

基于分级自适应倾斜决策树的 电力系统主导失稳模式辨识方法研究

甄永赞¹, 阮程^{1*}, 胡永强¹, 李宗翰², 袁超²

1. 新能源电力系统全国重点实验室(华北电力大学), 北京市 昌平区 102206;
2. 电网安全全国重点实验室(中国电力科学研究院有限公司), 北京市 海淀区 100192

Dominant Instability Mode Identification Method of Power System Based on Hierarchical-self-adaptive Oblique Decision Tree

ZHEN Yongzan¹, RUAN Cheng^{1*}, HU Yongqiang¹, LI Zonghan², YUAN Chao²

- (1. State Key Laboratory of Alternate Electrical Power System With Renewable Energy Sources (North China Electric Power University), Changping District, Beijing 102206, China; 2. National Key Laboratory of Grid Security (China Electric Power Research Institute), Haidian District, Beijing 100192, China)

ABSTRACT: Under the background of the development of new type power systems, post-fault transient power angle instability and transient voltage instability interact with each other. The current study on identifying dominant instability modes using artificial intelligence faces a “black box” issue, as this field is still in its nascent stages of development. Therefore, a new method of dominant instability mode identification based on hierarchical-self-adaptive oblique decision tree is proposed. The feature construction method of sliding window trajectory cluster is used to capture the time series response information of electrical quantities, which improves the training speed, generalization ability and robustness of the model. In the construction of the identification model, the oblique decision tree classification model fused with the decision surface of the support vector machine is used to establish the mapping relationship between the dominant instability mode and the feature quantity, and the nonlinear combination of multi-dimensional features is used to enhance the branch ability of the internal nodes of the traditional decision tree and improve the identification accuracy. In the first stage of the method, the stability evaluation is carried out, and the cost-sensitive mechanism is introduced to reduce the risk of misjudgment of the instability condition. In the second stage, the dominant instability mode is then identified. In addition, a hierarchical-self-adaptive strategy is used to improve the speed of sample identification and further reduce misjudgment. The generated identification rules are

characterized by polynomials, which can mine the correlation between multi-combination features and dominant instability modes. The effectiveness of the proposed method is verified by the transient power angle instability-voltage collapse system example and the ten-thousand-node standard example, which provides a new idea for the identification and analysis of the dominant instability mode based on artificial intelligence.

KEY WORDS: dominant instability mode; sliding window trajectory cluster feature; oblique decision tree; hierarchical-self-adaptation; identification rule

摘要: 新型电力系统发展背景下, 故障后暂态功角失稳与暂态电压失稳相互影响、交互作用, 现有基于人工智能的主导失稳模式辨识研究尚处于起步阶段, 且存在“黑箱”问题。为此, 提出一种基于分级自适应倾斜决策树的主导失稳模式辨识新方法。采用滑窗轨迹簇特征构造法来捕获电气量时序响应信息, 提升模型训练速度、泛化能力与鲁棒性。辨识模型构建上, 使用融合支持向量机决策面的倾斜决策树分类模型建立主导失稳模式与特征量间的映射关系, 以多维特征的非线性组合来增强传统决策树内部节点分支能力, 提升辨识精度。方法第一阶段进行稳定性评估, 并引入代价敏感机制降低失稳工况错判风险; 第二阶段进行主导失稳模式辨识。此外, 利用一种分级自适应策略来提高样本辨识速度, 并进一步减少错判。所生成辨识规则由多项式表征, 并能够挖掘多组合特征与主导失稳模式间的关联关系。暂态功角失稳-电压崩溃系统算例及万节点标准算例验证所提方法的有效性, 为基于人工智能进行主导失稳模式辨识与分析提供一种新思路。

级自适应; 辨识规则

0 引言

在“双碳”目标驱动的新型电力系统发展背景下, 含高比例可再生能源的交直流混联电网将成为电力系统的典型形态^[1-2]。该形态电网运行状态复杂多变, 大扰动冲击下往往面临暂态功角与暂态电压失稳的风险, 较易引发规模性停电事故^[3-4], 因此稳定性问题依旧是威胁系统安全运行的关键因素。

系统失稳识别主要依赖于失稳判据^[5]。目前, 针对两种失稳模式的传统分析评估方法主要有时域仿真法^[6]和基于能量函数的直接法^[7]等。然而, 传统方法存在需要准确的故障参数和网络配置信息, 以及计算耗时等缺点, 难以满足应用需求。近年来, 人工智能的快速发展为电网分析与决策提供了新的思路和方法, 其能够避开复杂物理机理, 有效降低人力投入并提高决策精度^[8]。同时相量量测单元(phasor measurement unit, PMU)在电力系统中的普及可以同步获取海量数据, 为构建基于人工智能方法的响应驱动暂态稳定决策模型奠定了数据基础。

相关研究中, 单一失稳模式的智能评估研究已相对成熟^[9-12], 然而其均建立在假设大扰动后的系统主导失稳模式已知。由于功角失稳会引起振荡中心低电压, 电压失稳会制约附近机组功率送出而发生功角失稳^[13], 两种失稳现象往往同时发生并相互影响, 因而单一与多重失稳模式下电气量暂态变化差异性较大, 此时单一失稳模式场景稳定性判据存在较高失效风险。部分学者开始注意二者的潜在关联性, 并进行了两种失稳模式的联合评估尝试。文献^[14-15]均采用响应驱动方法来构建输入数据和两种失稳模式间的综合映射关系。然而, 上述方法虽可以做到暂态失稳问题一体化评估, 但仅能给出系统存在某种或多种模式的失稳风险, 无法辨识由何种模式所主导。实际系统两种失稳模式往往对应不同控制策略^[16], 对于两种失稳模式共存的情况, 需明确何种失稳模式占主导地位才能确定采取哪一种控制策略更有利于稳定恢复。因此, 选取有效方法以明确系统主导失稳模式具有重要研究意义。

目前, 基于人工智能方法的主导失稳模式辨识研究尚处于起步阶段。文献^[17-20]分别基于挤压神经网络、图注意力网络、一维卷积神经网络与随机森林算法, 学习输入特征与主导失稳模式间的映射关系, 初步验证基于人工智能方案实现响应驱动的

主导失稳模式辨识的可行性。然而, 文献^[17-18]的应用场景为仿真数据分析, 其时间窗难以满足辨识快速性需求; 文献^[19]未能针对新型电力系统研究场景展开主导失稳模式辨识; 文献^[20]基于非连续采集特征构建算法, 未能有效利用 PMU 时序数据优势。此外, 上述研究算法受“黑箱”特性限制, 仅能单纯给出准确率结果而无法生成明确的辨识规则表达式, 从而无法对其辨识过程进行有效把握, 限制了相关方法在工程中的实际应用。

针对现有研究薄弱点, 本文提出一种响应驱动的分级主导失稳模式辨识新方法。在输特征构建上, 基于与暂态功角及暂态电压失稳强相关的电气量时序轨迹, 采用滑窗轨迹簇特征构造法来充分捕获响应特征并降低特征维度, 提升模型的泛化性与鲁棒性。在辨识模型构建上, 采用一种支持向量机决策面的倾斜决策树分类模型, 能够有效增强传统单决策树内部节点特征组合能力, 提升辨识能力。模型第一阶段使用融合代价敏感机制的斜决策树进行失稳判断, 可以有效降低失稳工况的错判风险; 对判断出的失稳样本, 启动第二阶段主导失稳模式辨识流程, 采用无代价敏感的斜决策树进行判断。此外, 利用一种分级自适应准则来进一步提高样本辨识速度与准确率。所生成的辨识规则具有明确的多项式表征, 从而决策流程十分清晰, 同时还能够进一步分析判据中所蕴含的机理含义。在中国电科院暂态功角失稳—电压崩溃算例系统及万节点标准算例测试系统中检验所提方法的有效性。

1 算法介绍

决策树(decision tree, DT)算法因计算快速、透明度高且泛化能力强, 非常适合应用于电力系统暂态稳定问题的评估与解析。传统 DT 模型的决策边界如图 1 所示, 其特征空间沿平行于特征变量轴的方向递归分割。因此, 当类样本在任何一维上不能

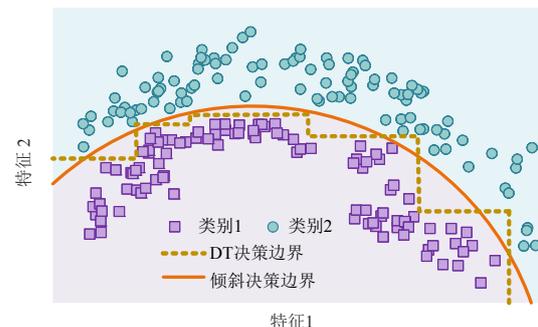


图1 DT与ODT的决策边界示意

Fig.1 DT and ODT decision boundary

完全分割时，DT 需要非常深的层数，具有复杂的步进式决策边界，导致方差增加和过拟合^[21]。

为解决传统 DT 所存在的问题，部分研究^[22-23]开始尝试将多维组合特征构造的倾斜决策树 (oblique decision tree, ODT) 算法应用于单一失稳模式评估中，因其能以较少决策边界准确划分不规则样本特征空间分布，取得了更好的评估效果。

