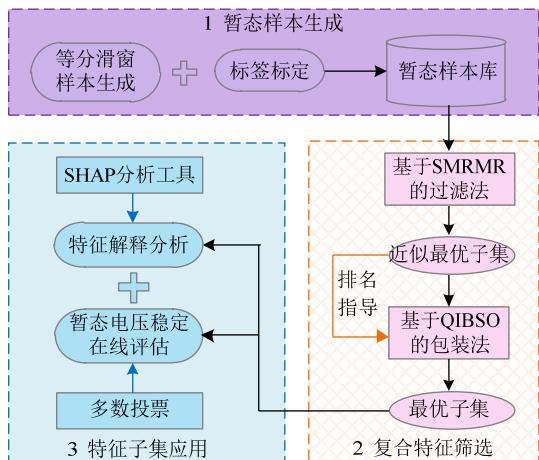


图2 复合特征筛选方法框架

Fig. 2 Framework of composite feature screening methods

1) 暂态样本生成。设置与暂态电压稳定性相关的多种条件，包括故障位置、故障清除时间和马达负载比例等，仿真生成等分滑窗时空暂态样本库。稳定性标签根据文献[19]规定的暂态电压稳定判据进行标定。

2) 基于复合筛选框架进行特征选择。第一阶段采用过滤法剔除冗余与噪声特征，获得近似最优子集，在此基础上第二阶段采用包装法进行特征细选以保留最优子集。

3) 特征子集应用。将步骤2) 细选出的最优子集作为机器学习模型的输入，对电力系统暂态电压稳定进行在线评估。此外，将所选特征对模型输出的影响进行解释性分析，进而得出导致暂态电压失稳的关键响应特征及系统潜在风险因素。

接下来，本节作为核心内容，详细介绍步骤2) 所提复合特征选择框架新方法。

### 2.1 阶段一：基于SMRMR的特征初筛

元启发式方法在直接面临电网高维备选特征

集合时训练速度较慢，且搜索过程缺乏目的性而易导致收敛效果不佳。因此，本文首先通过计算备选特征重要度排名并删减冗余特征，以提升元启发式算法搜索效率。考虑到过滤法一般用于特征选择流程前期来快速降低特征维数，本文选择最大相关最小冗余性准则(max-relevance and min-redundancy, MRMR)<sup>[20]</sup>过滤法进行特征初筛。MRMR除考虑了特征与类别的相关性之外，因还能够计及特征之间的冗余性，使其特征选择能力较其他过滤法表现更优。

原始MRMR基于互信息值表征两随机变量间的相关性。然而，互信息偏向于本身具有更多值的特征，仅使用互信息方法测量特征与类别间的相关性会产生一定偏差<sup>[21]</sup>。为提高筛选能力，采用对称不确定性(symmetrical uncertainty, SU)<sup>[22]</sup>值替换互信息值来补偿互信息方法对更多值特征的偏差，其计算公式为

$$V_{SU}(X, Y) = \frac{2I(X; Y)}{H(X) + H(Y)} \quad (1)$$

式中： $H(X)$  和  $H(Y)$  分别是特征变量  $X$  和  $Y$  的边缘熵； $I(X; Y)$  为  $X$  与  $Y$  间的互信息值。

基于  $V_{SU}$  值获得任意 2 个特征之间的冗余度以及每个特征与类别之间的相关度后，利用 MRMR 方法筛选出一组特征，本文将这 2 个计算步骤统称为 SMRMR 方法。在实际应用中，为减少搜索耗时，一般使用增量搜索算法<sup>[23]</sup>来选取最优特征子集。SMRMR 筛选步骤如下所述：

1) 设原始备选特征集合为  $F$ ，所选特征子集为  $S$ ， $S$  中所含特征数量为  $m$ ，设定保留特征数为  $M$ 。

2) 选择特征值与类别  $V_{SU}$  值最大的特征作为首个已选特征，加入  $S$  并从  $F$  中删除。

3) 根据式(2)计算其余候选特征  $f_j$  的增量值  $A_j$ ：

$$A_j = V_{SU}(f_j; \mathbf{C}) - \frac{1}{m} \sum_{f_i \in S} V_{SU}(f_j; f_i) \quad (2)$$

式中： $\mathbf{C}$  为标签向量； $f_j \in F$ 。

4) 将具有最大  $A$  值的特征  $f_m$  加入  $S$  中，并将其从  $F$  中删除， $m=m+1$ 。

5) 如果  $m \leq M$ ，执行步骤 3)，否则算法终止，输出所选最佳子集  $S$ 。

所得  $S$  即为基于 SMRMR 的初筛特征子集，其保留了重要度较高的特征，计算简单，能够快速剔除冗余特征实现特征降维。同时按特征在  $S$  的排列顺序可以得到特征重要度排名，能够指导后续特征

子集的精细挑选过程, 从而为元启发式特征选择方法建立基础。

## 2.2 阶段二: 基于 QIBSO 的特征细选

基于 SMRMR 得到的特征子集仍存在提升空间。首先, 过滤法的特征子集维数多为人工确定, 该维数并不一定最优, 可能仍包含无用信息。其次, 过滤法在降维过程中脱离评估分类器进行特征选择, 这使其无法根据所得准确率迭代调整所选子集。最后, 其也不能针对电力系统暂态电压稳定中降低失稳样本误判的实际问题。

为进一步改进所选特征子集, 本文采用融合 Q 学习强化学习的元启发式蜂群优化算法进行特征细选, 并改进了部分策略以增强寻优性能。本文记为基于改进 Q 学习的蜂群优化(Q-learning improved bee swarm optimization, QIBSO)算法。

### 2.2.1 改进的 IBSO 算法

元启发式蜂群优化算法(bee swarm optimization, BSO)基于蜜蜂群体合作迭代搜索过程寻找最优解, 因其独有的全局与局部最优解搜索正反馈机制使找到全局最优解的概率有效增加<sup>[24]</sup>, 其通用算法原理可见附录 A。本文基于 BSO 算法进行特征选择, 需要使通用算法适应特征子集搜索问题的具体情况。首先, 对于解的表示形式, 经 SMRMR 选择后的特征子集采用长度为  $l$  的布尔向量表示。如果选择了相应特征则将该位置设为 1, 否则为 0。其次, 对于参考解的生成, 通过在初始解中翻转  $l/f$  位特征生成, 特征布尔从 0 翻转为 1 为添加一个特征, 删除反之,  $f$  为经验参数。

BSO 在处理电力系统高维特征时首先会面临初始适应度较高的问题。因此, 本文改进原 BSO 算法初始解及参考解生成方法, 对初始寻优性能进行优化。将改进算法记作 IBSO, 如下所述:

1) 当初始解需随机生成时, 采用基于帕累托概率原理<sup>[25]</sup>的初始解选择方案替代。该方法是取 20% 的特征作为初始解, 以减少可能的特征组合种类。

2) 在采用帕累托原理确定初始解维数的基础上, 保留的特征组合根据重要度排名指导, 优先采用分数高的特征组合作为初始解。在生成参考解时, 同样优先翻转高重要度值特征作为后续搜索基础。

确定较为合理的初始解与参考解特征维度及内容, 可以抵御算法在迭代初期陷入停滞, 对解决 BSO 初始适应度值较高的问题具有较好帮助。

### 2.2.2 Q 学习替代盲目局部搜索

在 IBSO 算法中, 当蜜蜂被分配参考解后会执

行经典的局部搜索过程。该过程中每个访问解都是通过评估其所代表的特征子集给出的分类适应度值得出的, 蜜蜂从不使用搜索历史中所获经验, 因此局部搜索过程十分缓慢, 且只能聚焦于短期利益而无法达到最终最优。考虑到强化学习能够通过智能体与环境交互选择最优策略指导动作, 文献[26]提出使用 Q 学习代替 BSO 局部搜索的方法, 有效提升了寻优性能。考虑 Q 学习引入 IBSO 的可迁移性, 本文将其应用于暂态电压稳定特征子集精细选择中, 进一步增强 IBSO 寻优性能。

