

DOI: 10.19783/j.cnki.pspc.191244

# 基于 MVEE 和 LSPTSVM 的电力系统暂态稳定评估

王亮<sup>1</sup>, 韩冬<sup>2</sup>, 王长江<sup>2</sup>, 魏俊红<sup>3</sup>, 李斌<sup>4</sup>

(1. 国网辽宁省电力有限公司, 辽宁 沈阳 110006; 2. 东北电力大学电气工程学院, 吉林 吉林 132012; 3. 华电电力科学研究院有限公司东北分公司, 辽宁 沈阳 110167; 4. 国网辽宁省电力有限公司电力科学研究院, 辽宁 沈阳 110006)

**摘要:** 针对采用模式识别法进行电力系统暂态稳定评估时输入特征集构建困难和评估模型训练速度慢的问题, 提出一种基于最小体积闭包椭球理论(Minimum Volume Enclosing Ellipsoid, MVEE)和最小二乘投影孪生支持向量机(Least Square Projection Twin Support Vector machine, LSPTSVM)的电力系统暂态稳定评估方法。首先, 根据 MVEE 理论对系统轨迹信息进行优化处理, 确定高维空间内包含所有轨迹信息的最小体积闭包椭球, 并利用最小体积闭包椭球的物理属性构建输入特征集, 可有效实现特征集降维。其次, 在传统投影孪生支持向量机的目标函数中引入正则化项, 并改进评估模型的内部约束条件, 提高模型的求解速度, 达到大规模电力系统的计算效率需求。最后, 通过对 IEEE-39 和 IEEE-145 节点系统的算例分析, 验证所提方法的有效性与其可行性。

**关键词:** 模式识别; 暂态稳定评估; 最小体积闭包椭球; 最小二乘投影孪生支持向量机

## Power system transient stability assessment based on MVEE and LSPTSVM

WANG Liang<sup>1</sup>, HAN Dong<sup>2</sup>, WANG Changjiang<sup>2</sup>, WEI Junhong<sup>3</sup>, LI Bin<sup>4</sup>

(1. State Grid Liaoning Electric Power Supply Co., Ltd., Shenyang 110006, China; 2. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 3. Northeast China Branch, Huadian Electric Power Research Institute Co., Ltd., Shenyang 110167, China; 4. Electric Power Research Institute of State Grid Liaoning Electric Power Co., Ltd., Shenyang 110006, China)

**Abstract:** Given the difficulties of constructing the feature set and the slow training speed of the evaluation model when using the pattern recognition method for power system transient stability assessment, a power system transient stability assessment method based on Minimum Volume Enclosing Ellipsoid (MVEE) and Least Square Projection Twin Support Vector Machine (LSPTSVM) is proposed. First, according to the MVEE theory, the system trajectory information is optimized to determine the minimum volume closure ellipsoid with all trajectory information in high dimensional space. We construct the input feature set using the physical properties of the minimum volume closure ellipsoid. This can effectively achieve feature set dimension reduction. Secondly, a regularization term is introduced into the objective function of the traditional projection twin support vector machine, and the internal constraints of the evaluation model are improved. This can improve the solution speed of the model and meet the computational efficiency requirements of large-scale power systems. Finally, the validity and feasibility of the proposed method are verified by the case analysis of IEEE-39 and IEEE-145 node systems.

This work is supported by Science and Technology Project of State Grid Corporation of China (No. SGTYHT17-JS-199) and Science and Technology Project of State Grid Liaoning Electric Power Co., Ltd. (No. SGTYHT17JS201).

**Key words:** pattern recognition; transient stability assessment; minimum volume enclosing ellipsoid; least square projection twin support vector machine

## 0 引言

随着我国电力系统规模的不断扩大以及各区域

**基金项目:** 国家电网有限公司科技项目资助 (SGTYHT17-JS-199) “千万千瓦级分层接入直流送受端系统动态行为机理和协调控制措施研究”; 国网辽宁省电力有限公司科技项目资助 (SGTYHT17JS201) “辽宁电网利用广域量测系统提升电网安全稳定运行水平的技术研究”

间互联日益密切, 区域内停电故障会对互联系统造成一定的潜在威胁, 甚至引发一系列大规模连锁停电事故, 造成严重的经济损失<sup>[1-3]</sup>。电力系统暂态稳定评估作为判断系统经历大扰动后各发电机能否恢复同步运行的暂态稳定性分析方法, 可准确判断电力系统的暂态稳定状态, 并指导调度人员采取相应的安全稳定控制措施, 避免大面积停电, 对保障电力系统的安全稳定运行具有重要意义<sup>[4]</sup>。

电力系统暂态稳定评估主要分为时域法、能量

函数法以及模式识别<sup>[5]</sup>。时域法可通过对系统暂态过程中的微分方程进行求解,以确定系统的运行轨迹,并根据其变化情况判断系统未来时刻的稳定状态,具有评估精度高、可靠性强的优点,但面对大规模系统时会暴露出计算量较大、评估效率不足的缺点<sup>[6-7]</sup>。能量函数法可给出系统暂态稳定裕度,具有计算速度快的优点,但该方法易受系统模型限制,求解不同系统拓扑稳定裕度的通用性较差<sup>[8]</sup>。模式识别利用大数据挖掘方法建立故障样本与系统稳定状态之间的映射关系,并通过该映射关系对系统进行暂态稳定评估,具有计算速度快、评估准确率高以及受系统规模影响较小等优点,近年来一直是国内外研究热点<sup>[9]</sup>。

目前模式识别法的难点主要集中在特征构建与分类器模型构建两部分<sup>[10]</sup>。特征构建方面,文献[11]利用机械功率平均值、加速度均值、最大转子动能等系统指标作为特征量构建特征集,对系统运行状态进行多层次全方位描述,有效表征输入特征集与系统稳定状态之间的联系,具有较好的评估效果。文献[12]在利用系统运行数据构建系统特征集的基础上,引入投影能量函数角速度、加速度等指标补充传统特征集,可兼顾特征信息相关性和高维特征集问题,有效改善评估性能。文献[13]将系统暂态过程中所有发电机的相对转子角轨迹视为一个整体簇,定义转子角轨迹簇的4项基本指标作为输入特征,并将该4项指标的变化率以及加速度等其他信息作为输入特征构建输入特征集。文献[14]借助最小体积闭包椭球,将系统内所有同步相量测量单元采集到的电网数据转换为单个独立的最小体积闭包椭球以识别电网扰动,可有效降低数据维度,将计算复杂程度较高的数据转换为复杂程度较低的数据。文献[15]将 MVEE 理论与系统量测数据相结合,通过闭包椭球的动态变化特性判断系统稳定程度。鉴于 MVEE 在特征构建方面的优势,本文采用 MVEE 对系统量测信息进行优化处理,并依据椭球的物理属性构建表征系统稳定性的特征,有效降低特征集维度,提高暂态稳定评估的性能。