本文提出一种基于分级自适应倾斜决策树

(hierarchical-self-adaptive oblique decision tree, HODT) 的电网主导失稳模式辨识算法，模型框架如图 2 所示。融合的支持向量机 (support vector machine, SVM) 能够充分利用其自动组合特征生成决策函数的能力；代价敏感能够解决失稳样本错判率高的问题；分级自适应策略能够减少辨识时间并保证准确率兼优，使模型具有更强的表达能力与更好的学习性能。

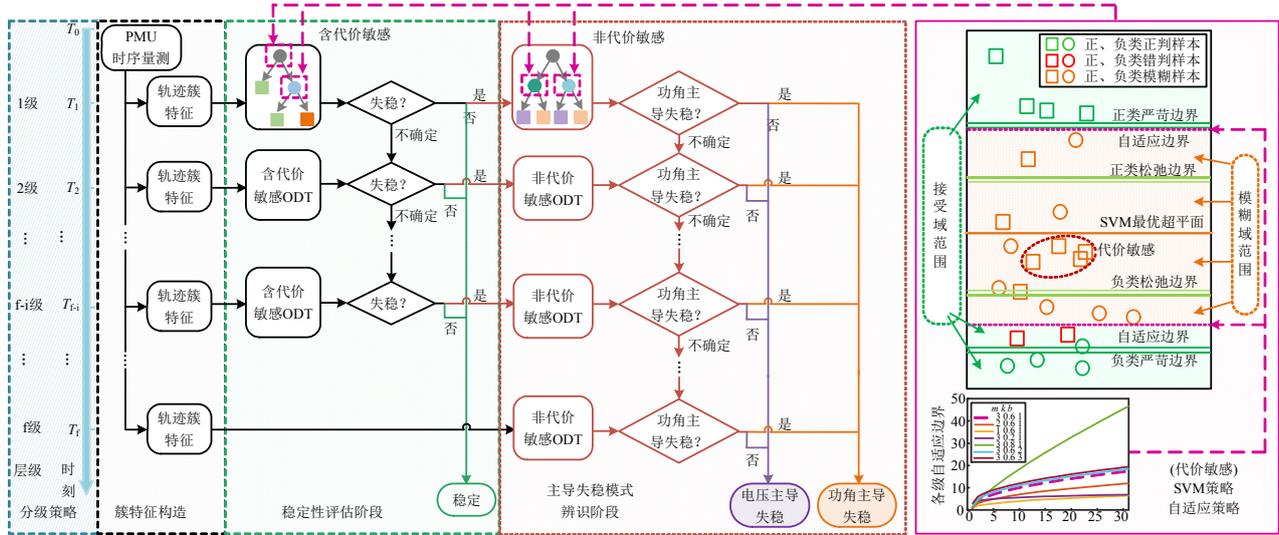


图 2 HODT 模型框架

Fig.2 HODT model framework

1.1 融合 SVM 的 ODT 算法

在文献[22-23]中，所提 ODT 的内部节点分裂决策是输入特征的线性组合表达，其通过前进后退搜索定义超平面的线性变换函数最优参数，因而确定决策边界的计算相当繁琐耗时，具有局限性。

除了线性函数，更强大的机器学习模型也逐渐被认为是多元线性和非线性决策的分割标准^[24]。在本文中，考虑到 SVM 具有明确的决策表达式与计算快速性，采用其构建 ODT 内部节点决策边界，以提升组合特征搜索效率。

标准的线性 SVM 算法寻找最优化分离超平面，使训练数据的边缘对于二元变量最大化。给定二分类训练向量 $\mathbf{x}_i \in R^n (i=1, \dots, l)$ 及标签向量 $\mathbf{y} \in R^l$ ，线性 SVM 解决了以下优化问题：

$$\begin{cases} \min & \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l \xi_i \\ \text{s.t.} & y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0, i = 1, \dots, l \end{cases} \quad (1)$$

式中： $\mathbf{w}^T \mathbf{w} / 2$ 为结构代价； $C \sum_{i=1}^l \xi_i$ 为经验代价； C

为惩罚参数； ξ_i 为松弛变量。

原 SVM 算法在暂态问题应用中存在两点不足。首先，实际应用对稳定性判别与主导失稳模式辨识分类代价的要求并不相同。对于前者，失稳样本的错判后果远比稳定样本要高得多。因此，本文在原 SVM 基础上，通过对稳定与失稳样本施加不同惩罚参数的代价敏感方法构建目标函数^[25]，达到侧重失稳类准确率的效果。更新后的优化问题可如下表示：

$$\begin{cases} \min & \frac{1}{2} \mathbf{w}^T \mathbf{w} + C [c^+ \sum_{y_i=1} \xi_i + c^- \sum_{y_i=-1} \xi_i] \\ \text{s.t.} & y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i \\ & \xi_i \geq 0, i = 1, \dots, l \end{cases} \quad (2)$$

式中：目标函数第二项为改进后的经验代价； c^+ 和 c^- 分别为稳定与失稳代价敏感系数，二者构成代价敏感矩阵 $\mathbf{c} = [c^+, c^-]$ ，当 $c^- > c^+$ 时可实现着重减少失稳样本错判的目标。

此外，特征线性组合在构造特征空间不规则分类边界时仍不灵活。为提升效率，采用 SVM 常用核技巧计算方法进行升阶，构造非线性组合特征决

策边界。本文所用核函数表达式为

$$K(\mathbf{x}_i, \mathbf{x}) = (\langle \mathbf{x}_i, \mathbf{x} \rangle + 1)^2 \quad (3)$$

式中: \mathbf{x}_i 为支持向量; \mathbf{x} 为待分类向量。

采用二阶核的目的是最大效率提升多维特征非线性映射能力, 同时尽可能减少决策表达式训练时间并保留其可读性。

改进后的最优决策函数为

$$y = \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{B} \mathbf{x} + b \quad (4)$$

式中: y 为决策函数计算值; \mathbf{x} 为该决策节点所使用的特征量向量; \mathbf{A} 为二次项变换系数矩阵; \mathbf{B} 为一次项变换系数矩阵; b 为最优偏置系数。

可见, 决策函数是多维特征非线性组合多项式函数。基于所得决策函数, 当获得一组待判样本后, ODT 采用 Gini 增益作为节点分裂原则递归构建。

1.2 融合分级自适应机制的 HODT 算法

图 2 可知, 代价敏感 SVM 策略虽有效减少了失稳样本错判数, 但同时也误判了一定数目稳定样本, 这会造成不必要的损失。此外, 若能越早给出判断结果, 失稳工况及时恢复的可能性便越高^[26]。

为减少稳定误判并提升判断快速性, 本文提出一种两阶段融合时序多级模糊域边界的分级自适应方法来进一步优化 ODT 模型。在各级判断节点, 第一阶段评估是否发生失稳, 判定失稳后启动第二阶段进行主导失稳模式辨识。分级策略主要针对落在决策边界附近模糊域内判断置信度较低的重叠样本, 若该时刻不能得出确切的稳定性或主导模式结果, 则将其顺延至时序下级分类器, 待采集更多特征信息后进行辨识, 直至输出确定结果。

其中分级策略的关键在于模糊域边界的选择合理性。根据样本错判率的高低来决定边界的宽严程度, 两种极端情况可分别对应为松弛与严苛边界。松弛边界放松了对该级判断准确率的要求, 因而错判率会升高, 但模糊域中的样本数较少, 可以较快完成判断任务; 严苛边界的情况则与之相反。显然, 仅考虑某种极端模糊域边界均非最优解。为实现判断时间与错判率间的自动有效衡量, 采用一种自适应策略用于寻找最优模糊域边界^[27]。自适应边界位于松弛边界与严苛边界之间, 采用错判率 M 为衡量, 其以确定待测样本决策值集合 Y 的 M 与分类器数目 I 的最小化目标为最佳折衷。该优化问题可以根据已知条件初步设为

$$\begin{cases} \min f = \lambda \frac{M(Y)}{M_{\max}} + (1 - \lambda) \frac{I(Y)}{I_{\max}} \\ \text{s.t. } 0 \leq M(Y) \leq M_{\max} \\ 1 \leq I(Y) \leq I_{\max} \\ I \in N^+ \end{cases} \quad (5)$$

式中: M_{\max} 、 I_{\max} 分别为可接受的最高错判率与最多分类器数目; λ 为目标函数加权系数, 从 0.4 至 0.6 中选择以防止过度倾向准确率或评估时间。

考虑两阶段问题包含 4 类待判样本, 其中对失稳错判率要求更为严格, 因而各级分类器模糊域稳定类边界(即图 2 正样本边界)均采用严苛边界而不寻优, 其他 3 类样本自适应边界则需寻找最优。