Q 学习通常使用马尔可夫决策过程(Markov decision process, MDP)来描述<sup>[27]</sup>。在融合 Q 学习的搜索过程中本文定义了以下元素: 将蜜蜂视为智能体, 状态  $s$  是蜜蜂附近所有可能的解决方案, 动作  $a$  为翻转, 与一对  $(s,a)$  相关的奖励  $r$  基于式(7)计算。

若定义式(3)为所有  $(s,a)$  的最优 Q 函数, 则智能体的目标是找到一个最优策略, 使期望长期奖励最大化, 即最优值函数  $\mathcal{V}^*(s)$  可如式(4)所示:

$$\mathcal{Q}^*(s,a) \triangleq \sum_{t=0}^{\infty} \gamma r_t(s_t, a_t) |_{s_0=s} \quad (3)$$

$$\mathcal{V}^*(s) = \max \{ \mathcal{Q}^*(s,a) \} \quad (4)$$

式中:  $0 \leq \gamma \leq 1$  为折扣参数, 如果  $\gamma$  接近于 0, 智能体倾向于选择即时回报, 反之倾向于考虑长期回报;  $t$  为局部搜索迭代数。

MDP 问题简化为对所有动作状态对寻找 Q 函数最优值。采用时序差分法<sup>[26]</sup>迭代求解, Q 函数按式(5)更新, 并将所得 Q 值储存在对应各  $(s,a)$  的 Q 表中, 当所有 Q 值收敛或达到迭代次数后算法终止。

$$\mathcal{Q}_{t+1}(s,a) = \mathcal{Q}_t(s,a) + \alpha[r_t(s,a) + \gamma \max_{a'} \mathcal{Q}_t(s,a') - \mathcal{Q}_t(s,a)] \quad (5)$$

式中: 学习率  $\alpha$  用于确定新信息对现有 Q 值的影响;  $a'$  为下一步可能采取的动作。

在融合强化学习的 IBSO 算法中, 蜜蜂摒弃了原始随意评估所访问解的盲目局部搜索, 其在 Q 表的精确引导下采取可使长期收益最大化的动作, 从而能够返回更优质的特征子集并提升寻优效率。

### 2.2.3 开发与探索折衷策略

智能体在搜索时面临的一个重要问题是开发与探索折衷, 即何时促进探索未知的状态和行动相对于开发早期得到的状态和行动能够获得更多奖励。有效的开发与探索折衷策略对算法在迭代初期偏向探索以跳出局部最优、在迭代后期偏向开发以

收敛到最优解尤为关键。

考虑到折扣参数  $\gamma$  能一定程度衡量即时回报与长期利益, 若能在迭代初期采用较大值来考虑更大比重的未来奖励, 后期采用较小值来注重即时开发奖励, 则有望使算法偏向于初期探索与后期开发。因此, 本文将原始  $\gamma$  固定参量值修改为随迭代次数递减的变化量, 其变化规律如下式所示:

$$\gamma_i = 0.5 - 0.5 \times \frac{i-1}{I_{\max} - 1} \quad (6)$$

式中:  $i$  为当前迭代数;  $I_{\max}$  为最大迭代数。

#### 2.2.4 改进的子集评价准则

基于 QIBSO 的特征选择算法以获得更高评估精度和更低特征子集维数为评价准则, 通常采用适应度值  $V_{\text{Fit}}$  来衡量, 其目标函数形式定义为

$$V_{\text{Fit}}(S) = \lambda_1 E(S) + \lambda_2 \frac{|S|}{|F|} \quad (7)$$

式中:  $F$  为 SMRMR 所保留的特征集合;  $S$  为两阶段所选特征子集;  $0 < \lambda_1, \lambda_2 \leq 1$  为权重系数;  $E$  为分类器采用该特征子集进行评估所获得的分类误差。

电力系统稳定评估问题对漏判情况更为关注, 因为这会导致系统崩溃等严重后果。以正类代表稳定样本, 以负类代表失稳样本, 将漏判(失稳判为稳定)记为假正(false positive, FP), 误判(稳定判为失稳)记为假负(false negative, FN), 稳定、失稳判断正确分别记为真正(true positive, TP)与真负(true negative, TN)。鉴于上述概念, 定义子集评价指标精度(precision, P)、召回(recall, R)的概念如下:

$$P = \frac{n_{\text{TP}}}{n_{\text{TP}} + n_{\text{FP}}} \quad (8)$$

$$R = \frac{n_{\text{TP}}}{n_{\text{TP}} + n_{\text{FN}}} \quad (9)$$

式中  $n$  为某类样本个数。

为了有效降低漏判率, 本文在设置  $V_{\text{Fit}}$  目标函数时考虑给予 FP 更高关注, 采用基于 F-beta 分数的漏判惩罚策略, 有:

$$E = 1 - \frac{(1 + \beta^2)PR}{\beta^2 P + R} \quad (10)$$

本文设置  $\beta$  为 0.2 以给予精度更大权重。

#### 2.2.5 QIBSO 特征选择流程

所提 QIBSO 算法的总体特征选择流程及优化策略如图 3 所示, 其步骤为:

1) 设 SMRMR 所保留的备选特征集合为  $F$ , 所选特征子集为  $S$ 。初始化  $S$ 、禁忌表与舞蹈表。

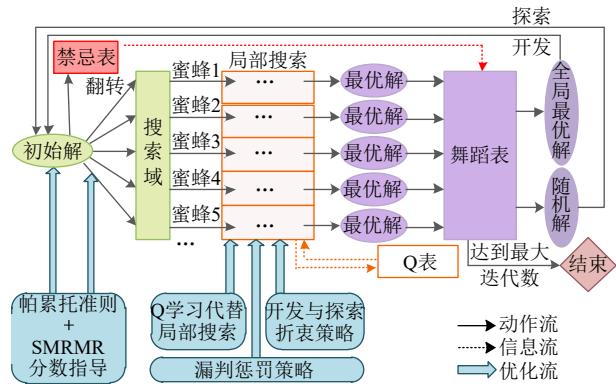


图 3 QIBSO 算法流程

Fig. 3 QIBSO algorithm flow

2) 确定初始解。对于  $S$  为空或舞蹈表返回随机解的情况, 依次向  $S$  中加入排名分数由高到低的特征, 特征数量为  $0.2|F|$ 。其余情况按上轮迭代所返回的全局最优解作为初始解。

3) 确定搜索域。对初始解进行翻转操作构造搜索域。翻转位置依次为排名分数由高到低的特征。

4) 局部搜索。基于 Q 学习进行局部搜索, 在此期间寻找各蜜蜂局部最优解, 同时更新 Q 表。

5) 确定全局最优解。选择各蜜蜂返回的最优解中评估效果最好的特征子集作为全局最优解, 并返回步骤 2) 进行开发。若评估结果没有改进, 则生成随机解返回步骤 2) 进行探索。

6) 停止条件。当达到最大迭代次数时算法停止。返回找到的全局最优特征子集即为所求。

### 3 特征子集应用

基于复合筛选框架选择的最优特征子集在暂态电压稳定分析中有两方面主要用途。一方面, 可以基于特征子集构建评估模型, 用于在线判稳; 另一方面, 基于所选特征与稳定性间的强相关性, 分析其中可能蕴含的关键知识。

#### 3.1 暂态电压稳定在线评估

所提框架可以采用任意分类器算法构建判稳模型用于暂态电压稳定评估, 具备较好兼容性。在本文中, 学习算法采用原理简单且易于实现的( $k$  nearest neighbors, kNN)分类器, 并基于漏报警率(missing alarm rate, MAR)与误报警率(false alarm rate, FAR)定义其在线评估评价指标漏判率与误判率, 以及准确率(accuracy, ACC)为

$$\eta_{\text{MAR}} = \frac{n_{\text{FP}}}{n_{\text{FP}} + n_{\text{TN}}} \quad (11)$$

$$\eta_{\text{FAR}} = \frac{n_{\text{FN}}}{n_{\text{FN}} + n_{\text{TP}}} \quad (12)$$

$$\eta_{\text{ACC}} = \frac{n_{\text{TP}} + n_{\text{TN}}}{n_{\text{TP}} + n_{\text{TN}} + n_{\text{FP}} + n_{\text{FN}}} \quad (13)$$