分类器模型构建方面,支持向量机(Support Vector Machine, SVM)可在高维特征空间内构建分类超平面,实现暂态稳定、不稳定状态的分类,具有较强的泛化能力,已被广泛应用于电力系统暂态稳定评估领域,但 SVM 存在计算复杂度高的缺陷<sup>[16-20]</sup>。近年来,衍生类 SVM-非平行超平面分类器(Nonparallel Hyperplane Classifier, NHC)逐渐成为研究热点<sup>[21]</sup>。文献[21]提出的特征值中心支持向量机(Generalized Eigenvalue Proximal Support Vector

Machine, GEPSVM)可分别确定不同类样本的超平面,使分类超平面与本类样本之间距离最小化,同时与其他类样本距离最大化。在 GEPSVM 的基础上,文献[22]提出孪生支持向量机(Twin Support Vector Machine, TWSVM),使样本尽量分布在超平面附近,并在 GEPSVM 的基础上进行算法优化,提升了原模型的评估精度。文献[23]构建了投影孪生支持向量机(Projection Twin Support Vector Machine, PTSVM),该模型通过确定最优投影轴实现样本分类,使得样本在投影轴上的投影点尽量聚集在均值附近,但存在初值要求较高和计算量较大的不足。本文在 PTSVM 的目标函数中引入正则化项以改善评估模型的稳定性,同时优化处理评估模型的不等式约束和松弛变量,以线性方程组替代原二次规划问题,避免对偶问题的复杂求解过程,有效改善评估模型的计算速度。

## 1 基于 MVEE 理论的轨迹信息优化处理

最小体积闭包椭球理论是一种数据优化方法,其核心思想是寻找与  $n$  维点集同维度的最小闭包椭球。该椭球包含点集内的所有数据,并对  $n$  维点集进行优化处理,确定数据的最优表达方案,在一定程度上减轻该点集的时间复杂度和空间复杂度,大幅度提高计算精度和计算速度<sup>[4]</sup>,该方法已成功应用于包括模式识别在内的多个领域<sup>[24-27]</sup>。因此可通过 MVEE 理论将电力系统的大规模、高维度数据转化为能够表征系统特性的低维度、高精度的数据,缓解分类器模型计算压力,提升暂态稳定评估的准确率和计算速度。

将 MVEE 理论应用于电力系统轨迹信息优化处理时,首先确定由系统轨迹信息构造的原始高维点集。假设存在  $m$  个同步相量测量单元(Phasor Measurement Unit, PMU),分别工作在系统内各发电机节点,对系统运行状态进行实时监测<sup>[27]</sup>。任一时刻下,某 PMU 对其所在发电机节点的  $n$  个特定轨迹信息(例如发电机功角、发电机转速等)进行数据采集,并构建  $n$  维列向量  $\boldsymbol{a}$ 。同理,将系统内全部 PMU 在该时刻观测所得的  $m$  个  $n$  维量测信息列向量进行数据整合,获取  $n \times m$  阶矩阵  $\boldsymbol{S} = [\boldsymbol{a}_1, \boldsymbol{a}_2, \dots, \boldsymbol{a}_m]$ ,其中  $\boldsymbol{a}_1, \boldsymbol{a}_2, \dots, \boldsymbol{a}_m$  为此时刻下发电机节点 1 至节点  $m$  的轨迹信息。矩阵  $\boldsymbol{S}$  为电力系统的原始点集,描述了系统在当前时刻的运行状态,通过原始点集  $\boldsymbol{S}$  可确定其对应的最小体积闭包椭球  $E_{Q,c}$ ,其表达式为<sup>[28]</sup>

$$E_{Q,c} = \left\{ \boldsymbol{\alpha}_i \in \boldsymbol{R}^n / (\boldsymbol{\alpha}_i - \boldsymbol{c})^T \boldsymbol{Q} (\boldsymbol{\alpha}_i - \boldsymbol{c}) \leq 1 \right\} \quad (1)$$

式中:  $\mathbf{c}$  为列向量, 表示椭球的中心位置;  $\mathbf{Q}$  为对称正定矩阵, 表示椭球的形状与体积;  $\mathbf{R}^n$  为系统轨迹信息所对应的  $n$  维样本空间。通过对  $\mathbf{Q}$ 、 $\mathbf{c}$  求解来确定椭球的空间位置和外部形态<sup>[28-30]</sup>, 利用位置与形态对系统数据进行二次表达, 将轨迹信息由高维转化至低维, 以达到对原始电力系统数据优化处理的目的。

## 2 基于 LSPTSVM 的暂态稳定评估

### 2.1 通过 MVEE 构建特征

根据上一节中对 MVEE 理论的讨论可知, 将该方法应用于电力系统数据优化处理时, 可将多节点、大规模、高维度的电力系统数据转换为空间椭球, 降低信息处理的难度与数据计算的复杂度。即可通过椭球的形态大小  $\mathbf{Q}$  和空间位置  $\mathbf{c}$  对系统节点信息进行描述, 同时根据  $\mathbf{Q}$ 、 $\mathbf{c}$  寻找新的能够表征系统稳定程度的特征量, 以完成特征构建。

系统在运行状态下, PMU 所采集的发电机节点信息时刻变化, 则通过 MVEE 理论和节点数据所生成的椭球亦随之发生变化, 包括椭球的形态、大小和位置等物理属性。因此, 可以由这些物理属性完成特征构建工作, 所建立的输入特征集对系统稳定水平具有一定代表性, 可用于模型训练与分类。

物理属性具体包括如下几方面。

#### 1) 椭球体积

椭球的体积公式为

$$V(\mathbf{E}_{\mathbf{Q}, \mathbf{c}}) = \rho_n \frac{1}{\sqrt{\det \mathbf{Q}}} \quad (2)$$

式中,  $\rho_n$  为电力系统  $n$  维样本空间内的单位椭球体积。椭球的体积是发电机参数信息的直观体现, 构建椭球所用的发电机特定参数数值在暂态过程中激增, 直接引起椭球体积的增大, 加剧系统压力。体积越大, 代表系统承受的压力越大, 振荡现象越严重, 系统趋向于失稳; 体积越小, 代表系统越平稳, 运行处于稳定状态。

#### 2) 椭球偏心率

椭球偏心率公式为

$$e(\mathbf{E}_{\mathbf{Q}, \mathbf{c}}) = \frac{\sqrt{r_{\max}^2 - r_{\min}^2}}{r_{\min}} \quad (3)$$

式中:  $r_{\max}$  代表椭球最长轴半径;  $r_{\min}$  代表椭球最短轴半径。在系统正常稳定运行状态下, 发电机各类参数保持在正常水平范围内, 系统所承受压力保持均衡, 特征椭球呈球形, 偏心率较小。当系统发生故障时, 各台发电机数据信息产生较大波动, 各项数据严重失衡, 包含发电机参数的椭球形态亦随之

变化, 偏心率逐渐增大, 椭球偏离球形。综上, 若椭球在受扰动后偏心率减小, 系统将趋于稳定; 反之椭球的偏心率在系统受扰动后若呈增大趋势, 发电机参数将持续畸变, 系统趋于失控状态。