此外, 随着暂态过程的逐步演化, 电气量将呈现出更强的稳定性或主导模式表征能力, 分类器的判断置信度会逐渐提升。因此可以考虑在前期分类器采用较为严苛的边界以尽可能降低错判率, 将模糊样本适当向后顺延; 对于后期辨识准确度较好的分类器, 适当采用松弛边界以加快判断速度。本文通过构建随准确率变化趋势的近似函数来表征这种层级变化关系, 各级可以允许的错判率 M_i 与 I 的函数关系近似表达为

$$M_i = \frac{mi^k + b}{N} \quad (6)$$

式中: $i \in [1, I]$ 为某级序号; N 为某类样本数; $0 \leq k \leq 1$; $m \geq 0$; $b \geq 0$ 。当 $m=b=0$ 时, 自适应边界即退化为最严苛边界; m 、 k 与 b 的值越大, 边界越松弛。

值得说明的是, 模型本身的固有特性使得 M 与 I 无法同时取得最优, 其之间存在一定隐式约束关系; 此外, 式(6)放开了各级 M_i 对 M_{\max} 的限制。两阶段 3 类自适应边界均按式(5)与(6)准则进行构造, 所得目标函数 f 最小化时即为该自适应边界策略下的最优化 HODT 模型。

综上, 融合分级自适应机制的 HODT 算法总体构建步骤为:

1) 初始化超参数初值 c 、 m 、 k 、 b 与 λ , 并确定期望参数 M_{\max} 及 I_{\max} 。由于不同系统所能获得的评估精度及评估速度通常存在一定差异, 因而期望参数通过在较小值基础上不断调大重复实验确定, 至率先满足式(5)不等式约束时即可;

2) 基于 1.1 节, 构建稳定性判别与主导失稳模式辨识分级 ODT 模型。对于稳定性判别问题, c 网格搜索至失稳样本错判率无明显降低为止; 对于主导辨识问题, c 值取 0.5;

3) 基于最小化目标函数, 网格搜索最优自适应边界参数 m 、 k 与 b 及目标函数加权参数 λ , 同时确定所需分类器层级数。

构建好的 HODT 模型应满足两个条件: 1) 样本能够全部较快判断完毕; 2) 失稳样本错判率尽可能低, 其他 3 类错判率尽可能在给定期望阈值内。

2 基于 HODT 的主导失稳模式辨识

基于 HODT 的电网主导失稳模式辨识方法流程如图 3 所示, 其主要分 3 个步骤进行。

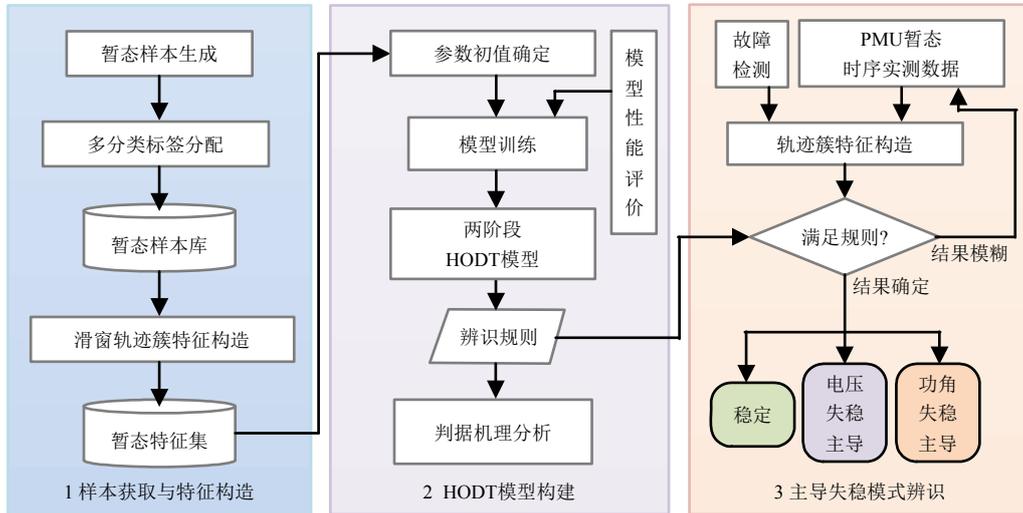


图 3 主导失稳模式辨识流程

Fig. 3 Identification process of coupling instability

1) 样本获取与特征构造。基于故障集生成暂态样本, 捕获与两种失稳模式具有强相关性的时序响应电气量, 构造滑窗轨迹簇特征用于模型训练;

2) HODT 模型构建。确定所需超参数初值及期望参数值, 基于节 1 所提模型构建方法, 采用模型评价指标评估其构建情况, 并提炼两阶段多项式判据作为辨识规则, 同时可分析规则所蕴含的机理;

3) 主导失稳模式辨识。检测到暂态故障发生后, PMU 量测所需电气量构造轨迹簇特征, 并将其送入各级表达式中进行规则匹配; 对于模糊的样本则顺延判断至输出高置信度结果。

本节对所使用的滑窗轨迹簇特征构造法及样本定义标注准则进行介绍, 以完善主导失稳模式辨识流程框架。

2.1 滑窗轨迹簇特征构造法

在机器学习中, 需要构建合理的特征集合来充分揭示输入样本之间的类别差异。以往研究中相关电气量被分类器直接用作输入特征^[9-12,14-15,17-20]。然而, 该方法的输入特征数量随系统节点数量呈指数增长, 会给模型训练及应用带来困难, 此外其在面对数据缺失问题时往往不能很好应对。

考虑所研究主导失稳模式辨识问题的特殊性, 本文综合考察现有针对单一失稳模式研究常使用的特征, 选取负荷母线电压幅值及相角、线路有功

及无功 4 种与两类失稳模式强相关的电气量^[14,17], 并采用一种滑窗轨迹簇特征构造法构建模型辨识所需特征^[28]。其研究故障后某种电气量的轨迹簇整体变化规律, 计算簇统计信息构造特征集合; 滑窗由多个连续采样点构成, 可以有效利用 PMU 流式数据优势, 提取一段时间轨迹簇的整体变化趋势信息。与单一轨迹向量相比, 轨迹簇的整体特征具有更全面的信息, 受 PMU 量测数据丢失的影响更小; 且簇定义特征维数固定, 不会受系统规模增大的影响, 在未来电网发展的背景下该特征构造方法依然具有普适性。

如图 4 所示, 利用统计学中描述数据分布的

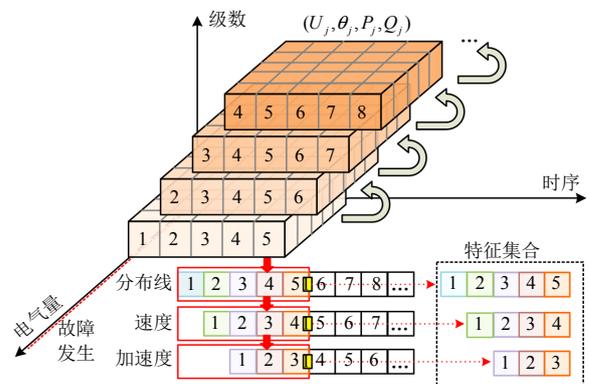


图 4 滑窗轨迹簇特征构造

Fig. 4 Sliding window trajectory cluster feature construction

几种典型测度，计算各电气量轨迹簇均值、方差、最大值、最小值、中位数、偏度和峰度 7 种分布线，反映轨迹簇位置、分散程度及形状特性，并计算分布线各断面速度与加速度，反映轨迹簇时序变化趋势特性。此外同时考虑历史特征信息对辨识的支撑作用，每个时间窗口包含 5 个断面的数据，自故障发生后每周波计算一次并不断向前滑动，构成滑窗轨迹簇特征集合。特征经归一化处理用于模型训练。所构造的特征集合及计算公式可详见附录 A。

2.2 样本标注规则

参阅文献[17,20,29]并结合电网仿真专家经验进行主导失稳模式样本标签标注，常有两种方法：

1) 时序标定法。从时间尺度上看，故障发生后任意两台发电机间最大功角差先摆开为功角失稳主导，电压先跌落崩溃认为电压失稳主导。

2) 反向校验法。通过反向施加紧急控制来校验，切机能使稳定性提高的可认为功角失稳主导，切负荷能使稳定性提高的可认为电压失稳主导。

3 算例分析

本节基于中国电科院发布的暂态功角失稳—电压崩溃(CEPRI-TAVC)算例测试系统及万节点标准算例测试系统检验所提方法有效性。算例基于 PSD 电力系统仿真分析平台搭建，模型训练在 Python 3.9 中进行。

3.1 CEPRI-TAVC 实验设置

CEPRI-TAVC 算例描述了高比例新能源接入的交直流混联电网，共 97 节点，其中 500 kV 主网架 44 个节点，主网接线如图 5 所示。新能源(240 万 kW)与常规电源(660 万 kW)总装机比例为 1:2.75，基本运行方式为新能源出力 120 万 kW (风电 60 万，