此外，由于本文采用随时序不断向前滑动的在线评估形式，可能会面临不同时刻分类器所给结果不一致的问题。为进一步提高评估准确性，采用判稳时窗多数投票法进行结果输出<sup>[28]</sup>。时窗范围内各断面给出该时刻评估结果，当多数结果一致时输出判断结果以确定是否发出失稳警报。其中时窗窗长与投票阈值的确定对最终准确率有较大影响。本文考虑设置时窗长度为6个时序断面，投票阈值为5票，以兼顾评估总时长与准确率的要求。

### 3.2 特征可解释性分析

分析所选特征对模型输出结果的积极或消极作用，可以得出导致暂态电压失稳的关键响应特征及潜在原因。因此，选择一种合理可解释性分析工具，对于确保解读结果的准确性与可靠性至关重要。

SHAP 归因分析工具作为一种利用合作博弈理论评估多重共线性变量重要性的新兴可解释人工智能方法<sup>[29]</sup>，已初步应用于暂态稳定关键特征智能分析研究中<sup>[4,30]</sup>。相较传统特征重要性评估方法，其主要优势在于：1) 对于特征，能够显示所有特征的重要性排名及某特征对所有样本的定量贡献度；2) 对于样本，可以显示某样本中各特征对模型预测值的正面或负面贡献程度；3) 可以为任何

分类器模型确定值。因此，本文将其作为暂态电压稳定评估中分析关键响应特征的工具。

SHAP 通过计算特征归因值(Shapley value)来反映特征对总体模型预测值的边际贡献程度。每个特征的贡献可负可正，取决于其对预测的影响情况。所有特征 Shapley 值之和是模型的评估输出，如式(14)所示。

$$g(z) = \phi_0 + \sum_{j=1}^{|F|} \phi_j \quad (14)$$

式中： $z$  代表某一样本； $\phi_0$  是模型对样本的预测基准值； $\phi_j$  是每个特征的贡献； $F$  为最优特征子集。各特征的综合贡献  $g(z)$  便可以反映 SHAP 对判稳的置信程度。

## 4 算例分析

采用中国电科院电压崩溃(CEPRI-VC)分析算例验证所提方法有效性，系统接线如图 4 所示。该算例描述了高比例新能源接入的交直流混联电网，共 100 节点，其中 500kV 主网架 32 个节点。新能源(240 万 kW)与常规电源(630 万 kW)装机比例为 1:2.62。基本运行方式为新能源发电 180 万 kW(风电 120 万 kW, 光伏 60 万 kW)和常规机组发电 386 万 kW。系统内一回直流，直流受入功率 80 万 kW。基于 BPA 平台搭建仿真算例，数据处理和模型训练在 MATLAB 2020 和 Python 3.9 中联合进行。

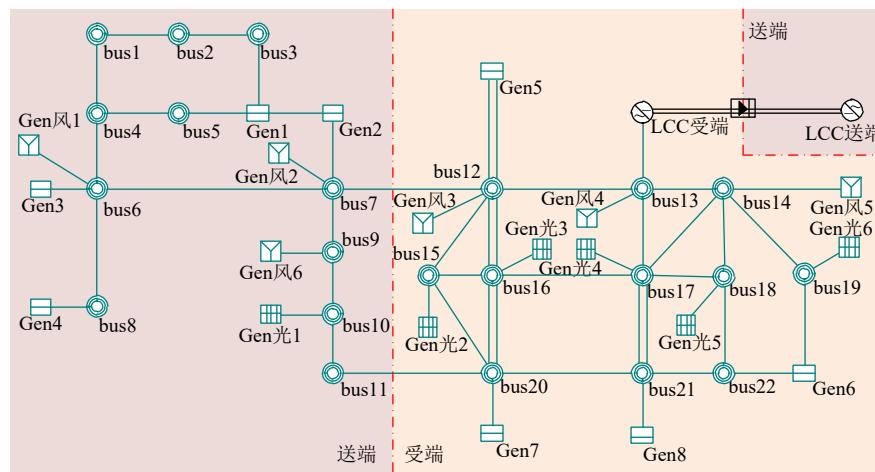


图 4 算例接线图  
Fig. 4 Example wiring diagram

### 4.1 样本与特征生成

设置多种操作条件和故障以涵盖与暂态电压稳定相关的重要事件。首先，在 500kV 主网架各线路分别设置三相短路故障，故障发生时刻设置为仿真开始后 1s，故障位置为距离某条线路首端 2%、50% 和 98% 处。其次，设置 3 至 10 周期共 8 种故

障切除时间，切除方式为该回线两侧断路器跳开。最后，电机负载比例分别设置为 40%、50%、60% 和 70% 共 4 种情况。采用等分滑窗时空样本构造法，共得到 4224 条样本，每条样本各评估断面的原始备选特征集含 1168 维特征，其中空间维度选择 500kV 电压等级相关电气量，共 292 维，时序 4 维。

算法训练集与测试集比例设置为 4:1。

## 4.2 复合特征选择框架有效性评估

将各阶段特征选择子集维数、多数投票评估准确率及在线评估用时结果列入表 1。其中，空间及时序特征数指各级备选特征集合经降维后所保留的平均个数。SMRMR 设置保留 50 维特征，相关算法超参数如附录 B 所示，各级分类器均采用十折交叉验证取平均的方式进行验证。此外，图 5 中给出了各级分类器均对完整测试集进行验证的漏判率与准确率变化结果，并与多数投票法进行对比。

由表 1 可知，原始特征集经两阶段精细筛选后仅保留 15.02 个具有较高重要性权重的特征，超过 98% 的特征被认为对学习过程没有明显影响；空间维度特征削减比例达 96.52%，时序维度也削减了 63%，从而对时空特征进行了有效降维。在评估准确率上，得益于严苛的失稳漏判惩罚条件，评估模型可以在最少特征子集维数下给出最低漏判率，并

保持较高的准确率。由于特征子集维数有效降低，在线计算时仅需 0.041s 便可得到判稳结果，能够满足在线实时应用需求。

为了说明采用两阶段复合特征筛选框架的必要性与互补性，对仅使用 SMRMR 与仅使用 QIBSO 方法所筛选特征子集进行性能评估。由表 1 可见，若仅采用 SMRMR 所选特征子集进行评估，准确率虽已较优，但相较复合框架其特征维数与漏判率依旧存在提升空间。仅使用 QIBSO 方法时，由于原始备选特征集维数较高且缺乏重要度排名指导，智能体会在寻优过程中面临初始解及参考解确定困难的问题，导致算法在搜索初期便停滞不前，只能收敛于局部最优解，因而所得特征子集维数与漏判率也并非最优。因此单独采用某种方法均不能得到最优特征子集，只有在过滤法结合包装法增强寻优，且包装法基于过滤法降低特征维数与排名分数指引才能获得子集维数与漏判率兼优的结果。

表 1 特征选择评价指标对比  
Table 1 Feature selection evaluation index comparison

特征选择阶段	平均子集维数/个	空间特征数/个	时序特征数/个	漏判率/%	误判率/%	准确率/%	在线计算用时/s
未降维	1168	292	4	3.021	1.383	97.969	0.154
仅 SMRMR	50.00	37.51	1.33	1.220	1.193	98.797	0.071
仅 QIBSO	79.21	55.01	1.44	1.016	2.166	98.106	0.089
SMRMR+QIBSO	15.02	10.15	1.48	0.920	1.775	98.559	0.041