#### 3) 椭球体积变化率

椭球体积变化率公式为

$$V(t) = \frac{\Delta V}{\Delta t} \quad (4)$$

式中:  $\Delta V$  表示椭球体积的变化量;  $\Delta t$  表示经过的时间。椭球体积变化率代表系统受扰动后的运行状态。如果故障切除后的  $V(t) > 0$ , 表示特征椭球体积处于增加状态, 系统所承受的压力并未在切除故障后减小, 反而持续增加, 系统趋于失稳; 相反, 若故障切除后的  $V(t) < 0$ , 表示系统承受的压力逐渐减小, 系统向稳定状态发展。

#### 4) 椭球中心点

椭球中心点公式为

$$\mathbf{O}_i = \sum_{i=1}^m \alpha_i / m \quad (5)$$

式中,  $\mathbf{O}_i$  为椭球的中心点。系统正常运行时, 发电机各项数据保持稳定, 椭球位置趋于固定, 不会产生剧烈偏移; 受到扰动后, 随着 PMU 所连发电机信息的变化, 中心点会较稳定状态时产生偏移, 其位置也会大幅度变化。

利用上述所求椭球物理属性构建输入特征集, 如表 1 所示。通过 MVEE 理论构建的输入特征集反映了系统在暂态过程中的运行状况, 其对系统在故障发生、切除时刻以及切除后数个周波内的变化态势进行了有效描述, 对系统稳定状态具有一定的代表性。意味着可以通过该输入特征集训练出较为精准的分类器模型, 对系统状态进行暂态稳定评估。

表 1 通过 MVEE 理论构建的输入特征集

Table 1 Input feature set constructed by MVEE theory

编号	输入特征
$Tz_1$	故障初始时刻 $V(\mathbf{E}_{\mathbf{Q}, \mathbf{c}})$
$Tz_2$	故障切除时刻 $V(\mathbf{E}_{\mathbf{Q}, \mathbf{c}})$
$Tz_3$	故障切除 $n$ 周波后 $V(\mathbf{E}_{\mathbf{Q}, \mathbf{c}})$
$Tz_4$	故障初始时刻 $e(\mathbf{E}_{\mathbf{Q}, \mathbf{c}})$
$Tz_5$	故障切除时刻 $e(\mathbf{E}_{\mathbf{Q}, \mathbf{c}})$
$Tz_6$	故障切除 $n$ 周波后 $e(\mathbf{E}_{\mathbf{Q}, \mathbf{c}})$
$Tz_7$	故障初始时刻 $V(t)$
$Tz_8$	故障切除时刻 $V(t)$
$Tz_9$	故障切除 $n$ 周波后 $V(t)$
$Tz_{10}$	故障初始时刻 $\mathbf{O}_i$
$Tz_{11}$	故障切除时刻 $\mathbf{O}_i$
$Tz_{12}$	故障切除 $n$ 周波后 $\mathbf{O}_i$

## 2.2 基于 PTSVM 的暂态稳定评估

不同于传统 SVM 利用超平面对样本进行分类, PTSVM 则是通过最佳投影轴  $w_1$  和  $w_2$  对故障样本集进行分类, 完成二分类问题。假设待分类样本集为  $X=\{(x_1, +1), (x_2, +1), (x_3, +1), \dots, (x_{m_1}, +1), (x_{m_1+1}, -1), (x_{m_1+2}, -1), \dots, (x_{m_1+m_2}, -1)\}$ , 其中样本数量为  $m_1+m_2$ ,  $x_i$  表示第  $i$  个样本的输入特征, +1 或 -1 表示该特征量对应的样本状态。当该模型应用于电力系统暂态稳定评估时, +1 代表系统稳定, -1 代表系统失稳,  $x_i$  为通过 MVEE 理论构建的第  $i$  个故障样本特征。通过 PTSVM 可将样本集  $X$  识别区分为  $X_1=\{(x_1, +1), (x_2, +1), (x_3, +1), \dots, (x_{m_1}, +1)\}$  和  $X_2=\{(x_{m_1+1}, -1), \dots, (x_{m_1+m_2}, -1)\}$ , 即稳定故障样本与失稳故障样本。

相比于传统 SVM, PTSVM 通过递归算法生成多个投影轴并利用投影轴对样本进行分类, 使得该模型具有良好的泛化能力以及计算精度。但同时该模型也存在不可回避的缺点: 首先, 确定投影轴所用的内方差矩阵必须为满秩, 并且计算中包含对内方差矩阵求逆的过程, 当内方差矩阵规模较大时, 严重影响模型求解速度; 其次, PTSVM 是在原问题的对偶空间内进行求解, 一定程度上加大了计算复杂度, 降低了计算效率。在电网要求对故障进行快速评估的背景下, 该模型计算速度方面显然存在提升空间<sup>[23]</sup>。

## 2.3 最小二乘投影孪生支持向量机

鉴于 PTSVM 存在的缺陷, 对原分类器模型进行改进, 构建最小二乘投影孪生支持向量机 LSPTSVM, 以解决对大规模系统进行暂态稳定评估时计算效率低下的问题。该模型与 PTSVM 的中心思想保持一致, 即为每一类别故障样本确定最优投影轴, 使该类故障样本在投影轴上的投射点尽量集中。LSPTSVM 在 PTSVM 的基础上做出了以下改进。

1) 在原模型中添加正则项, 以保证内方差矩阵的正定性, 从而使矩阵达到满秩条件, 为模型带来更好的泛化能力, 以处理复杂电网故障样本, 增强评估稳定性;

2) 将松弛变量由 1 范数修改为 2 范数, 通过这一修改, 省略了原优化模型中松弛变量大于 0 的限制, 减少了约束条件, 提升了评估模型求解速度;

3) 将原模型中的不同类别故障样本距离大于 1 的不等式约束修改为等式约束, 这一改动使模型无需通过对偶空间进行求解, 即可在原空间内通过线性方程组对问题进行求解, 极大程度地降低了计算复杂度。

修改后的具体模型即 LSPTSVM, 如下所示。

$$\min_{w_1} \frac{1}{2} \sum_{i=1}^{m_1} \left( w_1^T x_i^{(1)} - w_1^T \frac{1}{m_1} \sum_{j=1}^{m_1} x_j^{(1)} \right)^2 + \frac{c_1}{2} \sum_{k=1}^{m_2} \xi_k^2 + \frac{c_3}{2} \|w_1\|^2 \quad (6)$$

$$\text{s.t. } w_1^T x_k^{(2)} - w_1^T \frac{1}{m_1} \sum_{j=1}^{m_1} x_j^{(1)} + \xi_k = 1, k=1, 2, L, m_2 \quad (7)$$

$$\min_{w_2} \frac{1}{2} \sum_{i=1}^{m_2} \left( w_2^T x_i^{(2)} - w_2^T \frac{1}{m_2} \sum_{j=1}^{m_2} x_j^{(2)} \right)^2 + \frac{c_2}{2} \sum_{k=1}^{m_1} \eta_k^2 + \frac{c_4}{2} \|w_2\|^2 \quad (8)$$

$$\text{s.t. } - \left( w_2^T x_k^{(1)} - w_2^T \frac{1}{m_2} \sum_{j=1}^{m_2} x_j^{(2)} \right) + \eta_k = 1, k=1, 2, L, m_1 \quad (9)$$

