

# 基于支持向量机综合分类模型和关键样本集的 电力系统暂态稳定评估

田芳, 周孝信, 于之虹

(电网安全与节能国家重点实验室(中国电力科学研究院), 北京 100192)

**摘要:** 为了提高支持向量机(Support Vector Machine, SVM)的分类性能, 提出了根据关键样本集构造的 SVM 综合分类模型进行电力系统暂态稳定评估的方法。给出了基于不同特征量的 SVM 综合分类模型的构建方法、关键样本集的产生方法以及基于综合分类模型和关键样本集的 SVM 分类步骤。采用 3 机 9 节点典型算例和某省级电网算例进行分类效果分析。分析结果表明, 所提出的基于 SVM 综合分类模型和关键样本集的方法, 相较于传统 SVM 方法, 大幅度减少了将不稳定样本判定为稳定的漏分类数, 提高了 SVM 方法的实用性。所提出的基于关键样本集构造分类模型的思路对于其他数据挖掘方法也有一定的借鉴意义。

**关键词:** 支持向量机; 综合分类模型; 关键样本集; 电力系统; 暂态稳定评估

## Power system transient stability assessment based on comprehensive SVM classification model and key sample set

TIAN Fang, ZHOU Xiaoxin, YU Zhihong

(State Key Laboratory of Power Grid Safety and Energy Conservation  
(China Electric Power Research Institute), Beijing 100192, China)

**Abstract:** A power system transient stability assessment method according to comprehensive Support Vector Machine (SVM) classification model based on key sample set is presented to improve the performance of SVM classification. A construction method of comprehensive SVM classification model based on different features, a producing method of key sample set, and procedures of SVM classification based on comprehensive classification model and key sample set are given. A 3-generator 9-node system and a certain provincial power grid are analyzed to verify the effectiveness of the method. Analysis results show that the presented method largely decreases the false classification number of unstable test samples compared with the traditional SVM method, thus improves the practicability of the method. The thought of using key sample set to form the classification model might be significative to other data mining methods.

This work is supported by Science and Technology Project of State Grid Corporation of China (No. 5442xt170016).

**Key words:** support vector machine; comprehensive classification model; key sample set; power system; transient stability assessment

## 0 引言

随着电网运行控制复杂度的增加, 在线动态安全评估(DSA)技术<sup>[1-7]</sup>已成为保证电网安全的不可缺少的主要技术手段。DSA 系统一般包括暂态稳定评估、电压稳定评估、小干扰稳定评估等功能。其中, 基于时域仿真的暂态稳定评估是最耗时的一种计算。

随着我国电网规模的不断扩大以及直流输电工程的纷纷投运, 给 DSA 系统带来了挑战。一方面, 仿真计算时间会随着电网规模的增长而成倍增加; 另一方面传统的机电暂态仿真在分析交流故障引发直流换相失败等问题时往往捉襟见肘, DSA 系统迫切需要引入电磁-机电暂态混合仿真以提高安全评估的准确度, 这样计算时间将成千上万倍增长。解决上述问题的一个思路是扩充硬件资源, 提高并行计算效率, 另一个思路是将快速判稳的数据挖掘

技术与数值计算方法相结合,以提高暂态稳定评估的计算速度。

数据挖掘包括机器学习、专家系统、模式识别等多种方法。支持向量机 SVM 是基于统计学理论的 VC 维(Vapnik-Chervonenkis dimension)理论和结构风险最小化原则而提出的一种新的机器学习方法,在电力系统负荷预测<sup>[8-10]</sup>、新能源发电功率预测<sup>[11-12]</sup>、故障类型识别<sup>[13]</sup>等领域都有应用。在电力系统暂态稳定评估<sup>[14-17]</sup>方面也已开展较多研究。近几年的发展包括:对 SVM 的改进方法研究,如最小二乘 SVM<sup>[18-19]</sup>,相关 SVM<sup>[20]</sup>,主要用来提高计算速度;选择合适的输入特征<sup>[21]</sup>,或将 SVM 和其他方法相结合,如与证据理论相结合<sup>[18]</sup>,以提高分类准确性;对不同参数训练的 SVM 进行综合,减少漏判数<sup>[22]</sup>。