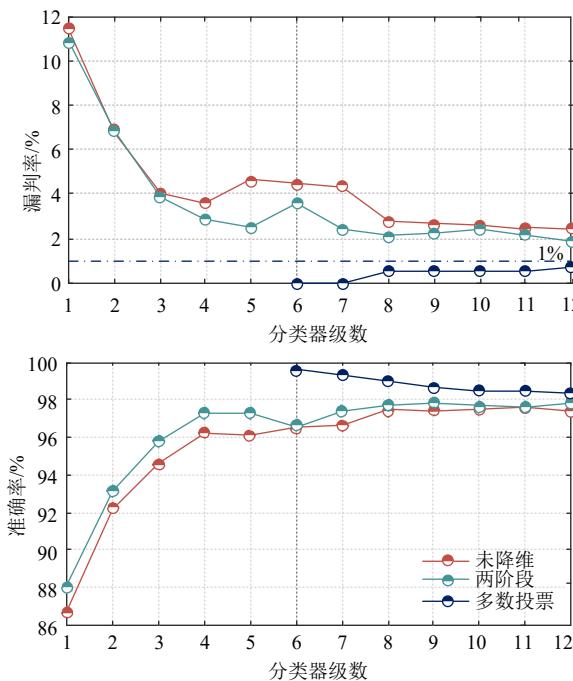


图 5 各级分类器评估结果

Fig. 5 Evaluation results of different classifiers

此外由图 5 评估结果可知，经特征选择后各分类器均能减少漏判并提升准确率，但评估前期的准确率偏低，可信度不高。采用多数投票法至所有样本判完为止后，模型能够以低于 1% 的漏判率、0.34s

总评估时长完成全部样本判稳任务，有效兼顾了判稳精度与时间，这也是采用多数投票法的意义所在。

## 4.3 包装法对比

对包装法中经常使用的四种启发式寻优算法与本文所提方法进行收敛结果比较，包括鲸鱼算法 (whale optimization algorithm, WOA)、粒子群算法 (particle swarm optimization, PSO)、遗传算法 (genetic algorithm, GA) 和灰狼算法 (grey wolf optimization, GWO)。此外为验证对原始 BSO 算法所提改进策略的有效性，同时对 IBSO 与 QIBSO 寻优曲线进行对比。过滤法均采用 SMRMR，相关算法超参数见附录 B，20 次测试平均收敛曲线如图 6 所示。

可见，由于原 BSO 算法只能进行简单的局部搜索，从不使用其寻优过程中获得的经验且只能专注于短期收益，与常见算法相比寻优效率表现并不突出。IBSO 改进了初始解与参考解生成过程，使算法能够选择在重要性更高的特征附近初始化搜索流程，在初期便围绕局部或全局最优解进行搜索，因而具备最小的初始寻优适应度值，间接优化了全局最优解的搜索结果。QIBSO 混合元启发式算法作为 IBSO 的进阶提升，首先以特有的 Q 学习代

替盲目局部搜索过程,使每只蜜蜂可以从 Q 表中受益,尽可能避免无用搜索过程,使得适应度曲线在前期降幅明显,能够较快进入精细开发阶段;同时所提开发与探索折衷策略能够帮助代理在前期倾向于探索未知解以跳出局部最优,因而获得了比 IBSO 更好的解决方案,最终解适应度值最低。验证了本文所提改进方法在改进初始适应度值、寻优效率与最终解上的有效性。

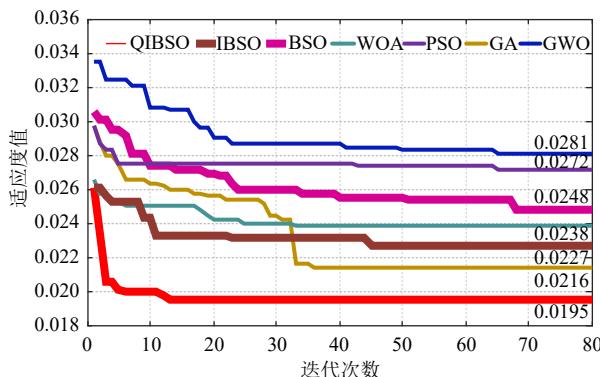


图 6 各寻优算法适应度曲线

Fig. 6 Fitness curves of each optimization algorithm

此外,对上述方法在特征子集维数、3 种模型评价准确率指标及寻优用时上进行对比。如表 2 所示,对比各方法指标优劣可以发现:1) BSO 在较为关注的子集维数、漏判率和准确率上较其余几种寻优算法有较大优势,但其寻优用时漫长,误判率也较高,因而存在一定提升空间;2) QIBSO 相较 BSO 在其弱势项上有较大改进,寻优用时提升 20% 左右,误判率也有效降低,综合排名均位于各方法前列。

表 2 各寻优方法评价指标对比

Table 2 Comparison of evaluation indexes of each optimization method

寻优方法	特征子集维数	漏判率/%	误判率/%	准确率/%	寻优用时/s
WOA	16.17	0.927	2.376	98.197	<b>1935.85</b>
PSO	19.42	1.520	1.969	98.208	2176.36
GA	15.59	1.824	<b>1.486</b>	98.362	2370.25
GWO	17.50	1.813	1.976	98.088	2201.59
BSO	<b>14.52</b>	0.923	1.984	98.432	2512.66
QIBSO	15.02	<b>0.920</b>	1.775	<b>98.559</b>	2025.69
BSO 排名	<b>1</b>	2	5	2	6
QIBSO 排名	2	<b>1</b>	2	<b>1</b>	2

为直观体现本文方法所筛选特征的特有优势,基于失稳场景观察相关特征变化情况。本例中交流线路 17-21 首端发生三相短路故障并持续 0.2s,该场景下系统发生电压崩溃事故。同时与 SMRMR+WOA(方法 1)、SMRMR+PSO(方法 2)所筛选特征子集变化情况进行对比。

图 7 展示了部分特征量的响应波形。在负荷有

功特征上,3 种方法均能成功筛选出变化幅度达 158.03MW 的母线 15 负荷有功特征,比母线 12 有功负荷变化量 150.67MW 更优。在电压特征上,考虑对所有火电机组机端母线电压的变化情况进行对比。此时 3 种方法均能筛选出变化幅度更大的 G5—G8 机群机端电压特征,但在该群电压波动趋势极为接近的情形下,仅有本文方法能将具有特殊变化特性的 G5 机端电压特征挑选出来,另外 2 种方法仅粗略选择了某一母线电压。在无功特征上分别选择 1.22s 与 1.2s 断面、1.3s 与 1.22s 断面进行对

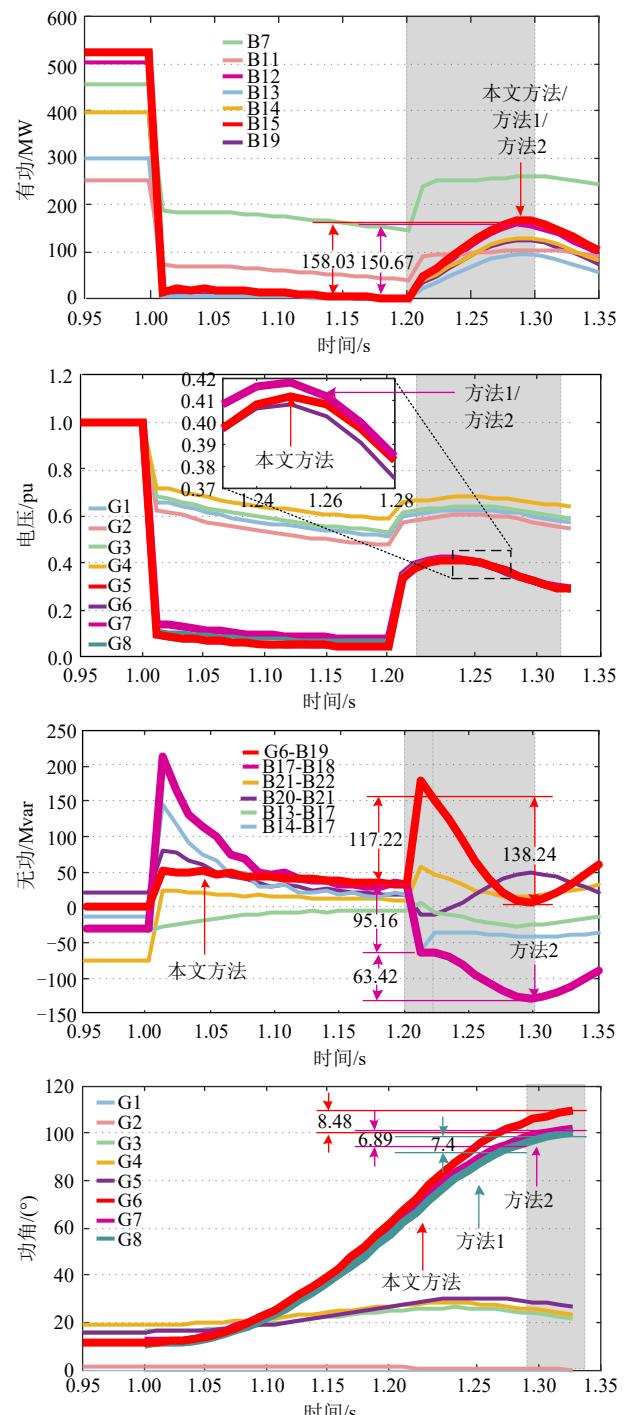


图 7 特征量响应波形

Fig. 7 Characteristic quantity response waveform

比。本文方法均能够在两时刻选择 G6-B19 线路无功特征，其变化量分别是方法 2 所选择特征的 1.23 倍与 2.18 倍，而方法 1 直接遗漏该关键响应特征，效果不佳。功角特征也仅有本文方法能从变化趋势最大的机组群中精细选择其中变化最为明显的特征。综上所述，本文所提特征选择方法能够筛选变化更加细致的特征，从而有利于判稳准确率提升。