式中:  $c_1$ 、 $c_2$  为惩罚因数;  $c_3$ 、 $c_4$  为正则化系数;  $x$  为基于 MVEE 理论构建的系统输入特征。如式(6)一式(9)所示, LSPTSVM 模型的目标函数引入了正则化项  $1/2c_3\|w_1\|^2$  和  $1/2c_4\|w_2\|^2$ , 通过这一修改使内方差矩阵避免出现奇异现象, 弥补了原 PTSVM 模型中内方差矩阵需满秩的缺点, 同时降低了评估模型出现过拟合现象的概率, 有利于提高模型稳定性和抗干扰能力。修改后的模型可对更复杂多样的故障样本进行分类, 从而使分类器拥有更强的泛化能力, 以获得更高的评估精度; 其次, 将模型中的松弛变量由 1 范数  $\xi_k$  和  $\eta_k$  修改为 2 范数  $\xi_k^2$  和  $\eta_k^2$ , 省略了  $\xi_k^2, \eta_k^2 \geq 0$  的约束条件, 有助于提升故障类型评估速度; 最后, LSPTSVM 的约束条件由 PTSVM 中的不等式约束修改为等式约束, 该条件下无需利用二次规划对  $w_1$  和  $w_2$  进行求解, 只需在原空间内通过对线性方程组求解即可。

将表征故障样本离散程度的内方差矩阵  $S_1$ 、 $S_2$  引入 LSPTSVM 模型中, 并将故障样本集通过矩阵形式表达, 式(6)一式(9)即可表示为

$$\min_{w_1} \frac{1}{2} w_1^T S_1 w_1 + \frac{c_1}{2} \eta^T \eta + \frac{c_3}{2} \|w_1\|^2 \quad (10)$$

$$\text{s.t. } (B w_1 - \frac{1}{m_1} e_2 e_1^T A w_1) + \eta = e_2 \quad (11)$$

$$\min_{w_2} \frac{1}{2} w_2^T S_2 w_2 + \frac{c_2}{2} \xi^T \xi + \frac{c_4}{2} \|w_2\|^2 \quad (12)$$

$$\text{s.t. } -(A w_2 - \frac{1}{m_2} e_1 e_2^T B w_2) + \xi = e_1 \quad (13)$$

式中:  $A$  为稳定类故障样本矩阵;  $B$  为失稳类故障样本矩阵。将约束条件(11)、(13)代入目标函数, 即可将式(10)、式(12)转换为

$$\min_{w_1} \frac{1}{2} w_1^T s_1 w_1 + \frac{c_1}{2} \| -B w_1 + \frac{1}{m_1} e_2 e_1^T A w_1 + e_2 \|^2 + \frac{c_3}{2} \|w_1\|^2 \quad (14)$$

$$\min_{w_2} \frac{1}{2} w_2^T s_2 w_2 + \frac{c_2}{2} \| A w_2 - \frac{1}{m_2} e_1 e_2^T B w_2 + e_1 \|^2 + \frac{c_4}{2} \|w_2\|^2 \quad (15)$$

分别对式(14)、式(15)中的  $w_1$  和  $w_2$  进行求导,

并令导数为 0, 可得到

$$S_1 \mathbf{w}_1 + c_1 \left( -\mathbf{B} + \frac{1}{m_1} \mathbf{e}_2 \mathbf{e}_1^T \mathbf{A} \right)^T \left( -\mathbf{B} \mathbf{w}_1 + \frac{1}{m_1} \mathbf{e}_2 \mathbf{e}_1^T \mathbf{A} \mathbf{w}_1 + \mathbf{e}_2 \right) + c_3 \mathbf{w}_1 = 0 \quad (16)$$

$$S_2 \mathbf{w}_2 + c_2 \left( \mathbf{A} - \frac{1}{m_2} \mathbf{e}_1 \mathbf{e}_2^T \mathbf{B} \right)^T \left( \mathbf{A} \mathbf{w}_2 - \frac{1}{m_2} \mathbf{e}_1 \mathbf{e}_2^T \mathbf{B} \mathbf{w}_2 + \mathbf{e}_1 \right) + c_4 \mathbf{w}_2 = 0 \quad (17)$$

对式(16)、式(17)进行整理, 可得到投影轴  $\mathbf{w}_1$  和  $\mathbf{w}_2$  的表达式为

$$\mathbf{w}_1 = \left( \frac{S_1}{c_1} + \left( -\mathbf{B} + \frac{1}{m_1} \mathbf{e}_2 \mathbf{e}_1^T \mathbf{A} \right)^T \left( -\mathbf{B} + \frac{1}{m_1} \mathbf{e}_2 \mathbf{e}_1^T \mathbf{A} \right) + \frac{c_3}{c_1} \mathbf{I} \right)^{-1} \times \left( -\mathbf{B} + \frac{1}{m_1} \mathbf{e}_2 \mathbf{e}_1^T \mathbf{A} \right)^T \mathbf{e}_2 \quad (18)$$

$$\mathbf{w}_2 = - \left( \frac{S_2}{c_2} + \left( \mathbf{A} - \frac{1}{m_2} \mathbf{e}_1 \mathbf{e}_2^T \mathbf{B} \right)^T \left( \mathbf{A} - \frac{1}{m_2} \mathbf{e}_1 \mathbf{e}_2^T \mathbf{B} \right) + \frac{c_4}{c_2} \mathbf{I} \right)^{-1} \times \left( \mathbf{A} - \frac{1}{m_2} \mathbf{e}_1 \mathbf{e}_2^T \mathbf{B} \right)^T \mathbf{e}_1 \quad (19)$$

式中,  $\mathbf{I}$  为与故障样本集规模相关的单位矩阵。在由  $\mathbf{A}$  和  $\mathbf{B}$  确定最佳投影轴  $\mathbf{w}_1$  和  $\mathbf{w}_2$  后, LSPTSVM 模型的训练阶段即结束, 可通过该模型对新输入故障样本所对应的系统状态进行评估, 评估规则为

$$\text{label}(\mathbf{x}) = \arg \min_{i=1,2} \left| \mathbf{w}_i^T \mathbf{x} - \mathbf{w}_i^T \frac{1}{m_i} \sum_{j=1}^{m_i} \mathbf{x}_j^{(i)} \right| \quad (20)$$

当新故障样本  $\mathbf{x}$  输入时, 将该样本特征分别投射在  $\mathbf{w}_1$  和  $\mathbf{w}_2$  上, 根据  $\mathbf{x}$  在两条投影轴上的投影点与样本中心的投射点之间的距离判断新样本的类别, 即令式(20)中的  $i$  依次取值 1 和 2, 得到  $D_1$  和  $D_2$  分别为

$$D_1 = \mathbf{w}_1^T \mathbf{x} - \mathbf{w}_1^T \frac{1}{m_1} \sum_{j=1}^{m_1} \mathbf{x}_j^{(1)} \quad (21)$$

$$D_2 = \mathbf{w}_2^T \mathbf{x} - \mathbf{w}_2^T \frac{1}{m_2} \sum_{j=1}^{m_2} \mathbf{x}_j^{(2)} \quad (22)$$