本文提出了一种提高 SVM 分类性能的新思路:基于关键样本集来构建若干个具有不同特征量的 SVM 分类模型,对其分类结果进行综合。本文将首先简单介绍 SVM 的基本原理,然后描述 SVM 综合分类模型的构建方法和关键样本集的产生方法,接下来介绍基于综合分类模型和关键样本集的 SVM 分类步骤,最后采用 3 机 9 节点典型算例和某省级电网算例进行分类效果验证。

## 1 支持向量机简介

支持向量机是 Cortes 和 Vapnik 于 1995 年首先提出的<sup>[23]</sup>,是一种建立在统计学习理论基础上的新型机器学习方法,遵循结构风险最小化原则。它在解决小样本、非线性及高维模式识别中表现出许多特有的优势。支持向量机分类方法的主要思想是针对两分类问题,在高维空间中寻找一个超平面作为两类的分割面,且使分类间隔最大。

支持向量机分类问题可描述为:给定训练集  $S = \{(\mathbf{x}_i, y_i) | \mathbf{x}_i \in \mathbf{R}^n, y_i \in \mathbf{R}\}_{i=1}^l$ , 求解最优分类超平面。其中  $\mathbf{x}_i$  为第  $i$  个描述系统状态的输入特征向量,  $y_i$  为第  $i$  个样本的分类标识,  $y_i \in \{-1, 1\}$ ,  $l$  为样本数。在训练集线性可分的情况下,通过求解下述最优化问题,确定最优分类函数  $f(\mathbf{x}) = \text{sgn}[(\mathbf{w} \cdot \mathbf{x}) + b]$ 。

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

式中:  $\mathbf{w}$  和  $b$  分别为系数向量和偏差项;  $C$  为惩罚因子;  $\xi_i$  为松弛变量。

构造拉格朗日函数如下:

$$\begin{aligned} L(\mathbf{w}, b, \xi, \boldsymbol{\alpha}, \boldsymbol{\gamma}) = & \frac{1}{2} (\mathbf{w} \cdot \mathbf{w}) + C \sum_{i=1}^l \xi_i - \\ & \sum_{i=1}^l \alpha_i \{y_i [(\mathbf{w} \cdot \mathbf{x}_i) + b] - 1 + \xi_i\} - \sum_{i=1}^l \gamma_i \xi_i \end{aligned} \quad (2)$$

式中,  $\alpha_i$ 、 $\gamma_i$  都是拉格朗日乘子。可转化为对其对偶问题的求解,即

$$\begin{aligned} \max \quad & \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^l y_i y_j \alpha_i \alpha_j (\mathbf{x}_i \cdot \mathbf{x}_j) \\ \text{s.t.} \quad & 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, l \\ & \sum_{i=1}^l \alpha_i y_i = 0 \end{aligned} \quad (3)$$

这是一个不等式约束下二次函数寻优的问题。解中只有一部分  $\alpha_i$  不为 0, 对应的样本就是支持向量。

在求得  $\alpha_i$  后,  $b$  可由  $-\frac{\max_{i, y_i = -1} (\mathbf{w} \cdot \mathbf{x}_i) + \min_{i, y_i = 1} (\mathbf{w} \cdot \mathbf{x}_i)}{2}$

得到。从而得到最优分类函数

$$\begin{aligned} f(\mathbf{x}) = & \text{sgn}[(\mathbf{w} \cdot \mathbf{x}) + b] = \\ & \text{sgn} \left[ \sum_{i=1}^l \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{x}) + b \right] \end{aligned} \quad (4)$$

当训练集中的数据线性不可分时,可通过非线性映射  $\Phi: \mathbf{R}^n \rightarrow \mathbf{H}$  将其映射到高维空间,使其在高维空间成为线性可分的。由于在高维空间的训练算法只需要进行内积运算  $\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$ , 当有函数满足  $K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$  时,高维空间的内积计算可通过原空间的函数来实现。这样的函数被称为核函数。核函数的基本作用就是接受两个低维空间里的向量为输入,能够计算出经过某个变换后在高维空间里的向量内积。

常用的核函数主要有

(1) 线性核函数

$$K(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y}) \quad (5)$$

(2) 多项式核函数

$$K(\mathbf{x}, \mathbf{y}) = [b(\mathbf{x} \cdot \mathbf{y}) + c]^d \quad (6)$$

式中,  $b, c, d$  均为常数。

(3) 径向基核函数

$$K(\mathbf{x}, \mathbf{y}) = \exp \left[ -\frac{\|\mathbf{x} - \mathbf{y}\|^2}{\sigma} \right] \quad (7)$$