#### 4.4 过滤法对比

过滤法作为复合筛选框架第一阶段方法，其筛选有效性直接影响第二阶段特征精细搜索结果，因而有必要验证所用 SMRMR 方法有效性。包装法与分类器仍采用 QIBSO 与 kNN，过滤法分别采用基于相似度理论的皮尔逊相关系数法(Pearson)、ReliefF 和 Fisher 得分法，以及基于信息论的联合互信息(joint mutual information, JMI)法。此外采用原始 MRMR 算法以验证对其改进的有效性。各方法均保留 4.2 节 SMRMR 相同特征子集维数，模型评价指标如表 3 所示。

表 3 过滤法对比

Table 3 Comparison of filtration methods

类别	方法	漏判率/%	误判率/%	准确率/%
基于相似度	Pearson	2.454	1.972	97.839
	ReliefF	2.432	2.432	97.485
	Fisher	2.682	1.453	98.071
基于信息论	MRMR	2.154	1.420	98.289
	JMI	1.223	<b>1.378</b>	<b>98.683</b>
	本文方法	<b>0.920</b>	1.775	98.559

可以发现，基于相似度论的过滤法因未能考虑特征间的冗余而导致准确率均偏低。基于信息论的方法中，原始 MRMR 因考虑了特征间的冗余性，较相似度论方法有一定改进，但存在漏判率高的问题，而本文对其改进后可以大大降低漏判率，验证了考虑 SU 值的有效性。JMI 准确率虽最优，但其漏判率仍较 SMRMR 方法高，不符合电力系统要求失稳漏判率低的要求。综合考虑，选取漏判率最低且准确率兼优的 SMRMR 方法有利于为包装法精细搜索提供较优的特征子集。

#### 4.5 等分滑窗策略有效性评估

为验证所提等分滑窗法构造原始特征子集的有效性与必要性，将仅采用评估断面特征、文献[18]所提滑动时窗构建方法与本文方法构建的特征子集分别训练判稳模型，降维方法均采用复合特征选择框架，结果如表 4 所示。

在缺乏时序历史特征支撑的情况下，单断面特征构造法中模型只能通过捕获当前断面的更多空间特征信息进行判稳，导致特征冗余性提高，准确率较差。文献[18]所提方法能一定程度考虑历史特

征对评估的影响，但时序暂态特征的采集冗余问题使评估效果有一定折扣。因此，本文所提特征构造方法有助于在保留更加充分与多样化的关键响应特征信息同时降低特征维数，提升判稳效果。

表 4 特征构造方法对比

Table 4 Comparison of feature construction methods

方法	子集维数	漏判率/%	误判率/%	准确率/%
单断面构造	18.59	2.872	4.395	95.810
文献[18]	15.23	1.216	2.166	98.208
等分滑窗法	15.02	0.920	1.775	98.559

#### 4.6 泛化性能验证

为进一步检验所提复合筛选方法的泛化性能，本文考虑了初始样本集中未涉及的 3 种操作场景：1) 线路 B13-B17 因检修需要断开，以模拟在线监测期间的意外拓扑变化；2) 考虑新能源场站建成投运对系统的影响，在节点 11 处接入与节点 10 等规模光伏场站；3) 新增 3 种运行方式。此外为真实模拟未知位置故障，在施加故障时随机摄动故障位置。每种场景生成 1032 条样本，采用本文复合筛选框架进行特征选择与准确率评估测试。适应性测试结果如表 5 所示。

表 5 泛化性能验证

Table 5 Generalization performance verification

场景	子集维数	漏判率/%	误判率/%	准确率/%
原场景	15.02	0.920	1.775	98.559
场景 1	15.88	0.619	1.205	99.026
场景 2	13.27	0.923	2.012	98.418
场景 3	15.32	0.906	2.165	98.331

可以看出，本文所提方法在新场景中的总体评估准确率能够保持在 98% 以上，且漏判率较低。它成功解决了未曾发生的 N-1 条件，意味着所提方法对未知拓扑变化的适应性较好；当弱电压支撑能力的新能源并网规模持续增长或系统运行方式发生调整时，其也可以适应新场景下的评估任务。因此，本文方法能有效应对不熟悉的工况和初始未覆盖的暂态事件，适应性较好。

#### 4.7 关键响应特征特性剖析

基于最优特征子集，本文从统计分析及 SHAP 可解释性分析两方面挖掘了暂态过程中的关键响应电气量，并对其暂态电压失稳机理进行了解读。

##### 4.7.1 特征统计及分析

对所筛选特征的出现频次及时空演化分布规律进行初步统计分析。将各级分类器高频特征列入表 6 中(其中 S1—S4 分别为稳态断面、评估时刻前第二个采样断面、评估时刻前第一个采样断面及评估时刻断面，下同)，并对各级特殊元件(新能源、直流)及送端系统(图 4 紫色区域)关键响应特征占比

进行统计，如图 8 所示。

分析以上统计结果，有以下特点：

1) 高频特征中呈现 S4 占比最高、S3 次之的分布规律。大多数情况下评估时刻的特征信息最重要，而历史特征对稳定性评估也有较大的补充作用。因此仅靠单断面特征进行评估存在缺陷，往往会遗漏历史特征的有关重要特性。

2) 呈现以负荷有功为主导、母线电压为次主导的特征主导形式，尤其以节点 15 有功负荷及发电机 5 号母线电压出现频次居多，与 4.3 节分析中电气量波动更大及异常波动特性的现象相符合。因此，相较暂态电压稳定评估常用的无功特征，负荷有功特征也是值得关注的关键响应特征。

3) 高频特征中没有出现线路潮流特征。这是由于线路潮流与负荷功率互为冗余特征，特征选择算法能够有效识别冗余特征并保留波动幅度较大的负荷特征。

4) 新能源、直流相关特征随时间推移占比逐渐降低至零，这与电力电子装备的快速动态响应特性有关。因此对于新型电力系统，新能源、直流等稳定特征量是暂态电压失稳初期的关键响应特征。

5) 时序演化过程中受端系统相关特征占主导地位，其中部分特征的空间分布呈现出由受端地区向送端地区转移、再移回至受端地区的特性。受端地区特征主导占比与暂态电压失稳多发生于负荷节点有关，负荷节点失稳后若没有及时采取干预措施，可能会逐步发展为整个电力系统失稳，在此过程中因送受端电气量深度交织、电力系统振荡伴随发生等而易产生主导特征空间分布转移现象。

#### 4.7.2 基于 SHAP 的特征可解释性分析

为深入探究特征与稳定性间的定性关系，量化失稳机理及系统薄弱环节，以 1.34s 断面为例，绘

制筛选后保留的特征落点如图 9 所示，并采用 SHAP 归因分析法分别从特征及样本角度展开研究。

1) 特征角度。

图 10 绘制了部分特征所有样本点 Shapley 值与特征本身数值的大小摘要图，其中 Shapley 值越大代表对认为失稳的贡献越大，颜色越红代表特征数值越大。根据对失稳总体影响程度大小，自上而下确定了经选择后所保留的前 10 名特征。这些特征因沿水平轴广泛扩展且呈“纺锤”状分布，其良好的分布特性能够有效区分稳定与失稳样本，提升评估准确性。