光伏 60 万)和常规机组出力 249 万 kW；系统内一回直流，受入功率 300 万 kW；负荷模型由 ZIP 综合负载和马达负载构成。

通过设置多种潮流水平与故障条件以涵盖与两种失稳模式相关的重要场景，具体包括：1) 各发电机出力在 80%~120%范围内变化，步长 10%，相应调整负荷水平；2) 在各 500 kV 线路分别设置三相短路故障，故障位置为线路首中末处；3) 马达负载比例在 30%~60%范围内变化，步长 10%。选择 500 kV 电压等级 4 种相关电气量，采用滑窗轨迹簇特征构造法构建时序特征样本集，采集起始时刻设置为故障发生后首个周波。共得到 4992 条样本，算法训练集与测试集样本比例设置为 4:1。

3.2 模型性能总体评价

对所提 HODT 模型进行准确率综合测试。相关超参数初始值设置为 $c=[0.5,0.5]$ ， $m=k=b=0$ ， $\lambda=0.5$ ；通过多次实验确定期望参数 M_{max} 为 4%， I_{max} 为 31。通过改变算法随机种子参数来随机训练模型 10 次，并将各次测试结果列入表 1。

表 1 HODT 模型准确率测试
Table 1 HODT model accuracy test

模型代号	稳定性评估			主导失稳模式辨识		
	失稳错判/%	稳定错判/%	准确率/%	功角错判/%	电压错判/%	准确率/%
1	0.00	3.91	98.00	2.93	2.92	97.13
2	0.00	3.47	98.20	3.58	1.00	97.50
3	0.00	3.99	97.90	3.51	2.46	96.94
4	0.00	4.67	97.60	2.88	4.35	96.49
5	0.00	3.50	98.10	3.85	1.53	97.15
6	0.00	4.34	97.70	3.66	1.87	97.23
7	0.21	3.78	97.90	2.14	3.17	97.44
8	0.21	3.48	98.10	4.26	2.24	96.67
9	0.00	3.81	98.00	3.63	3.11	96.50
10	0.00	3.88	98.00	3.56	3.45	96.49
平均	0.04	3.88	97.95	3.40	2.61	96.95

可知，HODT 稳定性评估阶段在代价敏感机制作用下能够有效压制失稳错判情况，其 10 次随机测试可以做到 8 次错判率为 0；稳定错判率及两种主导失稳模式辨识错判率有 7 次能够均位于 4%以下；综合准确率分别能够达到 97.95%与 96.95%，模型总体辨识鲁棒性与准确性较好。

3.3 改进策略有效性验证

3.3.1 轨迹簇特征构造法的有效性

特征构造作为算法辨识的基础，其构造有效性对辨识结果有较大影响，本节首先设置了对比试验

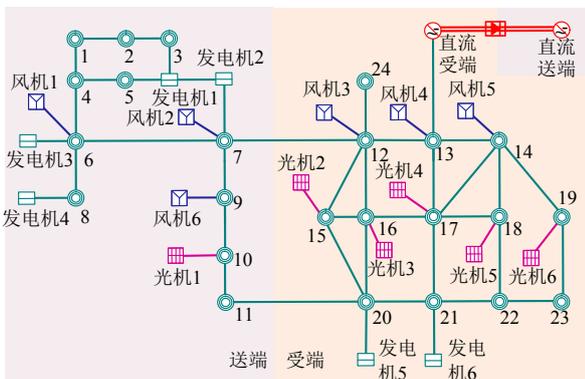


图 5 CEPRI-TAVC 算例接线图
Fig. 5 CEPRI-TAVC wiring diagram

以证明轨迹簇特征构造法的独有优势。通过分别采用轨迹簇特征构造法及原始量测值特征训练 HODT 模型，记录二者所需训练时间。训练完成后，基于 DT 特征重要度排名，当测试集样本分别丢失电压幅值与相角排名分数前 1 至 4 所对应的母线量测信息后进行辨识任务，辨识准确率效果如图 6 所示(测试为 10 次均值结果，下同)。

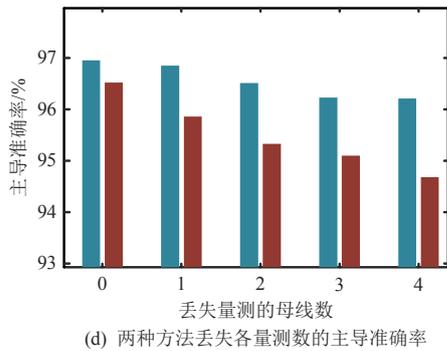
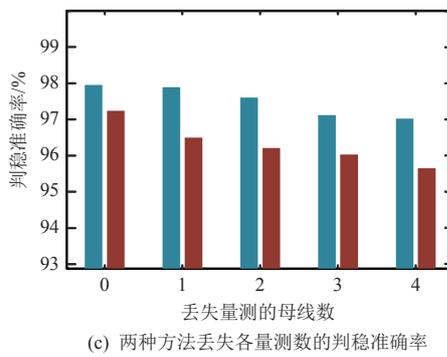
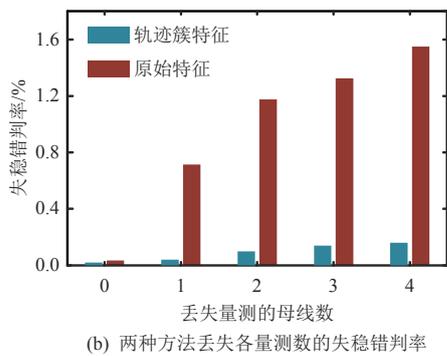
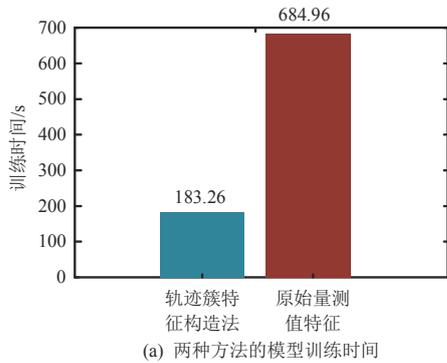


图 6 不同特征构造方法对辨识的影响

Fig. 6 Influence of different feature construction methods on identification

模型训练时间上，直接使用原始量测值所构造特征维数为 980 维，而滑窗轨迹簇特征构造法所构造特征维数 336 维，因而在模型训练时簇特征能避免过多的最优组合特征搜索过程，轨迹簇特征训练时间具有明显优势。

对于采集特征信息丢失的情况，直接采用量测数据进行模型构造的失稳错判率上升明显，两类准确率均不同程度下降。基于原始量测值训练模型对特征集合的完整性要求较高，在实际应用中若缺少一些关键量测信息，初始特征集将会直接产生空缺而受到很大干扰。而采用轨迹簇构建特征时以时序簇为整体，缺失少量的信息不会对整体统计量产生很大影响，鲁棒性强。

3.3.2 DT 融合 SVM 算法的有效性

本节对比相关暂态稳定评估研究中提出的几种倾斜决策树算法，包括二维组合属性决策树^[22]、线性决策树^[23]，同时对比了原始 DT 模型。各模型均采用分级自适应机制构建，测试结果如表 2、3 所示，其中判断时长为所有样本中最长辨识用时。

表 2 稳定性评估性能对比

模型	失稳错判率/%	稳定错判率/%	评估准确率/%	判断时长/s	训练时长/s
DT	0.56	5.43	95.00	0.60	33.87
文献[22]	0.16	4.80	96.29	0.52	114.57
文献[23]	0.24	4.01	97.50	0.50	95.42
HODT	0.02	3.88	97.95	0.46	73.04

表 3 主导失稳模式辨识性能对比

模型	功角错判率/%	电压错判率/%	辨识准确率/%	判断时长/s	训练时长/s
DT	6.62	6.57	93.06	0.68	44.89
文献[22]	2.64	8.25	94.78	0.64	195.79
文献[23]	4.26	2.79	96.03	0.64	177.48
HODT	3.40	2.61	96.95	0.58	109.56

可见，相较原 DT 算法，倾斜决策树能够在每次分裂中捕获更多的特征几何信息，获得了更优的准确率与判断时长。然而，文献[22]所提方法受限于二维特征规则维度，准确率提升有限，且反复搜索最优组合特征使模型训练时间明显增加。文献[23]构造特征向量的线性函数决策边界，较文献[22]进一步拓展了特征组合维度，使准确率得到明显优化，然而其在确定决策边界时仍依赖组合特征搜索，存在提升空间。而 HODT 在融合 SVM 后能在