式中,  $\sigma$  为样本输入特征个数与径向基核函数宽度的乘积,为常数。

(4) Sigmoid 核函数

$$K(\mathbf{x}, \mathbf{y}) = \tanh[\mathbf{b}(\mathbf{x} \cdot \mathbf{y}) + \mathbf{c}] \quad (8)$$

式中:  $\mathbf{b}, \mathbf{c}$  均为常数。

引入核函数后, 式(3)和式(4)分别为

$$\begin{aligned} \max \quad & \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^l y_i y_j \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s.t.} \quad & 0 \leq \alpha_i \leq C, \quad i=1, 2, \dots, l \\ & \sum_{i=1}^l \alpha_i y_i = 0 \end{aligned} \quad (9)$$

$$f(\mathbf{x}) = \text{sgn} \left[ \sum_{i=1}^l \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + \mathbf{b} \right] \quad (10)$$

具体选择哪种类型的核函数以及核函数中参数如何选择, 目前还缺乏具体的操作原则。只能在应用过程中采用试验法。即试验不同的核函数和不同的参数组合, 根据测试结果选取其中效果较好的一种。一般来说, 径向基核函数是不会出太大偏差的一种核函数。

## 2 SVM 综合分类模型

特征量的选择对 SVM 分类效果至关重要。在特征量较多时, 有时会掩盖主要特征, 导致分类的效果不理想; 特征量较少时, 又可能无法全面表征系统状态, 分类效果也不理想。为此, 有学者研究采用遗传算法、模拟退火、主成分分析等方法进行特征量选择和特征提取<sup>[24-25]</sup>。采用遗传算法等智能优化算法进行特征量的选择存在计算速度慢、难以适应大电网等不足; 主成分分析法可在不损失原始数据主要信息、不影响评估效果的前提下, 用少量有代表性的综合特征代替原有的输入特征, 显著降低了输入空间维度, 但失去了特征量的原始物理意义。

本文受文献[22]采用多个不同参数的分类器进行结果综合思想的启发, 构造多个具有不同特征量的 SVM 分类模型, 按照保守性原则, 对多个分类模型的分类结果进行综合, 规避了特征量选择的问题。所谓保守性原则即最大限度地减少漏分类(将不稳定样本判定为稳定)的样本数。为此, 对多个 SVM 分类模型的分类结果进行综合的方式为: 对于某一测试样本, 有 1 个分类模型判定为不稳定, 则归于不稳定分类中; 只有当所有的分类模型都判定为稳定时, 才归于稳定分类中。这样可以降低漏分类数, 其代价是提高了误分类(将稳定样本判定为不稳定)数。这样做的原因在于进行稳定评估时, 对漏分类的容忍度更低, 因漏分类对电力系统安全稳定性的影响要大得多。

图 1 给出了 SVM 综合分类模型的简单示意图。

图 1 中各 SVM 分类模型所选取的特征量可以各不相同, 也可以允许有部分交叉重叠。

在应用于在线暂态稳定评估时, 为了便于对预想故障失稳情况进行预防控制, 常以系统故障前的潮流量(节点功率、线路潮流等)作为输入特征量。此时特征量相对较少, 为了保证结果综合前单一的 SVM 分类模型具备良好的分类性能, 故采用后一方式。

具体特征量如何选择呢? 电网运行中离线确定输电断面的功率传输极限、在线监控断面功率的做法给了我们启迪。

离线确定输电断面功率极限时, 一般选取几种典型的运行工况, 针对某一特定的发电、负荷变化方式, 计算若干个关键输电断面的功率极限。在运行时, 实时监控这些关键输电断面的输送功率, 越限时由调度员采取手动调整措施。这说明运行工况和关键输电断面的输送功率是稳定判别的关键特征量。

由于发电、负荷的分布能直观地体现运行工况的差异性, 且线路较输电断面易识别, 本文选取发电、负荷作为综合分类模型中的重叠特征量, 选取重点关注线路的功率作为非重叠特征量。

对应于图 1, 第  $i(i=1, 2, \dots, m)$  个 SVM 分类模型的特征量选择如下: 第  $i$  条重点关注线路的传输功率、发电机出力、节点负荷。 $m$  为重点关注线路数量。