基于 Shapley 值可以间接得到特征值大小与稳定性间的相关关系。图 11 展示了节点 22 电压及节点 16 有功特征样本 Shapley 值与具体特征值间的分布关系。当特征值越小，Shapley 值越高，从而更容易发生暂态电压失稳。具体地，当节点 22 电压

表 6 高频特征统计

Table 6 High frequency feature statistics

频次	特征
8	S4-B15-P
7	S4-G5-U
6	S4-B14-P, S4-B16-U, S3-B12-P
5	S4-B12-P, S4-B19-P, S3-B19-P

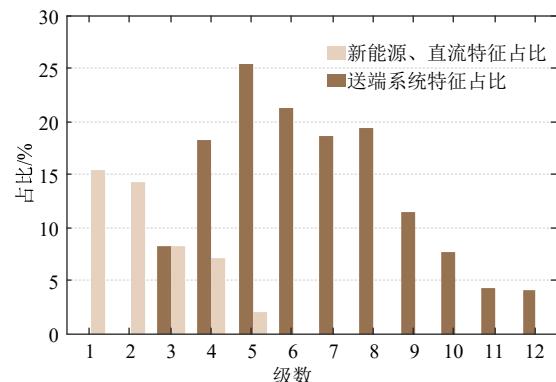


图 8 部分特征时序演化规律

Fig. 8 Temporal evolution of some features

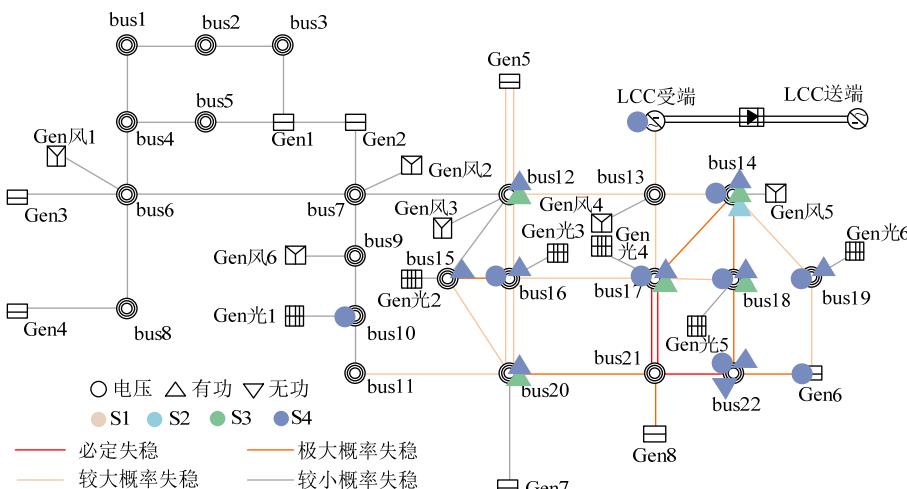


图 9 特征落点及系统薄弱断面

Fig. 9 Characteristic drop point and weak section of the system

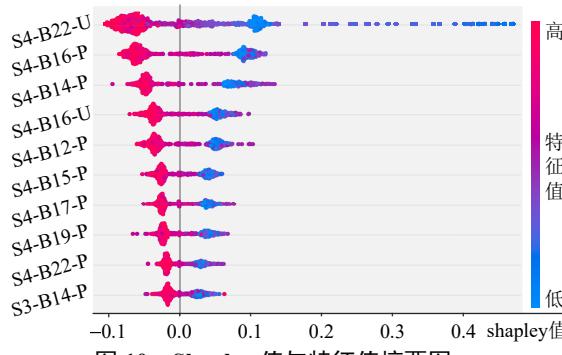


Fig. 10 Summary graph of Shapley values and eigenvalues

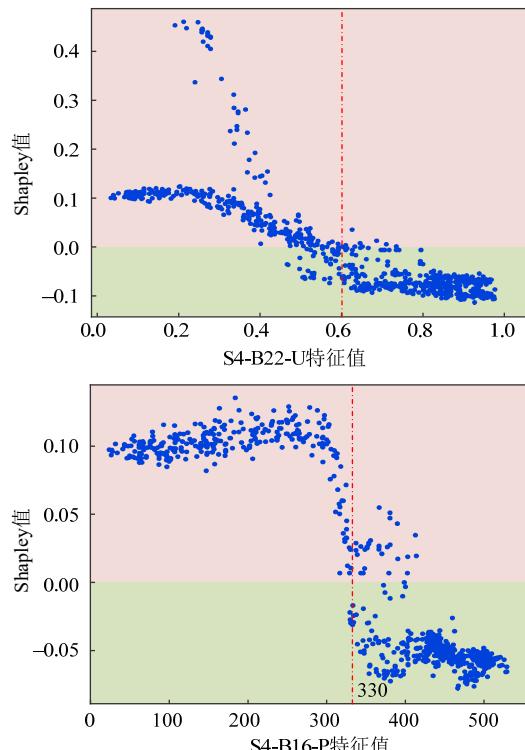


Fig. 11 Relationship between Shapley values and eigenvalues of two kinds of characteristics

小于 0.6pu 或节点 16 有功负荷小于 330MW 的风险拐点时，该范围内绝大部分样本的 Shapley 值将大于零，失稳风险增高，因而该特征的特征值与稳定呈正相关。该现象的机理分析为：①故障切除后电压会经历回升阶段，因而电压恢复情况越好说明系统保持电压稳定的能力越强，越不容易发生暂态电

压失稳现象。②本算例中节点 16 为马达负荷高占比节点，其暂态过程有功恢复情况对系统电压稳定性有较大影响。故障发生时负荷消耗有功骤降，马达电磁力矩降低同时滑差开始增大；故障切除后若有功恢复能够满足电磁转矩与机械转矩的平衡，则易回到稳定平衡点，否则将会促使滑差进一步拉大导致电机堵转，进而吸收大量无功而发生电压崩溃。

## 2) 样本角度。

图 12 显示了从测试集中随机选择的稳定与失稳实例 SHAP 特征力图。其中基准值表示训练集的模型估计结果平均值，如果模型的输出高于基准值，则认为失稳，相反则认为稳定。红色箭头表示正向影响，即认为会增加失稳风险，蓝色反之。箭头越长代表 Shapley 值越高，即影响力越大。每组特征根据其影响大小进行排序，并对影响最大的特征进行标记。可以看出，判稳与否主要是由少数特征驱动的。对于所示两条样本，经各特征正负影响后分别由基准值的 0.398 变为 0.0 与 1.0，从而得出稳定与失稳结果。以节点 16 有功特征为例，结合特征角度分析中所反映的特征正负相关性变化趋势，当其特征值分别为 429.92MW (即大于 330MW) 和 189.88MW (即小于 330MW) 时，模型对相应样本预测为失稳的概率分别减小了 0.0708 和增加了 0.1210。可见，基于 Shapley 值的可解释性分析能够量化某工况下不同特征对失稳风险的影响大小。

将所有样本的特征力图旋转 90 度并将特征贡献相似度较高的样本水平堆叠，可得到 SHAP 归因分析对整个测试集的分析图，如图 13 所示。其中对于绝大部分稳定样本，只有当节点 22 电压或节点 16 有功负荷 Shapley 值负向贡献度大于 0.07 或 0.06，对应于具体特征值高于 0.8pu 或高于 400MW 时系统才会稳定，否则极易失稳。而对于失稳样本的主导特征情形却不只以上两种(如节点 16 电压低于 0.70pu 失稳)，这意味着当暂态波动超过一定范围时会有很多种原因导致系统失稳，但稳定情形只有少数特征主导情况，这与图 10 中大部分特征