充分利用特征信息的同时避免繁琐最优组合特征搜索过程,节省了训练时间;升阶的决策边界能够适应更加复杂的样本空间分布,进一步优化了准确率与总判断时长。

此外,为体现改进策略对减少规则数目的有效性,以故障发生后 0.2s 时刻为例,选取表 1 模型 1 的 DT 重要性排名前二的特征绘制测试集散点图,并分别采用 DT 与 HODT 确定决策边界,可视化结果如图 7 所示。可以发现,原始树模型需 8 条辨识规则才能形成较为准确的决策。采用升阶 SVM 改进后,其仅需 5 条就能完成划分。对于 DT 决策边界中 4 处红圈内的错分样本, HODT 改进后均能做到正确分类。因此,所提策略能够使决策规则更加简洁的同时有效提升判断精度。值得注意的是,对于左下角失稳域,此时两种主导模式的样本高度交叠,因而需借助更多的特征信息来拟合更加精确的决策边界,这也是采用多维组合特征的意义所在。

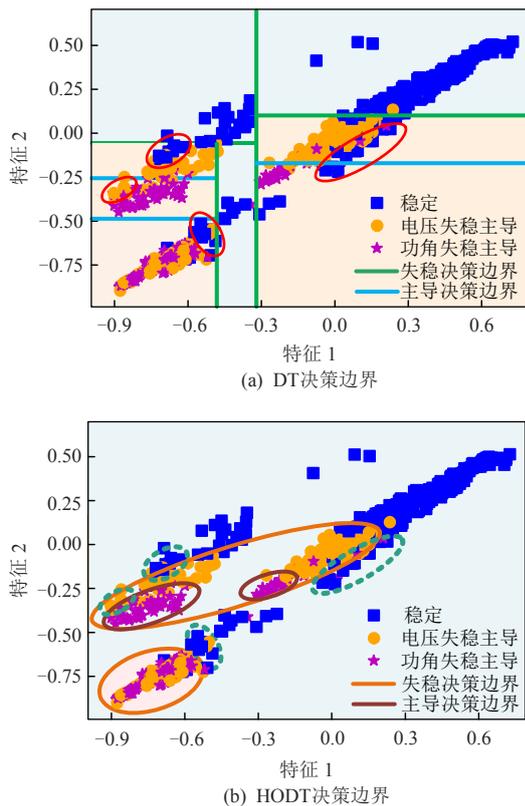


图 7 DT 与 HODT 决策边界示意

Fig. 7 DT and HODT decision boundary

为验证代价敏感系数 c 对降低失稳漏判的有效性,通过指定不同大小 c 值对模型稳定评估效果进行测试。如表 4 所示,随着失稳类代价敏感系数的逐步增加,失稳错判能够有效降低至 0,随之稳定样本错判率及相应的评估时间会有所增加。

表 4 不同代价敏感系数下模型性能测试

Table 4 Model performance tests under different cost sensitivity coefficients

c^{-}	失稳错判/%	稳定错判/%	评估准确率/%	辨识时长/s
0.8	0.04	3.88	97.95	0.58
0.85	0.02	4.64	97.49	0.64
0.9	0.00	5.22	97.29	0.66
0.95	0.00	7.93	95.89	0.72

进一步,通过选取一阶至四阶及径向基(radial basis function, RBF)核函数用于模型训练,对其辨识精度及训练时间进行了对比,以验证所选二阶核函数的合理性与有效性。如图 8 所示,由一阶升至二阶时其准确率提升较为明显,但继续升阶则效果不显著,其训练时间随阶数上升增加较多。RBF 核虽然取得了最优的辨识精度,但其规则无法解析表达出来,不能给出可视化的辨识流程并学习规则中所蕴含的有关知识。因此,综合考虑,本文选择二阶核函数能够兼顾精度、训练时间及规则解析的优势。

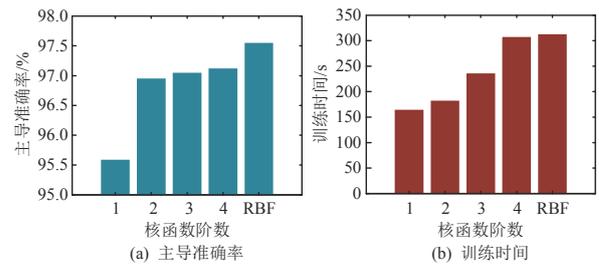


图 8 核函数选择影响

Fig. 8 Kernel function selection influence

3.3.3 分级自适应机制有效性

判断时间是评价模型性能的另一大关键指标。将 HODT 各级判稳与主导辨识样本数进行统计,如图 9 所示。

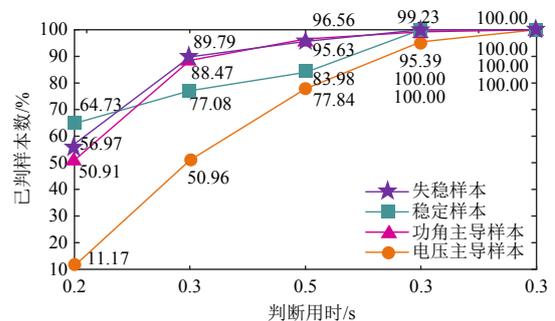


图 9 HODT 各级所判断样本数

Fig. 9 Number of samples judged by HODT level

在判稳阶段中,对于更为关心的失稳类样本,超过一半能够在全部故障切除时准确判断,近九成样本可以在故障发生 0.3s 内成功判断。在主导模式辨识阶段中,0.3、0.4 与 0.5s 内分别能够判断 88.47%、96.56%与 99.23%的功角主导失稳样本及

50.96%、77.84%与 95.39%的电压主导失稳样本。通过对每种类别所有样本所需判断时长累加求平均后，获得的失稳、稳定检测与功角、电压主导失稳模式识别平均时长分别只有 0.21、0.22、0.21 与 0.31 s。因此，对于严重失稳样本与表征明显的某种主导失稳模式，能够在特性表现之初就实现快速判断；对于临界判断有困难的样本，可以进行持续监测直至某种主导特性明显表征出来。

因所提方法通过分级方式构建各级分类器以提高辨识速度与准度，有必要将其与无分级 ODT 进行比较以证明其优势。无分级策略下，通过在每个时间点上判断所有测试样本的稳定性及主导模式检测结果来进行对比。如图 10 所示，失稳样本固定时间辨识均比分级策略错判率稍高；在达到与分级策略相同的错判率水平下，稳定判别、功角主导失稳与电压主导失稳分别须不早于 0.26、0.28 与 0.42 s 进行，相较分级策略下的平均时长滞后了 18.18%、33.33%与 35.48%，尤其是电压主导失稳模式在首次低于分级策略错判率之后仍有多次结果较差。而分级策略有助于进一步降低错判率，并相较后期固定时间判断具有更快的优势。

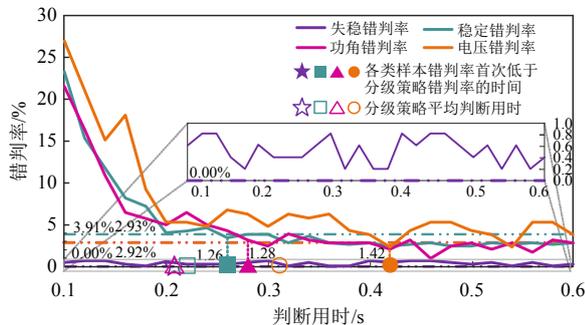


图 10 无分级策略的各级错判率

Fig. 10 Error rate at all levels without hierarchical strategy

在构建各级分类器时，自适应边界的选取对辨识结果也会有直接影响。以模型 1 功角主导失稳模式辨识为对象，在构建 HODT 各级分类器时，采用不同边界函数参数使模糊域边界自严苛至松弛演化，来试验不同边界对辨识错判率及用时的影响。参数取值及目标函数如表 5 所示，3 种参数互相组合 $5 \times 6 \times 5 = 150$ 种模糊域边界进行辨识，将对应错判率、分类级数与目标函数值组合绘制于图 11 中。 λ 由网格搜索所确定的最优值为 0.6。

可以看到，整体变化趋势为分类器级数与功角主导失稳错判率呈明显负相关，且全严苛或全松弛均不是最优策略；自适应机制以最小化目标函数为

表 5 边界参数取值及目标函数
Table 5 Boundary parameter values and objective functions

参数	参数取值	目标函数
m	0, 1, 2, 3, 4	$f=0.6 \times M/4 + 0.4 \times I/31$
k	0, 0.2, 0.4, 0.6, 0.8, 1	
b	0, 1, 2, 3, 4	

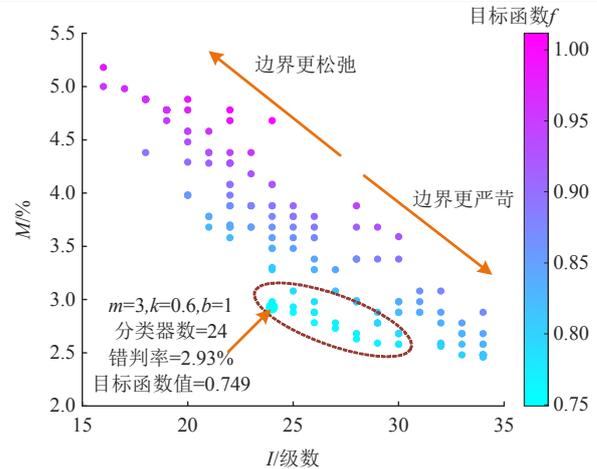


图 11 不同边界参数对自适应边界选取的影响

Fig. 11 Influence of different boundary parameters on adaptive boundary selection