当  $D_1 < D_2$ , 说明新样本  $\mathbf{x}$  距离  $\mathbf{w}_1$  投影轴更近, 为+1 类样本, 即系统恢复稳定; 当  $D_1 > D_2$ , 说明新样本  $\mathbf{x}$  距离  $\mathbf{w}_2$  投影轴更近, 为-1 类样本, 即系统持续失稳。

### 3 暂态稳定评估流程

本文通过 MVEE 理论构建输入特征集, 并利用 LSPTSVM 作为分类器模型对故障样本进行分类, 具体流程如图 1 所示。

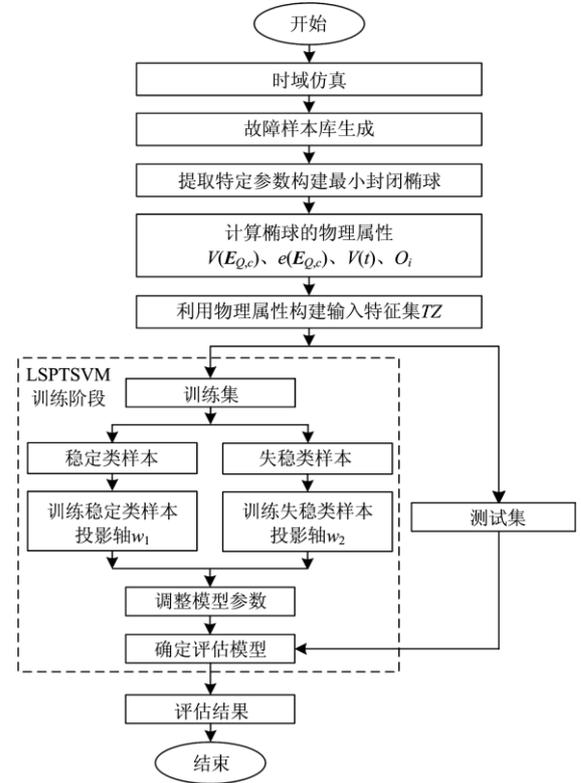


图 1 暂态稳定评估流程图

Fig. 1 Flow chart of transient stability assessment

首先通过时域仿真法模拟系统故障, 生成故障样本库, 并通过读取各发电机节点仿真数据模拟 PMU 量测过程。

其次将获取的发电机特定参数信息进行整合, 并利用 MVEE 理论构造关于系统特定参数信息的最小体积闭包椭球, 通过椭球的物理属性构建出能够反映系统状态的输入特征集。

将输入特征集随机分配为训练集与测试集, 通过训练集中的稳定样本和失稳样本训练 LSPTSVM, 确定两类故障样本的最优投影轴  $\mathbf{w}_1$  和  $\mathbf{w}_2$ , 完成分类器模型的构建。并将测试集对应的特征集输入至完成训练的 LSPTSVM 模型, 利用已确定的  $\mathbf{w}_1$  和  $\mathbf{w}_2$  对其稳定状态进行评估, 评估结果与时域仿真结果进行比对, 完成对已知模型的精度测试, 当精度满足工程要求时, 可利用该评估流程对系统其他故障样本进行暂态稳定评估, 保障系统安全运行。

### 4 算例分析

#### 4.1 IEEE-39 节点系统算例分析

利用电力系统仿真软件 PSD-BPA, 对 IEEE10 机 39 节点系统进行  $N-1$  三相短路故障时域仿真,

以模拟系统故障后各发电机节点 PMU 量测数据。在批量生成不同场景下故障样本的过程中, 首先使系统负荷水平和发电机出力在额定功率 80%~120% 的范围内等比例波动; 其次令三相短路故障分别发生在线路 2%、25%、50%、75%、98% 的位置; 故障切除时间设置为发生故障后的 0.1~0.4 s, 采样步长为 0.02 s, 构建包含 3 400 个样本的样本库。各故障样本通过暂态过程中各发电机功角、频率偏差等轨迹信息对系统的动态变化进行了完整描述, 并以任一时刻下系统内发电机最大功角差是否大于  $360^\circ$  作为判稳条件<sup>[11]</sup>。在获取包含系统完整轨迹信息的故障样本后, 通过 MVEE 理论将样本转换为输入特征集, 并根据其训练出完整的 LSPTSVM 分类器模型, 以参与后续暂态稳定评估。

### 1) 参数优化分析

分析 LSPTSVM 在不同模型参数下的评估准确率情况, 主要对模型中的惩罚因数  $c_1$ 、 $c_2$  以及正则化系数  $c_3$ 、 $c_4$  进行最优参数选择, 以构建更为精确的评估模型, 参数选择过程如图 2 所示。分别对模型系数  $c_1$  至  $c_4$  进行赋值, 对不同参数下的评估准确率进行记录, 选择最优参数组合, 构建精度最高的 LSPTSVM 模型。其中  $c_1$  取 0.4 时模型精度最高, 为 94.75%;  $c_2$  取 0.7 时模型精度最高, 为 94.25%;  $c_3$  取 0.1~0.2 或 0.3~0.5 时模型精度最高, 为 94.25%;  $c_4$  取 0.1~0.5 时模型精度最高, 为 94.5%。

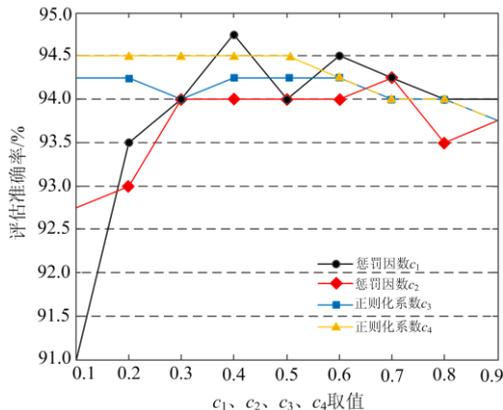


图 2 不同参数下评估准确率对比

Fig. 2 Comparison of accuracy under different parameters

通过对  $c_1$  至  $c_4$  的不同赋值, 确定最优参数组合, 以此组合为基础, 对 LSPTSVM 进行训练, 获得分类准确率最高的评估模型, 利用其对系统进行暂态稳定评估。

### 2) 评估准确率分析

在确定分类器模型内部参数后, 将 LSPTSVM 与其他传统分类器进行对比。对比分类器模型包括

SVM、PTSVM、最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)和人工神经网络(Artificial Neural Network, ANN), 时间窗口设置为 4~6 周波, 各分类器的评估准确率如表 2 所示。

表 2 LSPTSVM 与传统分类器评估准确率对比

Table 2 Comparison of LSPTSVM and traditional classifier

分类器模型	evaluation accuracy		
	准确率/% (4 周波)	准确率/% (5 周波)	准确率/% (6 周波)
LSPTSVM	95.00	95.25	95.75
SVM	93.99	94.49	94.89
PTSVM	91.75	92.25	92.50
LSSVM	94.49	94.49	94.49
ANN	95.00	95.50	95.75