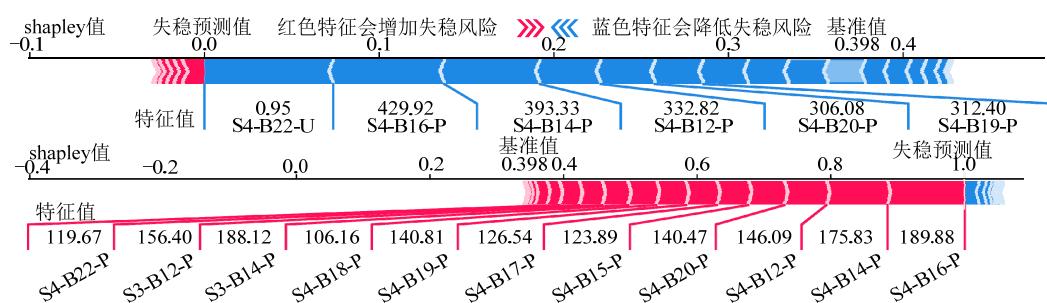


图 12 稳定与失稳实例 SHAP 特征力图

Fig. 12 SHAP feature diagrams of stable and unstable instances

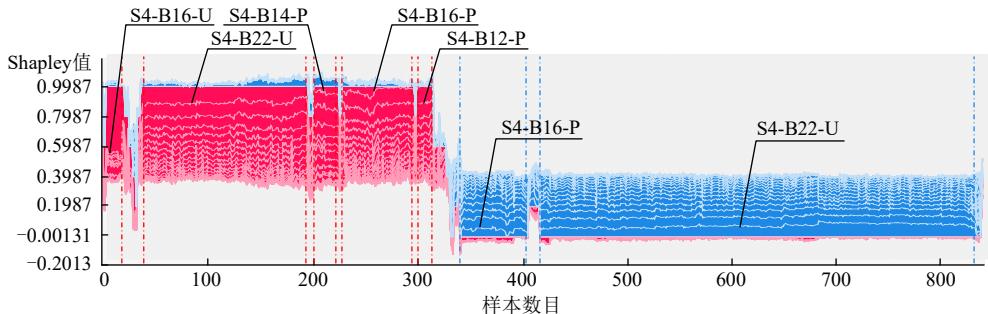


图 13 对整个测试集的 SHAP 归因分析

Fig. 13 SHAP attribution analysis for the entire test set

Shapley 值偏右延伸相一致。因此，选择暂态电压稳定问题中的关键响应特征量并关注其暂态波动情况，对于预防可能发生的失稳情况有较大帮助。

此外，主导特征归因相类似的样本与故障位置间也存在一定规律。对于以节点 22 电压低于 0.70pu 为主导特征的失稳类样本，如图 9 不同颜色线路所示，当故障位置位于红色线路(线路 17-21 或 21-22)则必失稳，颜色越浅的线路失稳概率越低。产生这种现象的原因为节点 22 处负荷所需功率主要由 17-21-22 输电走廊提供(发电机 Gen6 因还需向节点 19 提供支撑而供给能力有限)，若发生故障导致其中任一条线路切除时，潮流大量转移至而线路 18-22，而算例中线路 18-22 本身因线路阻抗较高存在交流输电通道薄弱、承载功率能力不足的问题，受限于其功率传输极限而易导致暂态电压失稳。因此，通过 SHAP 归因分析挖掘出本算例中薄弱断面包含线路 18-22，可考虑架设双回线以提高功率传输能力。类似地可以分析其他特征贡献相似度较高的样本共同反映出的系统薄弱问题。

基于样本角度的 SHAP 分析有助于挖掘系统运行薄弱点，从而可以有针对性地进行系统优化调整，消除可能导致系统暂态电压失稳的潜在危险，提高系统安全稳定运行水平。

## 5 结论

有效的电力系统暂态电压稳定特征子集选择方法对稳定性在线评估、关键响应特征分析等工作具有重要意义。本文提出一种两阶段复合特征选择框架，具备以下优势：

1) 提出一种等分滑窗样本构建方法，从时间和空间维度上联合构造备选特征集，有助于提升时空特征信息捕获能力。

2) 采用对称不确定值改进的 MRMR 方法进行第一阶段特征粗筛，并将基于强化学习的元启发式优化算法应用于第二阶段特征细选并加以优化，改进了原优化算法收敛速度较慢、陷入局部最优解的

情况，可以有效降低时空特征维数，提升计算效率与在线评估准确率，具备较强的泛化能力。

3) 基于 SHAP 归因分析工具，定性、定量分析了所筛选特征与失稳之间的关联性及系统潜在薄弱点，为评估模型可解释性分析提供了新视角。

综上所述，本文方法在电力系统暂态电压稳定评估与分析中具有一定应用潜力。然而，仍有问题值得深入研究：考虑将强化学习融合至其他元启发式优化算法，选择更适用于电力系统特征选择的方法是值得尝试的方向。

附录见本刊网络版(<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

## 参考文献

- [1] 孙华东, 徐式蕴, 许涛, 等. 新能源多场站短路比定义及指标[J]. 中国电机工程学报, 2021, 41(2): 497-505.  
SUN Huadong, XU Shiyun, XU Tao, et al. Definition and index of short circuit ratio for multiple renewable energy stations[J]. Proceedings of the CSEE, 2021, 41(2): 497-505(in Chinese).
- [2] 毛安家, 马静, 删圣宇, 等. 高比例新能源替代常规电源后系统暂态稳定与电压稳定的演化机理[J]. 中国电机工程学报, 2020, 40(9): 2745-2755.  
MAO Anjia, MA Jing, KUAI Shengyu, et al. Evolution mechanism of transient and voltage stability for power system with high renewable penetration level[J]. Proceedings of the CSEE, 2020, 40(9): 2745-2755(in Chinese).
- [3] 袁小明, 程时杰, 胡家兵. 电力电子化电力系统多尺度电压功角动态稳定问题[J]. 中国电机工程学报, 2016, 36(19): 5145-5154.  
YUAN Xiaoming, CHENG Shijie, HU Jiabing. Multi-time scale voltage and power angle dynamics in power electronics dominated large power systems[J]. Proceedings of the CSEE, 2016, 36(19): 5145-5154(in Chinese).
- [4] 胡润滋, 马晓忱, 孙博, 等. 基于特征选择的暂态安全评估方法及其可解释性研究[J]. 电网技术, 2023, 47(2): 755-762.  
HU Runzi, MA Xiaochen, SUN Bo, et al. Transient safety assessment and its interpretability based on feature selection[J]. Power System Technology, 2023, 47(2): 755-762(in Chinese).
- [5] 施启军, 潘峰, 龙福海, 等. 特征选择方法研究综述[J]. 微电子学与计算机, 2022, 39(3): 1-8.  
SHI Qijun, PAN Feng, LONG Fuhai, et al. A review of feature selection methods[J]. Microelectronics & Computer, 2022, 39(3): 1-8(in Chinese).
- [6] 李鹏, 董鑫剑, 孟庆伟, 等. 基于 Fisher Score 特征选择的电力系