准则，能够有效识别出 HODT 最优目标得分位于中央偏下区域。本文所选择的最优自适应边界为 $M_f = (3i^{0.6} + 1)/205$ ，其是辨识用时与错判率的最佳衡量。

上述分析综合体现了分级自适应机制可以在故障发生早期及时判断系统稳定性并给出相应的主导失稳模式结果，提高了辨识速度，同时能进一步降低错判率，兼顾了判断准确率的需求。

3.4 抗噪能力测试

考虑到实际中 PMU 量测噪声的存在，本节研究所提出方法在噪声条件下的评估表现。将分布服从 $N(0, \sigma^2)$ 的高斯噪声添加到四种电气量的时序轨迹中， σ 分别设置为 1%、2% 和 3%，以模拟实际不同级别的 PMU 噪声^[30]。采用滑窗轨迹测特征构造法并使用 HODT 进行主导失稳模式辨识，有关结果如表 6 所示。

表 6 PMU 噪声对辨识的影响

Table 6 Influence of PMU noise on identification

噪声大小	漏判率/%	判稳准确率/%	主导辨识准确率/%
无噪声	0.02	97.95	96.95
1%	0.04	97.13	96.52
2%	0.16	96.85	95.70
3%	0.62	96.23	95.31

显然，所提出的方法能够在不同水平噪声下实现期望的辨识性能。即使存在极其严重的噪声

(3%)，总准确率仍可以分别保持在96%与95%以上。由于实际PMU量测噪声通常要求小于1%^[31]，因此所提方法在实际量测环境中有望将评估精度保持在97%与96%以上，鲁棒性较强。

3.5 辨识规则分析

在实际工程应用中，往往需要知道辨识规则的解析表征。相较深度学习等“黑箱”算法，基于HODT方法所形成的辨识判据具有明确的多项式表征，能够可视化决策流程并分析其所蕴含机理。本节以第1组模型为实验对象，以第6级成功辨识的某电压失稳主导样本为例，自首级至末级提取其两阶段决策规则，对其判断流程进行分析。辨识流程如下：

级1： $(y_{(1,1)}^{(1)} < 0) \cap (-1.26 \leq y_{(1,2)}^{(1)} < 0)$ ，尚无法确定稳定性，推至下级；

级2： $(y_{(2,1)}^{(1)} < 0) \cap (-1.38 \leq y_{(2,2)}^{(1)} < 0)$ ，尚无法确定稳定性，推至下级；

级3： $(y_{(3,1)}^{(1)} < 0) \cap (-1.29 \leq y_{(3,2)}^{(1)} < 0)$ ，尚无法确定稳定性，推至下级；

级4： $(y_{(4,1)}^{(1)} < 0) \cap (y_{(4,2)}^{(1)} < -1.22)$ ，判为失稳，进入主导失稳模式辨识阶段； $-2.13 \leq y_{(4,1)}^{(2)} < 3.11$ ，尚无法确定主导失稳模式，推至下级；

级5： $-2.52 \leq y_{(5,1)}^{(2)} < 2.42$ ，尚无法确定主导失稳模式，推至下级；

级6： $(y_{(6,1)}^{(2)} < 0) \cap (y_{(6,3)}^{(2)} < -1.09)$ ，判为电压失稳主导模式。

其中， $y_{(j,k)}^{(i)} = \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{B} \mathbf{x} + b$ ， i, j, k 分别代表稳定性判断阶段(1)或主导模式辨识阶段(2)、时序层级与HODT内部节点标号。稳定性判断判据中 y 为正值判为稳定，负值为失稳；主导模式辨识判据中正值判为功角失稳主导，负值为电压失稳主导。

所生成判据为多特征非线性组合多项式， y 为模型训练所得到门槛值。可以看出，规则包含单特征二次项、两特征乘积项、单特征一次项及常数项。

对于单特征二次项及一次项，稳定性判据中特征变换系数大小均反映了相应特征对稳定性的正面或负面影响程度；主导辨识判据变换系数大小也均体现了相应特征反映某种稳定形态占主导地位的重要程度。以级1稳定性判据中所含 $1.14(U_{\min}^t)^2$ 及 $0.86(U_{\mu}^t)^2$ 二次项为例，由二者变换系数为正可知，电压特征的数值越大则系统越稳定；并且对比

两系数大小可以发现，系统稳定性对负荷母线中最低电压的变化情况更为敏感。相较所有节点的电压均值，若最低节点电压不能及时恢复，往往会导致临近节点电压进一步发生崩溃，从而衍生整体系统失稳事故。主导辨识判据中所含 $1.33(\theta_{\min}^t)^2$ 及 $-0.59(U_{\min}^t)^2$ 二次项能够直观体现出相角量与电压量对两种主导失稳模式辨识的直接贡献。一次项系数作用原理与二次项系数相似。

对于两特征乘积项，其能够反映两种特征间潜在的关系。级1稳定性判据中 $-0.35\theta_{\min}^t P_{\max}^t$ 项可知，若相角增大而传输有功相对较小时，距离线路功率传输极限较远，经过多摆振荡后能够保持系统功角稳定；而当传输有功也相对较大时，该项乘积负值较大，此时接近线路功率传输极限而使功角稳定性变差。该项可以体现出系统功率传输极限尚存裕度。对于稳定性判据 $0.23U_{\mu}^t Q_k^t$ 项，若电压低而传输无功较大则不易导致失稳，当电压低而传输无功不足时即容易导致失稳。该项可以体现出系统无功支撑能力是否充足。同时，对于主导辨识判据中 $0.56U_{\mu}^t \theta_{\min}^t$ 项，若电压一定，相角越大则越容易为功角失稳主导，反之若相角一定，电压越低则越容易为电压失稳主导。由于两种失稳模式同时存在时往往会发生电压降低与相角增大同时存在的情况，因而当其中某种特征变化更为明显时则更能够突出该种失稳模式所占的主导地位。

上述分析可知，所提方法的辨识规则含有明确的多项式表达式，计算过程透明，实际工程中可以对其应用效果进行有效把握。同时，其能够将多种特征关系联系在一起，弥补了传统决策树仅能分析单一变量与稳定性间关联及线性决策树规则中特征间关联分析能力的不足，为稳定性及主导失稳模式机理分析提供了新思路。

3.6 泛化性能验证

本节采用中国电科院万节点标准算例测试系统检验所提方法在大规模系统中的泛化性能。该系统示意如图12所示，包括送端和受端2个子系统，其中送端系统分3个区，分区1S为高比例新能源风火打捆外送，分区2S为常规负荷中心，分区3S为高比例水电外送；受端系统分4个区，分区1R为受电区域，分区2R含高比例新能源，分区3R为交直流混联受电，分区4R为纯电源基地。送受端系统均以500kV为主网架，包含10575个三相节点、约550台同步电源、风/光可再生能源场站1031

个；电源总装机 28 958 万 kW，常规机组装机 17 896 万千瓦，新能源装机 11 062 万 kW(占总装机 38.2%)；系统含 6 回直流，其中送受端通过 3 回 800 万直流相连，送端 1 回送往其他电网，受端 2 回由其他电网馈入。负荷采用综合负荷模型。

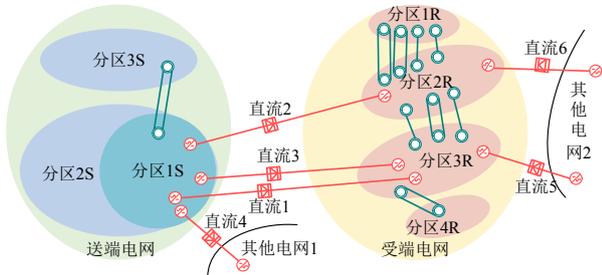


图 12 万节点测试系统示意图

Fig. 12 Schematic diagram of 10,000 node test system

根据某实际送受端电网近 3 年峰谷平差别较大月份的日负荷情况以及年度新能源调研情况，分析确定了 10 套运行方式，包含 6 种高峰方式、1 种平荷及 3 种低谷方式。对每种方式设置包括 N-1、N-2、直流双极闭锁、直流连续换相失败、多直流同时故障等多种类型故障。共仿真获得 7 920 条样本，算法训练集与测试集样本比例设置为 4:1。特征构建方法及标签标定方法等与 CEPRI-TAVC 算例一致。

对所提 HODT 模型进行准确率综合测试。HODT 相关超参数 c 、 m 、 k 、 b 与 λ 初值与 CEPRI-TAVC 相同，期望参数 M_{max} 、 I_{max} 通过实验确定并根据实际需求适当放宽为 6% 与 41。通过改变算法随机种子参数来随机训练模型 10 次，将各次测试结果列入表 7。此外，同样对比了相关决策树算法，测试结果如表 8、9 所示。