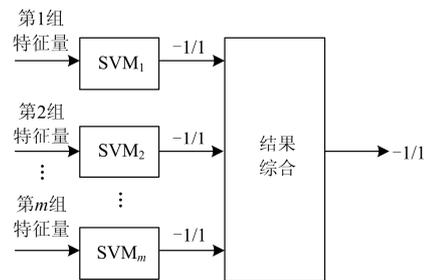


图 1 SVM 综合分类模型示意图

Fig. 1 Schematic diagram of the comprehensive SVM classification model

## 3 关键样本集的产生

### 3.1 样本集的构造

在采用 SVM 方法进行暂态稳定评估时, 样本集的构造是第一步的工作。一般是通过离线仿真计算, 针对特定网络进行大量运行方式下的各种故障仿真, 以得到样本集。也可以通过在线安全评估系统, 收集过去一段时间内的历史数据作为样本集。但在线安全评估系统收集到的历史数据, 其运行方

式的覆盖性并不全面,往往还需要大量的离线仿真计算作补充。样本集得到后,随机抽取其中一部分作为训练样本,另一部分作为测试样本。

为了使样本的分布范围尽可能广,一般采用如下的方式来产生运行方式:在初始潮流方式基础上,使负荷水平逐步增长。对每个负荷水平,设置不同的负荷增长方式和发电出力。

### 3.2 关键样本集

采用上述方式构造出来的样本非常复杂,训练出来的模型分类效果往往不尽如人意。如何将样本简化,同时提升分类效果呢?

在实际电网分析中,我们发现,对于不同的发电、负荷变化方式,同一输电断面的功率传输极限是不同的。对于测试样本,只要知道了其发电、负荷变化方式,以及输电断面实际传输功率和相应的功率传输极限,可以很容易地判别是否稳定。

这里,我们将具有与测试样本类似的发电、负荷变化方式的样本称为关键样本。所有关键样本组成的样本集为关键样本集。

这样,我们就可以根据关键样本集而不是全部样本来构造稳定分类模型。

那么如何确定对应某一测试样本的关键样本集呢?

首先,我们在获得所有的训练样本集后,根据不同的发电、负荷变化方式,对原始样本集进行分类,这样将形成若干个子样本集。

然后,对应某一测试样本,通过计算其与训练样本空间中所有样本的距离,找到与其距离最小的那个样本,该样本所属的子样本集,即为对应于该测试样本的关键样本集。2个样本间距离的计算公式如下:

$$D(\mathbf{x}_i, \mathbf{x}_j) = \|\mathbf{x}_i - \mathbf{x}_j\| \quad (11)$$

## 4 基于综合分类模型和关键样本集的 SVM 分类步骤

针对暂态稳定评估问题,基于综合分类模型和关键样本集,采用 SVM 方法进行分类的步骤如下:

- (1) 构造原始训练样本集和测试样本集。
- (2) 根据不同的发电、负荷变化方式,对原始训练样本集进行分类,形成  $N$  个子样本集。
- (3) 对  $N$  个子样本集,针对每个故障,选取  $m$  组特征量,采用 SVM 方法进行训练,得到  $N \times M \times m$  个分类模型,  $M$  为故障数。
- (4) 对测试样本集中的每个测试样本,找到其关键样本集  $I$ ,之后采用样本集  $I$  及相应故障对应的  $m$

个分类模型进行分类,得到  $m$  个分类结果,对分类结果进行综合,得到最终的分类结果。

## 5 算例分析

### 5.1 3机9节点典型算例

#### 5.1.1 样本生成

对3机9节点典型算例进行分析。系统接线图如图2所示。联络线2和5将该系统分为区域1和区域2。

构造了2个样本集。样本集1的构造过程如下:在初始潮流方式基础上,通过调节发电、负荷,在75%~150%(以5%为变化步长)基准负荷下,对每个负荷水平设置3种不同的负荷增长方式(区域1、2负荷同比增长;仅增长区域1负荷;仅增长区域2负荷)、对每种负荷增长方式各设置6种不同的发电出力。其中,基准负荷下只设置6种不同的发电出力。共得到276个潮流方式。每个潮流方式,对该系统的6条线路依次作  $N-1$  暂稳校验。故障类型为线路两侧三相永久性短路故障,故障发生后0.1s故障切除。合计得到3312(276×12)个运行样本。

样本集2的构造过程如下:在初始潮流方式基础上,通过调节发电、负荷,分别使线路1-线路6上的功率增长(功率增长的步长约0.1 p.u.),直到系统不稳定或潮流不收敛。共得到117个潮流方式。 $N-1$  暂稳校验时故障线路和故障类型同样本集1。合计得到1404(117×12)个运行样本。