- 统暂态稳定评估方法[J]. 电力自动化设备, 2023, 43(7): 117-123.
- LI Peng, DONG Xinjian, MENG Qingwei, et al. Transient stability assessment method for power system based on Fisher Score feature selection[J]. Electric Power Automation Equipment, 2023, 43(7): 117-123(in Chinese).
- [7] 李海英, 刘中银, 宋建成. 电力系统静态安全状态实时感知的相关向量机法[J]. 中国电机工程学报, 2015, 35(2): 294-301.
- LI Haiying, LIU Zhongyin, SONG Jiancheng. Real-time static security situational awareness of power systems based on relevance vector machine[J]. Proceedings of the CSEE, 2015, 35(2): 294-301(in Chinese).
- [8] 周艳真, 吴俊勇, 于之虹, 等. 基于转子角轨迹簇特征的电力系统暂态稳定评估[J]. 电网技术, 2016, 40(5): 1482-1487.
- ZHOU Yanzhen, WU Junyong, YU Zhihong, et al. Power system transient stability assessment based on cluster features of rotor angle trajectories[J]. Power System Technology, 2016, 40(5): 1482-1487(in Chinese).
- [9] CAO Man, WANG Yajun. Application of binary particle swarm optimization in feature selection for transient stability assessment[C]//Proceedings of 2011 International Conference on Electric Information and Control Engineering. Wuhan: IEEE, 2011.
- [10] SHARMA V, TRIPATHI A K. A systematic review of meta-heuristic algorithms in IoT based application[J]. Array, 2022, 14: 100164.
- [11] GE Hong, HU Tianliang. Genetic algorithm for feature selection with mutual information[C]//Proceedings of the 7th International Symposium on Computational Intelligence and Design. Hangzhou: IEEE, 2014.
- [12] 姜新雄, 徐箭, 廖思阳, 等. 基于增强进化计算的电力系统暂态稳定关键特征智能选择方法[J]. 中国电机工程学报, 2023, 43(14): 5358-5372.
- JIANG Xinxiong, XU Jian, LIAO Siyang, et al. An intelligent selection method for power system transient security key features based on enhanced evolutionary computation[J]. Proceedings of the CSEE, 2023, 43(14): 5358-5372(in Chinese).
- [13] 卢锦玲, 於慧敏. 极限学习机和遗传算法在暂态稳定评估特征选择中的应用[J]. 电力系统及其自动化学报, 2016, 28(12): 103-108.
- LU Jinling, YU Huimin. Application of extreme learning machine and genetic algorithm to feature selection of transient stability assessment[J]. Proceedings of the CSU-EPSA, 2016, 28(12): 103-108(in Chinese).
- [14] CHEN Zhen, HAN Xiaoyan, FAN Chengwei, et al. A two-stage feature selection method for power system transient stability status prediction[J]. Energies, 2019, 12(4): 689.
- [15] WAUTERS T, VERBEECK K, DE CAUSMAECKER P, et al. Boosting metaheuristic search using reinforcement learning[M]// TALBI E G. Hybrid Metaheuristics. Berlin Heidelberg: Springer, 2013: 433-452.
- [16] 陈明华, 刘群英, 张家枢, 等. 基于 XGBoost 的电力系统暂态稳定预测方法[J]. 电网技术, 2020, 44(3): 1026-1033.
- CHEN Minghua, LIU Qunying, ZHANG Jiaoshu, et al. XGBoost-based algorithm for post-fault transient stability status prediction[J]. Power System Technology, 2020, 44(3): 1026-1033(in Chinese).
- [17] 唐飞. 基于 WAMS 的电力系统暂态稳定性特征提取及评估方法研究[D]. 武汉: 武汉大学, 2013.
- [18] 季佳伸, 吴俊勇, 王彦博, 等. 基于深度残差网络的电力系统暂态电压稳定评估[J]. 电网技术, 2022, 46(7): 2500-2509.
- JI Jiashen, WU Junyong, WANG Yanbo, et al. Power system transient voltage stability assessment based on deep residual network[J]. Power System Technology, 2022, 46(7): 2500-2509(in Chinese).
- [19] 薛安成, 周健, 刘瑞煌, 等. 采用多二元表判据的实用暂态电压稳定裕度指标研究[J]. 中国电机工程学报, 2018, 38(14): 4117-4125.
- XUE Ancheng1, ZHOU Jian, LIU Ruihuang, et al. A new practical transient voltage stability margin index based on multiple-two-element notation criterion[J]. Proceedings of the CSEE, 2018, 38(14): 4117-4125(in Chinese).
- [20] PENG Hanchuan, LONG Fuhui, DING C. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1226-1238.
- [21] HOSSEINI E S, MOATTAR M H. Evolutionary feature subsets selection based on interaction information for high dimensional imbalanced data classification[J]. Applied Soft Computing, 2019, 82: 105581.
- [22] WANG Yurong, ZHU Yifei, WANG Qi, et al. Complex fault source identification method for high-voltage trip-offs of wind farms based on SU-MRMR and PSO-SVM[J]. IEEE Access, 2020, 8: 130379-130391.
- [23] 李扬, 顾雪平. 基于改进最大相关最小冗余判据的暂态稳定评估特征选择[J]. 中国电机工程学报, 2013, 33(34): 179-186.
- LI Yang, GU Xueping. Feature selection for transient stability assessment based on improved maximal relevance and minimal redundancy criterion[J]. Proceedings of the CSEE, 2013, 33(34): 179-186(in Chinese).
- [24] 张超群, 郑建国, 王翔. 蜂群算法研究综述[J]. 计算机应用研究, 2011, 28(9): 3201-3205, 3214.
- ZHANG Chaoqun, ZHENG Jianguo, WANG Xiang. Overview of research on bee colony algorithms[J]. Application Research of Computers, 2011, 28(9): 3201-3205, 3214(in Chinese).
- [25] FORBES C, EVANS M, HASTINGS N, et al. Pareto distribution[M]// FORBES C, EVANS M, HASTINGS N, et al. Statistical Distributions. 4th ed. Hoboken: John Wiley & Sons, Inc, 2010.
- [26] SADEG S, HAMDAD L, REMACHE A R, et al. QBSO-FS: a reinforcement learning based bee swarm optimization metaheuristic for feature selection[C]//Proceedings of the 15th International Work-conference on Artificial Neural Networks. Gran Canaria: Springer, 2019: 785-796.
- [27] LUONG N C, HOANG D T, GONG Shimin, et al. Applications of deep reinforcement learning in communications and networking: a survey[J]. IEEE Communications Surveys & Tutorials, 2019, 21(4): 3133-3174.
- [28] LI Baoqin, WU Junyong, HAO Liangliang, et al. Anti-jitter and refined power system transient stability assessment based on long-short term memory network[J]. IEEE Access, 2020, 8: 35231-35244.
- [29] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc, 2017.
- [30] 周挺, 杨军, 詹祥澎, 等. 一种数据驱动的暂态电压稳定评估方法及其可解释性研究[J]. 电网技术, 2021, 45(11): 4416-4425.
- ZHOU Ting, YANG Jun, ZHAN Xiangpeng, et al. Data-driven method and interpretability analysis for transient voltage stability assessment[J]. Power System Technology, 2021, 45(11): 4416-4425(in Chinese).



在线出版日期: 2023-06-09。

收稿日期: 2022-12-13。

作者简介:

甄永赞(1985), 男, 博士, 讲师, 研究方向为新能源发电与电力系统控制, E-mail: zhenyongzan\_001@126.com;

阮程(1999), 男, 通信作者, 硕士研究生, 研究方向为新能源电力系统, E-mail: 858635218@qq.com。

(责任编辑 宋钰龙)

## 附录 A

通用 BSO 元启发式优化算法搜索过程分六个步骤进行：

①随机或启发式生成初始解，并从中确定一个搜索区域，同时将初始解加入禁忌列表不再调用。对于初次迭代，初始解是以纯随机的方式生成，其余轮迭代基于探索(探寻全局解)或开发(强化局部解)原则生成(见步骤⑥)。搜索区域是由初始解生成的一组参考解，参考解数目等于蜜蜂数量。

②参考解分配给蜜蜂。

③蜜蜂执行局部搜索，迭代次数为  $I_{loc}$ ，在此期间评估访问的解决方案并寻找局部最优解。

④搜索结束后，每只蜜蜂返回其找到的最优解。

⑤将返回的最优解加入舞蹈表中。

⑥当全局最优解得到改进时，下轮迭代选择该最优解作为初始解来进行开发，否则进行探索。探索时选择与禁忌列表中所有解决方案差别最大的舞蹈表解决方案。若舞蹈表所有的解都在禁忌列表中，则生成一个随机解作为初始解。当达到全局最大迭代次数  $I_{max}$  时算法停止。

## 附录 B

相关算法超参数设置如表 B1 所示。

表 B1 超参数设置  
**Table B1 hyperparameter setting**

算法名称	参数内容	参数值
全局设置	搜索代理数	10
	全局最大迭代数 $I_{max}$	80
	目标函数 $\lambda_1, \lambda_2$	0.5, 0.5
	kNN 近邻数 $k$	5
Q 学习	学习率 $\alpha$	0.9
	探索因子 $\varepsilon$	0.1
BSO	翻转系数 $f$	5
	局部迭代数 $I_{loc}$	10
PSO	惯性常数 $w$	0.9
	加速常数 $c_1, c_2$	2, 2
GA	交叉率 $p_c$	0.8
	突变率 $p_m$	0.01