从表 2 中可知, LSPTSVM 的分类准确率会随着读取信息的时间窗口的延长而提升, 并且在不同时间窗口下的分类准确率基本高于其他四种传统分类器。其中当各模型采用故障切除后 4 周波内信息构建输入特征集时, LSPTSVM 评估准确率可达 95%, 其他四种分类器评估准确率分别为 93.99%、91.75%、94.49% 以及 95%, LSPTSVM 与 ANN 相同且高于其他分类器; 读取故障切除后 5 周波内信息时, LSPTSVM 的评估准确率为 95.25%, 其他分类器评估准确率分别为 94.49%、92.25%、94.49% 以及 95.5%, LSPTSVM 除了略低于 ANN 外, 对系统状态的评估精度仍高于其余分类器; 当利用故障切除后 6 周波内系统数据进行评估时, LSPTSVM 评估准确率为 95.75%, 其他分类器评估准确率分别为 94.89%、92.50%、94.49% 以及 95.75%, LSPTSVM 除了与 LSSVM 评估精度相同以外, 对比其他分类器仍拥有精度方面的优势。

由以上分析可知, LSPTSVM 相比于其他传统分类器模型具有较高的评估精度, 在面对威胁系统正常运行的故障时, 能够进行准确判断, 为系统调控提供准确信息, 保障系统安全稳定运行。

### 3) 计算速度分析

利用 LSPTSVM 和其余四类分类器对样本进行评估, 时间窗口设置为 4~6 周波, 各种分类器的消耗时间如图 3 所示。

由图 3 可知, 在不同窗口长度下, LSPTSVM 的计算速率明显高于其他分类器, 其中时间窗口为 4 周波时, 四种传统分类器评估时间分别为 0.896 s、12.72 s、1.474 s 以及 7.883 s, 而 LSPTSVM 评估时间仅为 0.447 s; 当选取故障切除后 5 周波内数据构建输入特征集时, 其他分类器评估时间分别为 1.006 s、13.06 s、1.593 s 以及 8.271 s, LSPTSVM

评估时间为 0.464 s; 当选取故障切除后 6 周波内数据用于评估时, 对比分类器计算时间分别为 1.059 s、13.81 s、1.607 s 以及 8.89 s, LSPTSVM 计算时间为 0.482 s。

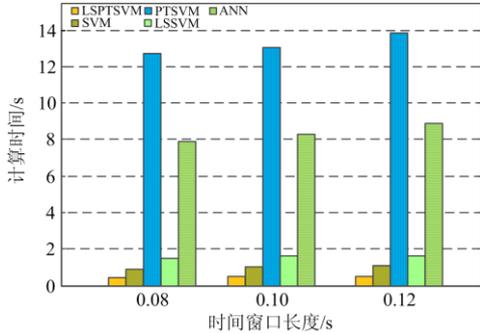


图 3 LSPTSVM 与传统分类器评估时间对比

Fig. 3 Comparison of LSPTSVM and traditional classifier evaluation time

通过 LSPTSVM 与各分类器对同一故障样本集进行评估所用时间的对比, 不难发现由于 LSPTSVM 模型在原始空间内对问题进行求解, 省略了不等式约束, 减轻了计算复杂程度, 使其能够快速对输入特征进行分析求解, 迅速评估故障类型。其计算时间远远少于分类器模型, 计算效率方面占有巨大优势, 并且该优势会随着模型所处理的数据规模增大而愈发明显。LSPTSVM 计算速度快这一特点能大幅度提升系统安全系数, 在系统遭受故障时可以迅速对故障类型进行判断, 第一时间识别出可能威胁系统正常运行的故障, 为后续保护动作及防控措施争取宝贵时间。

#### 4) 抗干扰能力分析

在原输入特征集的基础上, 对各特征量随机添加 5 次干扰, 干扰值分别取 0.001 和 0.01, 通过添加干扰的方式模拟实际评估过程中的系统噪声, 以此构建新的输入特征集, 并利用所获得的新特征集对 PTSVM 及 LSPTSVM 进行训练及测试, 结果如表 3 所示。

表 3 LSPTSVM 与 PTSVM 抗干扰能力对比

Table 3 Comparison of anti-interference ability between LSPTSVM and PTSVM

干扰程度	分类器模型	准确率/%	计算时间/s
0.001	LSPTSVM	92.50±0.08	0.485±1.73×10 <sup>-5</sup>
	PTSVM	89.55±0.82	11.949±0.019
0.01	LSPTSVM	91.65±0.05	0.512±4.85×10 <sup>-5</sup>
	PTSVM	88.80±7.29	12.181±0.050

由表 3 可知, 在干扰程度为 0.001 时, LSPTSVM 可保持 92.50% 的平均评估准确率, 而 PTSVM 仅为

89.55%, LSPTSVM 的评估准确率方差为 0.08, 而 PTSVM 的方差为 0.82; 同时 LSPTSVM 的平均计算时间为 0.485 s, 计算时间方差为 1.73×10<sup>-5</sup>, 远低于 PTSVM 的 11.949 s 和 0.019。同理, 当干扰程度为 0.01 时, LSPTSVM 的评估准确率、计算速度以及稳定程度仍优于 PTSVM。

上述现象表明, LSPTSVM 在 PTSVM 的基础上添加正则项的方式有效地降低了模型对特征量初值的要求, 且提升了模型稳定性, 降低了评估波动性, 使 LSPTSVM 在系统噪声下仍能提供高效精确且受干扰程度较低、可靠性较强的暂态稳定评估。

## 4.2 IEEE-145 节点系统算例分析

通过对 IEEE-145 系统进行算例分析, 进一步验证本文所提方法的有效性。首先对该系统在不同场景下的暂态过程进行时域仿真, 获取 6 432 个故障样本; 其次利用 MVEE 理论将全部故障样本转换为输入特征集。基于该输入特征集, 分别利用 LSPTSVM 与各类传统模型进行暂态稳定评估, 以验证本文方法面对较大规模系统时的可行性, 以及其在评估速度、准确率及稳定性方面的优势。

### 1) 评估速度及准确率分析

将输入特征集分别与各模型进行结合以完成暂态稳定评估, 各分类器的评估准确率及评估时间如表 4 所示。

表 4 LSPTSVM 与传统分类器评估情况对比

Table 4 Comparison of LSPTSVM and traditional classifier evaluation

分类器模型	准确率/%	计算时间/s
LSPTSVM	94.35	0.802
SVM	92.92	1.125
PTSVM	89.92	66.317
LSSVM	94.09	4.185
ANN	94.09	10.981

评估准确率方面, LSPTSVM 评估准确率为 94.35%, 而其余传统分类器的该项指标分别为 92.92%、89.92%、94.09% 以及 94.09%, 均低于 LSPTSVM 模型。通过该分析对比, 证明在面对高维度、大规模、计算复杂度较高的发电机轨迹信息时, LSPTSVM 能够有效去除样本噪声, 抓取样本信息中的主要影响因子, 以此训练并获取能够对故障样本进行合理二分类的投影轴模型, 并根据其决策函数对新故障下的系统稳定类型进行精准预测评估。验证了基于 LSPTSVM 模型的暂态稳定评估方法在解决较大规模电力系统评估问题时的有效性与可靠性。