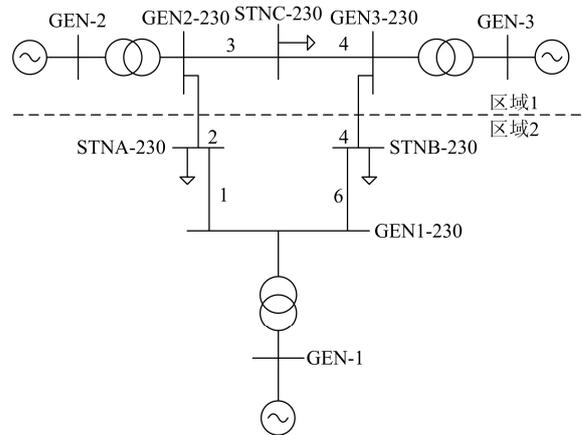


图2 3机9节点系统接线图

Fig. 2 Single line diagram of the 3-generator 9-node system

#### 5.1.2 特征量选择

综合分类模型的特征量选择已在第2节中给出。用于对比研究时,选取如表1所示的部分运行数据及其统计值作为全部输入特征量。表1特征量的选择参考了文献[26-27]。

表 1 特征量  
Table 1 Features

| 序号 | 特征量     |
|----|---------|
| 1  | 系统总发电出力 |
| 2  | 系统总负荷   |
| 3  | 线路传输功率  |
| 4  | 发电机出力   |
| 5  | 节点负荷    |

### 5.1.3 传统 SVM 方法分析结果

采用 LIBSVM3.2<sup>[28]</sup>作为训练和测试工具。采用径向基函数作为核函数,构造 SVM 分类模型,惩罚系数  $C=100$ 。以样本集 1 作为训练样本集,样本集 2 作为测试样本集。传统 SVM 方法的分类结果如下:在 1404 个测试样本中,漏分类个数为 6,占测试总数的 0.43%;误分类个数为 356,占测试总数的 25.4%。

### 5.1.4 本文方法分析结果

以样本集 1 作为训练样本集,样本集 2 作为测试样本集。根据发电、负荷增长形式的不同,将样本集 1 划分为 18 个子样本集。对每个子样本集,针对每个故障,选取 6 组特征量,采用径向基函数作为核函数,构造 SVM 分类模型,惩罚系数  $C=100$ 。这样,共得到  $18 \times 12 \times 6$  个分类模型。6 组特征量分别包含图中 6 条线路功率。

对于测试样本集中的每个样本,首先找到其归属的关键样本集,然后根据该关键样本集和相应故障对应的 6 个 SVM 分类模型对其进行分类,再对分类结果进行综合。

表 2 给出了本文方法和传统 SVM 方法的分类效果比较,表中还给出了仅采用关键样本集方法时的分类效果。

表 2 分类效果比较

Table 2 Comparison of classification effect

| 方法                     | 漏分类 | 误分类 | 分类    |
|------------------------|-----|-----|-------|
|                        | 样本数 | 样本数 | 正确率   |
| 传统 SVM(全部特征量)          | 6   | 356 | 74.2% |
| 关键样本集 SVM<br>(全部特征量)   | 8   | 2   | 99.3% |
| 本文方法(综合分类<br>模型+关键样本集) | 6   | 6   | 99.1% |

从表 2 可见,相对于传统 SVM 方法,关键样本集 SVM 方法(全部特征量),误分类数大幅度减少,分类正确率大幅度提高;基于 SVM 综合分类模型和关键样本集的方法,进一步减少了漏分类数,其代价是牺牲了误分类率。

## 5.2 某省级电网算例

### 5.2.1 样本生成

以某省级电网系统作为分析对象。其 500 kV 主网接线图如图 3 所示。该系统共分为 3 个区域:西部、中部和东部,包含图中所示的 17 个分区,其中西部区域包括分区 1、8、9、17;东部区域包括分区 4、12、14、15、16;其余分区属于中部区域。系统规模如下:母线 2036 条,发电机 149 台,交流线 761 条,直流线 1 条。