表 7 HODT 模型泛化测试

Table 7 HODT model generalization test

模型 序号	稳定性评估			主导失稳模式辨识		
	失稳	稳定	准确	功角	电压	准确
	错判率/%	错判率/%	率/%	错判率/%	错判率/%	率/%
1	0.22	5.32	96.21	5.98	5.83	94.09
2	0.00	5.73	95.90	5.65	5.45	94.45
3	0.00	5.03	96.40	5.91	5.17	94.47
4	0.65	6.41	95.27	6.64	5.83	93.91
5	0.00	5.67	95.96	5.98	5.45	94.30
6	0.45	6.77	95.01	6.70	6.28	93.51
7	0.44	7.00	94.89	6.49	7.14	93.19
8	0.00	5.44	96.15	5.63	5.80	94.38
9	0.00	5.48	96.09	5.17	5.91	94.47
10	0.22	6.66	95.20	5.60	6.17	94.18
平均	0.20	5.95	95.71	5.98	5.90	94.10

表 8 稳定性评估性能对比

Table 8 Stability evaluation performance comparison

模型	失稳 错判率/%	稳定 错判率/%	评估 准确率/%	判断 时长/s	训练 时长/s
DT	1.75	9.39	92.80	0.86	44.06
文献[22]	1.33	7.69	94.13	0.76	149.00
文献[23]	1.10	7.30	94.51	0.78	131.48
HODT	0.20	5.95	95.71	0.74	87.65

表 9 主导失稳模式辨识性能对比

Table 9 Comparison of the performance of leading instability mode identification

模型	功角 错判率/%	电压 错判率/%	辨识 准确率/%	判断 时长/s	训练 时长/s
DT	8.79	10.70	90.31	0.96	60.35
文献[22]	7.76	7.17	92.53	0.94	181.05
文献[23]	6.64	6.82	93.28	0.94	160.24
HODT	5.98	5.90	94.10	0.88	104.05

可见，HODT 在大规模电力系统场景下模型指标依旧表现较好。其 10 次测试可以做到 5 次错判率为 0；稳定错判率及两种主导失稳模式辨识错判率有 6 次能够均位于 6% 以下，模型的辨识准确性较好。同时，相较原始 DT 及相关研究所提斜决策树模型，HODT 仍具有显著优势。因而其能够有效适应不同系统结构与运行方式的主导失稳模式辨识任务，泛化性较强。

在不同特征构造法构建评估模型用时上，由于系统规模显著扩大，基于原始量测值所构造特征维数上升为 5 360 维，而滑窗轨迹簇特征构造法依旧仅使用 336 维，因而二者模型训练用时分别为 2 092.81 s 与 191.70 s，采用滑窗轨迹簇特征构造法减少了 90.84% 的训练时间，因此滑窗轨迹簇特征构造法不会受系统规模增大的影响，具有很强的普适性。

4 结论

本文提出一种基于分级自适应倾斜决策树的电网主导失稳模式辨识方法，基于两个标准算例测试系统验证了方法的有效性。主要贡献如下：

1) 倾斜决策树模型能够充分利用支持向量机自动组合特征生成决策函数的能力，提升原始决策树对不规则分类边界的拟合性能，准确给出主导失稳模式辨识结果；同时代价敏感机制可以强化对失稳类样本的错判惩罚，在稳定性判别阶段有效降低失稳样本错判率。

2) 提出一种分级自适应的判断机制，分级机制可以将判断置信度偏低的样本在时序后级获得

更多信息后再进行准确辨别,自适应机制通过结合先严苛后松弛的模糊域边界函数表征来进一步提升方法的判断速度与准确性。

3)方法所生成的辨识判据具有明确多项式表征,计算过程直观透明,能够明确给出主导失稳模式的计算指标值,同时有助于挖掘多组合特征与稳定性及主导失稳模式间的关联关系。

4)滑窗轨迹簇特征构造法对PMU量测信息丢失、系统规模变大等场景具有很好的适应性。

综上,所提方法在电网主导失稳模式辨识中具有一定应用潜力。后续研究将进一步分析期望参数取值规律以更好适应不同电力系统需求。

参考文献

- [1] 张智刚,康重庆.碳中和目标下构建新型电力系统的挑战与展望[J].中国电机工程学报,2022,42(8):2806-2818.
ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2818(in Chinese).
- [2] 贺之渊,杨杰,吴亚楠,等.能源转型下的未来交流和直流联合运行模式及发展趋势探讨[J].中国电机工程学报,2023,43(1):99-113.
HE Zhiyuan, YANG Jie, WU Yanan, et al. Investigation on the future AC and DC combined operation form and development trend under energy transition[J]. Proceedings of the CSEE, 2023, 43(1): 99-113(in Chinese).
- [3] 林伟芳,易俊,郭强,等.阿根廷“6.16”大停电事故分析及对中国电网的启示[J].中国电机工程学报,2020,40(9):2835-2841.
LIN Weifang, YI Jun, GUO Qiang, et al. Analysis on blackout in Argentine power grid on June 16, 2019 and its enlightenment to power grid in China[J]. Proceedings of the CSEE, 2020, 40(9): 2835-2841(in Chinese).
- [4] 李琳,冀鲁豫,张一驰,等.巴基斯坦“1·9”大停电事故初步分析及启示[J].电网技术,2022,46(2):655-661.
LI Lin, JI Luyu, ZHANG Yichi, et al. Preliminary analysis and lessons of blackout in Pakistan power grid on January 9, 2021[J]. Power System Technology, 2022, 46(2): 655-661(in Chinese).
- [5] 黎晓,刘崇茹,辛蜀骏,等.暂态功角稳定与暂态电压稳定的耦合机理分析与耦合强度评估指标[J].中国电机工程学报,2021,41(15):5091-5106.
LI Xiao, LIU Chongru, XIN Shujun, et al. Coupling mechanism analysis and coupling strength evaluation index of transient power angle stability and transient voltage stability[J]. Proceedings of the CSEE, 2021, 41(15): 5091-5106(in Chinese).
- [6] GNANAVIGNESH R, SHENOY U J. An improved relaxation based spatial domain decomposition method for parallel transient stability simulation[J]. International Journal of Electrical Power & Energy Systems, 2022, 135: 107561.
- [7] 魏少攀,杨明,韩学山,等.一种利用机端电压幅值轨迹MLE指标的暂态功角稳定在线辨识方法[J].中国电机工程学报,2017,37(13):3775-3786.
WEI Shaopan, YANG Ming, HAN Xueshan, et al. An online identification method for transient angle stability using MLE index of generator terminal voltage amplitude trajectory[J]. Proceedings of the CSEE, 2017, 37(13): 3775-3786(in Chinese).
- [8] 汤涌,姚伟,王宏志,等.电网仿真分析与决策的人工智能方法[J].中国电机工程学报,2022,42(15):5384-5405.
TANG Yong, YAO Wei, WANG Hongzhi, et al. Artificial intelligence techniques for power grid simulation analysis and decision making[J]. Proceedings of the CSEE, 2022, 42(15): 5384-5405(in Chinese).
- [9] 李福成,徐箭,廖思阳,等.基于样本关注度和多层次特征的多阶段电力系统暂态稳定评估[J].中国电机工程学报,2021,41(22):7596-7607.
LI Fucheng, XU Jian, LIAO Siyang, et al. Multi-stage power system transient stability assessment based on sample attention and hierarchical features[J]. Proceedings of the CSEE, 2021, 41(22): 7596-7607(in Chinese).
- [10] 田芳,周孝信,史东宇,等.基于卷积神经网络综合模型和稳态特征量的电力系统暂态稳定评估[J].中国电机工程学报,2019,39(14):4025-4031.
TIAN Fang, ZHOU Xiaoxin, SHI Dongyu, et al. Power system transient stability assessment based on comprehensive convolutional neural network model and steady-state features[J]. Proceedings of the CSEE, 39(14): 4025-4031(in Chinese).
- [11] 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).
- [12] 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).
- [13] 李宗翰, 孙华东, 郑超, 等. 基于广域支路响应无功分布特征的主导失稳形态判别[J]. 中国电机工程学报, 2023, 43(13): 4883-4898.
- LI Zonghan, SUN Huadong, ZHENG Chao, et al. Discrimination of dominant instability mode based on the reactive power distribution characteristic of wide-area branch response[J]. Proceedings of the CSEE, 2023, 43(13): 4883-4898(in Chinese).
- [14] 史法顺, 吴俊勇, 季佳伸, 等. 基于深度学习的电力系统暂态电压与暂态功角稳定一体化超前评估[J]. 电网技术, 2023, 47(2): 741-754.
- SHI Fashun, WU Junyong, JI Jiashen, et al. Integrated advance assessment of power system transient voltage and transient angle stability based on deep learning[J]. Power System Technology, 2023, 47(2): 741-754(in Chinese).
- [15] 孙黎霞, 彭嘉杰, 白景涛, 等. 结合图嵌入算法的电力系统多任务暂态稳定评估[J]. 电力系统自动化, 2022, 46(2): 83-91.
- SUN Lixia, PENG Jiajie, BAI Jingtao, et al. Multi-task transient stability assessment of power system incorporating graph embedding algorithm[J]. Automation of Electric Power Systems, 2022, 46(2): 83-91(in Chinese).
- [16] 胡泽, 曾令康, 姚伟, 等. 电力系统两阶段紧急切负荷控制智能预决策[J]. 中国电机工程学报, 2024, 44(4): 1260-1272.
- HU Ze, ZENG Linggang, YAO Wei, et al. Intelligent pre-decision of two-stage emergency load shedding control in power systems[J]. Proceedings of the CSEE, 2024, 44(4): 1260-1272(in Chinese).
- [17] 石重托, 姚伟, 黄彦浩, 等. 基于 SE-CNN 和仿真数据的电力系统主导失稳模式智能识别[J]. 中国电机工程学报, 2022, 42(21): 7719-7730.
- SHI Zhongtuo, YAO Wei, HUANG Yanhao, et al. Power system dominant instability mode identification based on convolutional neural networks with squeeze and excitation block and simulation data[J]. Proceedings of the CSEE, 2022, 42(21): 7719-7730(in Chinese).
- [18] ZHANG Runfeng, YAO Wei, SHI Zhongtuo, et al. A graph attention networks-based model to distinguish the transient rotor angle instability and short-term voltage instability in power systems[J]. International Journal of Electrical Power & Energy Systems, 2022, 137: 107783.
- [19] 史法顺, 吴俊勇, 吴昊衍, 等. 基于深度学习的电力系统暂态功角与暂态电压稳定裕度一体化评估[J]. 电网技术, 2023, 47(2): 731-740.
- SHI Fashun, WU Junyong, WU Haoyan, et al. Integrated evaluation of power system transient power angle and transient voltage stability margin based on deep learning[J]. Power System Technology, 2023, 47(2): 731-740(in Chinese).
- [20] LASHGARI M, SHAHRTASH S M. Fast online decision tree-based scheme for predicting transient and short-term voltage stability status and determining driving force of instability[J]. International Journal of Electrical Power & Energy Systems, 2022, 137: 107738.
- [21] TOMITA T M, BROWNE J, SHEN Cencheng, et al. Sparse projection oblique random forests[J]. The Journal of Machine Learning Research, 2020, 21(1): 104.
- [22] 王康, 孙宏斌, 张伯明, 等. 基于二维组合属性决策树的暂态稳定评估[J]. 中国电机工程学报, 2009, 29(S1): 17-24.
- WANG Kang, SUN Hongbin, ZHANG Boming, et al. Transient stability assessment based on 2D combined attribute decision tree[J]. Proceedings of the CSEE, 2009, 29(S1): 17-24(in Chinese).
- [23] 孙宏斌, 王康, 张伯明, 等. 采用线性决策树的暂态稳定规则提取[J]. 中国电机工程学报, 2011, 31(34): 61-67.
- SUN Hongbin, WANG Kang, ZHANG Boming, et al. Rule extraction in transient stability study using linear decision trees[J]. Proceedings of the CSEE, 2011, 31(34): 61-67(in Chinese).
- [24] MONTAÑANA R, GÁMEZ J A, PUERTA J M. STree: a single multi-class oblique decision tree based on support vector machines[C]//Proceedings of the 19th Conference of the Spanish Association for Artificial Intelligence. Málaga: Springer, 2021.
- [25] IRANMEHR A, MASNADI-SHIRAZI H, VASCONCELOS N. Cost-sensitive support vector machines[J]. Neurocomputing, 2019, 343: 50-64.
- [26] ZHANG Yuchen, XU Yan, DONG Zhaoyang, et al. A hierarchical self-adaptive data-analytics method for real-time power system short-term voltage stability assessment[J]. IEEE Transactions on Industrial Informatics, 2019, 15(1): 74-84.
- [27] 甄永赞, 阮程. 基于代价敏感支持向量机和多变量决策树的分级自适应暂态电压稳定评估[J]. 电网技术, 2024, 48(2): 778-791.
- ZHEN Yongzan, RUAN Cheng. Hierarchical self-adaptation transient voltage stability assessment based on cost-sensitive SVM and multivariate decision tree [J]. Power System Technology, 2024, 48(2): 778-791(in Chinese).
- [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] 国家市场监督管理总局, 国家标准化管理委员会. GB 38755—2019 电力系统安全稳定导则[S]. 北京: 中国