评估速度方面, LSPTSVM 在 0.802 s 内完成模

型训练以及暂稳评估的工作, 相同工作量下, 其余分类器模型分别用时 1.125 s、66.317 s、4.185 s 以及 10.981 s, 所消耗时间均高于 LSPTSVM 模型。通过该对比可知, 在面对较大规模电力系统时, LSPTSVM 在原空间内利用线性方程组求解的计算方式使其拥有极快的评估速度, 此特性使其能够快于其他分类器模型, 先一步完成对系统稳定类型的评估, 提升系统安全性。

同时 LSPTSVM 在对同一系统的不同规模样本数据进行评估处理时, 其计算速度受样本规模的影响远远小于其他分类器模型。如表 5 所示, 在对三种不同规模故障样本进行评估时, LSPTSVM 依次用时 0.436 s、0.802 s 以及 1.172 s, 而 SVM 分别用时 0.533 s、1.125 s 以及 1.718 s, PTSVM 分别用时 14.295 s、66.317 s 以及 168.310 s, LSSVM 分别用时 1.398 s、4.185 s 以及 16.955 s, ANN 分别用时 7.297 s、10.981 s 以及 14.891 s。

表 5 不同规模故障样本下各分类器评估时间对比

Table 5 Comparison of evaluation time of each classifier under different scale fault samples

分类器模型	计算时间/s (3 216 样本)	计算时间/s (6 432 样本)	计算时间/s (9 648 样本)
LSPTSVM	0.436	0.802	1.172
SVM	0.533	1.125	1.718
PTSVM	14.295	66.317	168.310
LSSVM	1.398	4.185	16.955
ANN	7.297	10.981	14.891

根据对比可发现, 在样本数量由 3 216 增加至 9 648 的过程中, LSPTSVM 的耗时增量为 0.736 s, 而其他分类器模型耗时增量分别为 1.185 s、154.015 s、15.557 s、7.594 s, 均高于 LSPTSVM。由此可知, LSPTSVM 计算速度受数据规模的影响远远小于其余分类器模型, 其评估的系统规模越大、发电机数量越多、系统响应数据越复杂时, 其在计算速度方面的优势越显著。

## 2) 抗干扰能力分析

抵抗大系统噪声方面, 在原输入特征集基础上添加 0.001 及 0.01 的干扰量构建新特征集, 用于暂态稳定评估, 具体评估表现如表 6 所示。

从表 6 中可知, 在对大规模样本数据进行处理时, LSPTSVM 在 PTSVM 的基础上添加正则项的求解方式使其求解过程不易发生矩阵奇异现象, 带来更高的评估精度与稳定水平, 致使评估准确率与评估稳定性均优于原 PTSVM 模型。同时, 利用方程组直接求解的计算方式也使 LSPTSVM 的计算速度与计算稳定性远高于 PTSVM。由此可知, 在面

表 6 LSPTSVM 与 PTSVM 抗干扰能力对比

Table 6 Comparison of anti-interference ability between LSPTSVM and PTSVM

干扰程度	分类器模型	准确率/%	计算时间/s
0.001	LSPTSVM	90.94±0.11	1.221±5.90×10 <sup>-4</sup>
	PTSVM	90.20±0.14	185.510±288.13
0.01	LSPTSVM	90.67±0.26	1.240±7.57×10 <sup>-4</sup>
	PTSVM	89.68±0.67	194.010±258.90

对规模较大、系统结构较复杂的故障样本数据时, LSPTSVM 的抗噪表现仍优于原 PTSVM 模型, 可为系统带来稳定可靠的评估。

综上所述, 通过 IEEE-145 节点系统的算例分析, 验证了 LSPTSVM 在面对大规模系统时依然能够进行准确评估, 同时保持其评估速度快的优势, 为故障后的调控措施迅速提供可靠信息, 确保电力系统安全稳定运行。

## 5 总结

通过对 IEEE-39 节点系统和 IEEE-145 节点系统的仿真分析, 可知本文所提电力系统暂态稳定评估方法具有如下优势:

1) 利用 MVEE 理论将发电机信息转换为最小体积闭包椭球并以椭球的物理属性完成特征构建, 此举有效地降低了分类器模型原始输入空间维度, 通过小规模、低维度的输入特征集表征了大规模、高维度的原始电力系统数据, 避免了传统方法中信息冗余、特征量过多的缺点;

2) 通过 LSPTSVM 模型对电力系统故障样本进行分类评估, 可有效提高计算速度和泛化能力, 在保证评估准确率的前提下节约大量计算时间, 为故障后的调控解决措施争取宝贵时间。同时该模型受系统规模影响较小, 在面对大规模系统时仍能提供快速准确的评估, 有效保障系统安全。

## 参考文献

- [1] 梁志峰, 葛睿, 董昱, 等. 印度“7.30”、“7.31”大停电事故分析及对我国电网调度运行工作的启示[J]. 电网技术, 2013, 37(7): 1841-1848.  
LIANG Zhifeng, GE Rui, DONG Yu, et al. Analysis of large-scale blackout occurred on July 30 and July 31, 2012 in India and its lessons to China's Power Grid dispatch and operation[J]. Power System Technology, 2013, 37(7): 1841-1848.
- [2] 常康, 徐泰山, 郁琛, 等. 自然灾害下电网运行风险控制策略探讨[J]. 电力系统保护与控制, 2019, 47(10): 73-81.