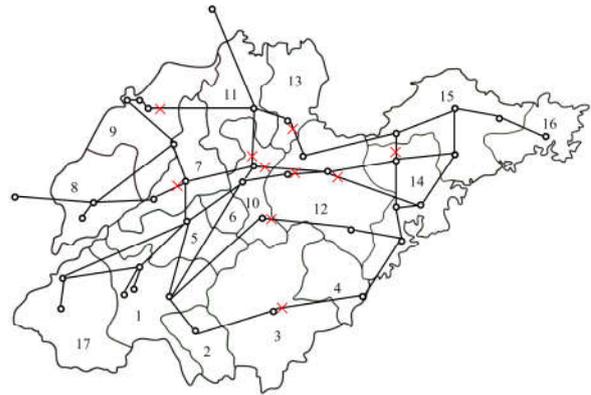


图 3 某省级电网 500 kV 主网接线图

Fig. 3 Wiring diagram for 500 kV main network of the certain provincial power grid

构造了 2 个样本集。样本集 1 的构造过程如下:在初始潮流方式基础上,通过调节发电、负荷,在 75%~120%(以 1%为变化步长)基准负荷下,对每个负荷条件设置 7 种不同的负荷增长方式(按区域考虑负荷的增长,即仅东部增长、仅中部增长、仅西部增长、中西部同比增长、东西部同比增长、中东部同比增长、平均增长),对每种负荷增长方式各设置 7 种不同的发电出力(按区域考虑发电的调节,即仅东部调节、仅中部调节、仅西部调节、中西部同时调节、东西部同时调节、中东部同时调节、中西东部同时调节)。共得到 2024 个潮流方式。每个潮流方式,选取了该系统的 10 条 500 kV 线路(在图中标出,线路编号分别为 602002、600383、600218、600098、602305、600522、602591、600716、600695、600626)依次作  $N-1$  暂稳校验。故障类型为线路首端三相永久性短路故障,故障发生后 0.3 s 或 0.4 s 故障切除(由于系统网架较强,采用实际故障切除时间系统均保持稳定,为便于进行算法验证,人为加大了故障切除时间)。合计得到 20240(2024×10)个运行样本。

样本集 2 的构造过程如下:在初始潮流方式基础上,通过调节发电、负荷,分别使 10 条 500 kV

线路(线路编号同前)上的功率变化。调节灵敏度较大的若干台发电机出力,调节幅度为 75%~140%,调节负荷功率增减与发电机功率增减相匹配。共得到 124 个潮流方式。 $N-1$  暂稳校验时故障线路和故障类型同样本集 1。合计得到 1240(124×10)个运行样本。

在进行暂稳仿真时,发电机采用考虑  $E_q''$ ,  $E_d''$ ,  $E_q'$  电势变化的 5 阶模型,考虑了励磁和调速器模型,部分发电机还考虑了 PSS(电力系统稳定器)。采用电力系统分析综合程序(PSASP)进行仿真。

### 5.2.2 传统 SVM 方法分析结果

采用 LIBSVM3.2 作为训练和测试工具。采用径向基函数作为核函数,构造 SVM 分类模型,惩罚系数  $C=100$ 。以样本集 1 作为训练样本集,样本集 2 作为测试样本集。传统 SVM 方法的分类结果如下:在 1240 个测试样本中,漏分类个数为 103,占测试总数的 8.3%;误分类个数为 24,占测试总数的 1.9%。

### 5.2.3 本文方法分析结果

以样本集 1 作为训练样本集,样本集 2 作为测试样本集。

训练时,根据发电、负荷增长形式的不同,将样本集 1 划分为 49 个子样本集。对每个子样本集,针对每个故障,选取 10 组特征量,采用径向基函数作为核函数,构造 SVM 分类模型,惩罚系数  $C=100$ 。这样,共得到  $49 \times 10 \times 10$  个分类模型。10 组特征量分别包含图中标出的 10 条线路功率。

测试时,需根据与测试样本对应的关键样本集和相应故障,对对应的 10 个具有不同特征量的 SVM 分类模型的分类结果进行综合。

表 3 给出了本文方法和传统 SVM 方法的分类效果比较。从表 3 可见,本文所提出的基于 SVM 综合分类模型和关键样本集的方法分类效果较好,对于 1240 个测试样本,存在 44 个漏分类,42 个误分类。与传统 SVM 方法相比,不仅分类正确率从 89.6 增加到 93.1%,且漏分类数大大减少,符合保守性原则。上述结果验证了该方法在较大规模电网中应用的有效性。

表 3 分类效果比较

Table 3 Comparison of classification effect

| 方法            | 漏分类<br>样本数 | 误分类<br>样本数 | 分类<br>正确率 |
|---------------|------------|------------|-----------|
| 传统 SVM(全部特征量) | 103        | 24         | 89.6%     |
| 本文方法          | 44         | 42         | 93.1%     |