标准出版社, 2019.

State Administration of Market Supervision and Administration of the People's Republic of China, Standardization Administration of the People's Republic of China. GB 38755—2019 Code on security and stability for power system[S]. Beijing: Standards Press of China, 2019(in Chinese).

[30] ZHU Lipeng, HILL D J. Networked time series shapelet learning for power system transient stability assessment [J]. IEEE Transactions on Power Systems, 2022, 37(1): 416-428.

[31] GOMEZ F R, RAJAPAKSE A D, ANNAKAGE U D, et al. Support vector machine-based algorithm for post-fault transient stability status prediction using synchronized measurements[J]. IEEE Transactions on Power Systems, 2011, 26(3): 1474-1483.

附录 A

以电压幅值 U 为例, 第 t 辨识时刻构造的轨迹簇特征集合如表 A1 所示。电压相角 θ 、线路有功 P 及线路无功 Q 轨迹簇特征构造与之相同, 不再赘述。

表 A1 电压轨迹簇特征集合

Table A1 Voltage trajectory cluster feature set

序号	特征内容
1—7	$t-4$ 时刻轨迹簇的均值、方差、最大值、最小值、中位数、偏度和峰度
8—14	$t-3$ 时刻轨迹簇的均值、方差、最大值、最小值、中位数、偏度和峰度
15—21	$t-2$ 时刻轨迹簇的均值、方差、最大值、最小值、中位数、偏度和峰度
22—28	$t-1$ 时刻轨迹簇的均值、方差、最大值、最小值、中位数、偏度和峰度
29—35	t 时刻轨迹簇的均值、方差、最大值、最小值、中位数、偏度和峰度
36—42	8—14 的速度
43—49	15—21 的速度
50—56	22—28 的速度
57—63	29—35 的速度
64—70	15—21 的加速度
71—77	22—28 的加速度
78—84	29—35 的加速度

7 种轨迹簇基本统计特征计算公式如下:

1) 均值:

$$U_{\mu} = \frac{1}{m} \sum_{i=1}^m U_i \quad (A1)$$

式中 m 为负荷母线数, 下同。

2) 方差:

$$U_{\sigma^2} = \frac{1}{m} \sum_{i=1}^m |U_i - \mu|^2 \quad (A2)$$

3) 最大值:

$$U_{\max} = \max \{U_i\}, i=1, 2, \dots, m \quad (A3)$$

4) 最小值:

$$U_{\min} = \min \{U_i\}, i=1, 2, \dots, m \quad (A4)$$

5) 中位数:

$$U_{\text{med}} = \frac{1}{2}(U_{\max} + U_{\min}), i=1, 2, \dots, m \quad (A5)$$

6) 偏度:

$$U_s = \frac{1}{m} \sum_{i=1}^m (U_i - \mu)^3 / \sigma^3 \quad (A6)$$

7) 峰度:

$$U_k = \frac{1}{m} \sum_{i=1}^m (U_i - \mu)^4 / \sigma^4 \quad (A7)$$

以电压均值为例, 两种轨迹簇基本时序变化趋势特征计算公式如下:

1) 速度:

$$v_{U_{\mu}}(t-i) = \frac{U_{\mu}(t-i) - U_{\mu}(t-i-1)}{\Delta T} \quad (A8)$$

式中: $i \in \{0, 1, 2, 3, 4\}$; $\Delta T=1$ (单位周波), 下同。

2) 加速度:

$$a_{U_{\mu}}(t-i) = \frac{v_{U_{\mu}}(t-i) - v_{U_{\mu}}(t-i-1)}{\Delta T} \quad (A9)$$



甄永赞

在线出版日期: 2023-12-14.

收稿日期: 2023-06-16.

作者简介:

甄永赞(1985), 男, 博士, 副教授, 主要研究方向为新能源发电与电力系统控制, zhenyongzan_001@126.com;

*通信作者: 阮程(1999), 男, 硕士研究生, 主要研究方向为新能源电力系统, 858635218@qq.com;

胡永强(1981), 男, 讲师, 主要研究方向为新能源电力系统稳定分析与控制、新能源电力系统优化运行与调度, hy_qiang@126.com;

李宗翰(1993), 男, 博士, 主要研究方向为电力系统稳定分析与控制、人工智能在电力系统的应用, lzh624218372@163.com;

袁超(1995), 男, 本科, 中级工程师, 主要研究方向为电力系统稳定分析与控制, 1518898477@qq.com.

(编辑 乔宝榆, 李新洁)