- CHANG Kang, XU Taishan, YU Chen, et al. Discussion of power system operation risk control strategy in natural disasters[J]. Power System Protection and Control, 2019, 47(10): 73-81.
- [3] 辛建波, 王玉麟, 舒展, 等. 特高压交直流接入对江西电网暂态稳定的影响分析[J]. 电力系统保护与控制, 2019, 47(8): 71-79.
- XIN Jianbo, WANG Yulin, SHU Zhan, et al. Transient stability impact analysis of UHV AC/DC access to Jiangxi power grid[J]. Power System Protection and Control, 2019, 47(8): 71-79.
- [4] 陈振, 肖先勇, 李长松, 等. 基于代价敏感极端学习机的电力系统暂态稳定评估方法[J]. 电力自动化设备, 2016, 36(2): 118-123.
- CHEN Zhen, XIAO Xianyong, LI Changsong, et al. Power system transient stability assessment based on cost-sensitive extreme learning machine[J]. Electric Power Automation Equipment, 2016, 36(2): 118-123.
- [5] 管霖, 何楚瑶, 曾毅豪, 等. 基于模式匹配的智能稳定评估方法[J]. 电力自动化设备, 2016, 36(11): 107-119.
- GUAN Lin, HE Chuyao, ZENG Yihao, et al. Intelligent stability assessment based on pattern recognition[J]. Electric Power Automation Equipment, 2016, 36(11): 107-119.
- [6] 王亚俊, 王波, 唐飞, 等. 基于响应轨迹和核心向量机的电力系统在线暂态稳定评估[J]. 中国电机工程学报, 2014, 34(19): 3178-3186.
- WANG Yajun, WANG Bo, TANG Fei, et al. Power system online transient stability assessment based on response trajectory and core vector machine[J]. Proceedings of the CSEE, 2014, 34(19): 3178-3186.
- [7] 姜涛, 王长江, 陈厚合, 等. 基于正则化投影孪生支持向量机的电力系统暂态稳定评估[J]. 电力系统自动化, 2019, 43(1): 141-148.
- JIANG Tao, WANG Changjiang, CHEN Houhe, et al. Transient stability assessment of power system based on projection twin support vector machine with regularization[J]. Automation of Electric Power Systems, 2019, 43(1): 141-148.
- [8] 姚德全, 贾宏杰, 赵帅. 基于复合神经网络的电力系统暂态稳定评估和裕度预测[J]. 电力系统自动化, 2013, 37(20): 41-46.
- YAO Dequan, JIA Hongjie, ZHAO Shuai. Power system transient stability assessment and stability margin prediction based on compound neural network[J]. Automation of Electric Power Systems, 2013, 37(20): 41-46.
- [9] 邵雅宁, 唐飞, 刘涤尘, 等. 一种适用于 WAMS 量测数据的系统暂态功角稳定评估方法[J]. 电力系统保护与控制, 2015, 43(6): 33-39.
- SHAO Yaning, TANG Fei, LIU Dichen, et al. An approach of transient angle stability assessment in power system for WAMS measured data[J]. Power System Protection and Control, 2015, 43(6): 33-39.
- [10] 张玮灵, 胡伟, 闵勇, 等. 稳定域概念下考虑保守性的电力系统在线暂态稳定评估方法[J]. 电网技术, 2016, 40(4): 992-998.
- ZHANG Weiling, HU Wei, MIN Yong, et al. Conservative online transient stability assessment in power system based on concept of stability region[J]. Power System Technology, 2016, 40(4): 992-998.
- [11] 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.
- [12] 陈厚合, 王长江, 姜涛, 等. 基于投影能量函数和 Pin-SVM 的电力系统暂态稳定评估[J]. 电工技术学报, 2017, 32(11): 67-76.
- CHEN Houhe, WANG Changjiang, JIANG Tao, et al. Transient stability assessment in bulk power grid using projection energy function and support vector machine with pinball loss[J]. Transactions of China Electrotechnical Society, 2017, 32(11): 67-76.
- [13] 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.
- [14] 丁涛, 顾伟, 万秋兰. 基于 MVEE 理论和广域测量的扰动识别算法[J]. 电力系统自动化, 2013, 37(3): 38-42.
- DING Tao, GU Wei, WAN Qiulan. Disturbances identification based on minimum volume enclosing ellipsoid theory and wide area measurement system[J]. Automation of Electric Power Systems, 2013, 37(3): 38-42.
- [15] 杨跃, 刘俊勇, 黄媛, 等. 基于特征椭球和支持向量机复合映射的暂态稳定预测模型[J]. 电网技术, 2017, 41(8): 2514-2520.
- YANG Yue, LIU Junyong, HUANG Yuan, et al. A transient stability prediction model based on CELL-SVM composite projection[J]. Power System Technology, 2017, 41(8): 2514-2520.

- [16] 戴远航, 陈磊, 张玮灵, 等. 基于多支持向量机综合的电力系统暂态稳定评估[J]. 中国电机工程学报, 2016, 36(5): 1173-1180.  
DAI Yuanhang, CHEN Lei, ZHANG Weiling, et al. Power system transient stability assessment based on multi-support vector machines[J]. Proceedings of the CSEE, 2016, 36(5): 1173-1180.
- [17] HOU KY, SHAO G H, WANG H M, et al. Research on practical power system stability analysis algorithm based on modified SVM[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 119-125. DOI: 10.1186/s41601-018-0086-0.
- [18] 贾志成, 张智晟, 刘远龙, 等. 基于 RS-SVM 算法的配电网故障诊断方法[J]. 广东电力, 2019, 32(9): 107-114.  
JIA Zhicheng, ZHANG Zhisheng, LIU Yuanlong, et al. Fault diagnosis method based on RS-SVM algorithm for power distribution network[J]. Guangdong Electric Power, 2019, 32(9): 107-114.
- [19] 谢明磊. 基于 LSTM 网络的住宅负荷短期预测[J]. 广东电力, 2019, 32(6): 108-114.  
XIE Minglei. Short-term residence load forecast based on LSTM network[J]. Guangdong Electric Power, 2019, 32(6): 108-114.
- [20] 孔敏儒, 陈怡, 李文慧, 等. 基于粒子群优化 PCA-LSSVM 算法的高压断路器机械故障诊断研究[J]. 电网与清洁能源, 2019, 35(10): 68-74.  
KONG Minru, CHEN Yi, LI Wenhui, et al. Research on mechanical fault diagnosis of high voltage circuit breakers based on particle swarm optimization PCA-LSSVM[J]. Power System and Clean Energy, 2019, 35(10): 68-74.
- [21] MANGASARIAN OL, WILD E. Multisurface proximal support vector machine classification via generalized eigenvalues[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28 (1): 69-74.
- [22] JAYADEVA, KHEMCHANDAI R, CHANDRA S. Twin support vector machines for pattern classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(5): 905-910.
- [23] CHEN X B, YANG J, YE Q L, et al. Recursive projection twin support vector machine via within-class variance minimization[J]. Pattern Recognition, 2011, 44(10): 2643-2655.
- [24] FINE S, SCHEINBERG K. Efficient SVM training using low-rank kernel representation[J]. Journal of Machine Learning Research, 2001, 2: 243-264.
- [25] TAX D M J, DUIN R P W. Support vector domain description[J]. Pattern Recognition Letters, 1999, 20(14): 1191-1199.
- [26] BOUVILLE C. Bounding ellipsoid for ray-fractal intersection[J]. Computer Graph, 1985, 19: 45-52.
- [27] 张大波, 连帅, 陶维青, 等. 基于 PMU 的电网等值在互联电网运行可靠性评估中的应用[J]. 电力系统保护与控制, 2019, 47(15): 40-47.  
ZHANG Dabo, LIAN Shuai, TAO Weiqing, et al. Application of PMU-based grid equivalent model in operation reliability evaluation of interconnected power grid[J]. Power System Protection and Control, 2019, 47(15): 40-47.
- [28] KUMAR P, YILDIRIM, E A. Minimum volume enclosing ellipsoids and core sets[J]. Journal of Optimization Theory & Application, 2005, 126(1): 1-21.
- [29] KHACHIYAN L G, TODD M J. On the complexity of approximating the maximal inscribed ellipsoid for a polytope[J]. Math Program, 1993, 61: 137-159.
- [30] KHACHIYAN L G. Rounding of polytopes in the real number model of computation[J]. Mathematics of Operations Research, 1996, 21: 307-320.

收稿日期: 2019-10-12; 修回日期: 2019-11-19

作者简介:

王亮(1983—), 男, 高级工程师, 研究方向为电网运行检修及方式分析; E-mail: syauwl@163.com

韩冬(1992—), 男, 硕士研究生, 研究方向为电力系统暂态稳定评估; E-mail: handong1129@aliyun.com

王长江(1989—), 男, 通信作者, 博士研究生, 主要研究方向为柔性直流输电的控制和安全稳定性分析、电力系统暂态稳定。E-mail: cjwangneepu@163.com

(编辑 魏小丽)