## 6 结论

本文提出基于 SVM 综合分类模型和关键样本集的电力系统暂态稳定评估方法,对传统 SVM 分类方法进行了改进,3 机 9 节点典型算例和某省级电网算例分析结果表明:

1) 特征量的选取对于关键样本集 SVM 分类结果有较大影响。为降低漏分类率,采用基于不同特征量构造的若干个分类模型的综合结果进行分类的思路是可行的。

2) 基于 SVM 综合分类模型和关键样本集的暂态稳定评估方法在某省级电网中的分类效果较好,相对于传统 SVM 方法,分类正确率有所增加,漏分类数大幅减少,提高了 SVM 方法用于稳定评估时的实用性。

如何合理选取特征量,进一步提升分类正确率值得进一步深入研究。所提出的基于关键样本集构造分类模型的思路对于其他数据挖掘方法也有一定的借鉴意义。

## 参考文献

- [1] TADA Y, CHIANG H D. Design and implementation of online dynamic security assessment[J]. IEEJ Transactions on Electrical and Electronic Engineering, 2009, 4(3): 313-321.
- [2] TIRADO C, ROMO S. Online security assessment in Mexican power systems[C] // CIGRE 2014. Paris, France, August 24-29, 2014.
- [3] WANG Lei, TONG Jianzhong, LI Haoen. An application example for on-line DSA systems[C] // IEEE International Conference on Power System Technology, Auckland, New Zealand, October 30-November 2, 2012: 1-5.
- [4] 严剑峰, 于之虹, 田芳, 等. 电力系统在线动态安全评估和预警系统[J]. 中国电机工程学报, 2008, 28(34): 87-93.  
YAN Jianfeng, YU Zhihong, TIAN Fang, et al. Dynamic security assessment & early warning system of power system[J]. Proceedings of the CSEE, 2008, 28(34): 87-93.
- [5] NETO C A S, QUADROS M A, SANTOS M G, et al. Brazilian system operator online security assessment system[C] // IEEE Power and Energy Society General Meeting, Minneapolis, MN, USA, July 25-29, 2010: 1-7.
- [6] DUDURYCH I M, ROGERS A, AHERNE R, et al. Safety in numbers: online security analysis of power grids with high wind penetration[J]. IEEE Power and

- Energy Magazine, 2012, 10(2): 62-70.
- [7] 李建, 庞晓艳, 李曼, 等. 省级电网在线安全稳定预警及决策支持系统研究与应用[J]. 电力系统自动化, 2008, 32(22): 97-102.  
LI Jian, PANG Xiaoyan, LI Man, et al. Research and application of online security pre-warning and decision making support system for provincial power grid[J]. Automation of Electric Power Systems, 2008, 32(22): 97-102.
- [8] 李瑾, 刘金朋, 王建军. 采用支持向量机和模拟退火算法的中长期负荷预测方法[J]. 中国电机工程学报, 2011, 31(16): 63-66.  
LI Jin, LIU Jinpeng, WANG Jianjun. Mid-long term load forecasting based on simulated annealing and SVM algorithm[J]. Proceedings of the CSEE, 2011, 31(16): 63-66.
- [9] 陈超, 黄国勇, 范玉刚, 等. 基于离散 Frechet 距离和 LS-SVM 的短期负荷预测[J]. 电力系统保护与控制, 2014, 42(5): 142-147.  
CHEN Chao, HUANG Guoyong, FAN Yugang, et al. Short-term load forecasting based on discrete Frechet distance and LS-SVM[J]. Power System Protection and Control, 2014, 42(5): 142-147.
- [10] 王宁, 谢敏, 邓佳梁, 等. 基于支持向量机回归组合模型的中长期降温负荷预测[J]. 电力系统保护与控制, 2016, 44(3): 92-97.  
WANG Ning, XIE Min, DENG Jialiang, et al. Mid-long term temperature-lowering load forecasting based on combination of support vector machine and multiple regression[J]. Power System Protection and Control, 2016, 44(3): 92-97.
- [11] 李霄, 王昕, 郑益慧, 等. 基于改进最小二乘支持向量机和预测误差校正的短期风电负荷预测[J]. 电力系统保护与控制, 2015, 43(11): 63-69.  
LI Xiao, WANG Xin, ZHENG Yihui, et al. Short-term wind load forecasting based on improved LSSVM and error forecasting correction[J]. Power System Protection and Control, 2015, 43(11): 63-69.
- [12] 高相铭, 杨世凤, 潘三博. 基于 EMD 和 ABC-SVM 的光伏并网系统输出功率预测研究[J]. 电力系统保护与控制, 2015, 43(21): 86-92.  
GAO Xiangming, YANG Shifeng, PAN Sanbo. A forecasting model for output power of grid-connected photovoltaic generation system based on EMD and ABC-SVM[J]. Power System Protection and Control, 2015, 43(21): 86-92.
- [13] 祝志慧, 孙云莲. 基于 EMD 近似熵和 SVM 的电力线路故障类型识别[J]. 电力自动化设备, 2008, 28(7): 81-84.  
ZHU Zhihui, SUN Yunlian. Fault classification for power transmission line using EMD-approximate entropy and SVM[J]. Electric Power Automation Equipment, 2008, 28(7): 81-84.
- [14] KALYANI S, SWARUP K S. Binary SVM approach for security assessment and classification in power systems[C] // Annual IEEE India Conference, Ahmedabad, India, December 18-20, 2009: 1-4.
- [15] RAJAPAKSE A D, GOMEZ F, NANAYAKKARA O M K K, et al. Rotor angle instability prediction using post disturbance voltage trajectories[J]. IEEE Transactions on Power Systems, 2010, 25(2): 947-956.
- [16] 刘艳芳, 顾雪平. 基于支持向量机的电力系统暂态稳定分类研究[J]. 华北电力大学学报, 2004, 31(3): 26-29, 55.  
LIU Yanfang, GU Xueping. Transient stability assessment of power systems based on support vector[J]. Journal of North China Electric Power University, 2004, 31(3): 26-29, 55.
- [17] 许涛, 贺仁睦, 王鹏, 等. 基于统计学习理论的电力系统暂态稳定评估[J]. 中国电机工程学报, 2003, 23(11): 51-55.  
XU Tao, HE Renmu, WANG Peng, et al. Power system transient stability assessment based on statistical learning theory[J]. Proceedings of the CSEE, 2003, 23(11): 51-55.
- [18] 刘姝琼, 孔英会. 基于 LSSVM 和证据理论的电力系统暂态稳定评估[J]. 电力科学与工程, 2010, 26(1): 34-38.  
LIU Shuqiong, KONG Yinghui. Assessment of power system transient stability based on SVM and evidence[J]. Electric Power Science and Engineering, 2010, 26(1): 34-38.
- [19] WAHAB N I A, MOHAMED A, DABBAGH M A. Transient stability assessment of a large actual power system using least squares support vector machine with enhanced feature selection[C] // 2008 Power Engineering Conference, Sydney, Australia, December 14-17, 2008: 1-6.
- [20] SHARMA C, TYAGI B. Transient stability status predictor based on relevance vector machine[C] // IEEE Innovative Smart Grid Technologies (ISGT) Asia 2013, Bangalore, India, November 10-13, 2013: 1-6.
- [21] GEEGANAGE J, ANNAKAGE U D, WEEKES T, et al. Application of energy-based power system features of

- dynamic security assessment[J]. IEEE Transactions on Power Systems, 2015, 30(4): 1957-1965.
- [22] 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.
- [23] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [24] 曹曼. 基于遗传模拟退火算法的暂态稳定评估特征选择[D]. 北京: 华北电力大学, 2006.
- CAO Man. Feature selection for transient stability assessment based genetic simulated annealing algorithms[J]. Beijing: North China Electric Power University, 2006.
- [25] 于之虹, 郭志忠. 改进主成分分析法用于暂态稳定评估的输入特征选择[J]. 电力自动化设备, 2003, 23(8): 17-20.
- YU Zhihong, GUO Zhizhong. Improved principal component analysis to feature selection for transient stability assessment[J]. Electric Power Automation Equipment, 2003, 23(8): 17-20.
- [26] 于之虹, 黄彦浩, 鲁广明, 等. 基于时间序列关联分析的稳定运行规则提取方法[J]. 中国电机工程学报, 2015, 35(3): 519-526.
- YU Zhihong, HUANG Yanhao, LU Guangming, et al. A time series associative classification method for the operation rule extracting of transient stability[J]. Proceedings of the CSEE, 2015, 35(3): 519-526.
- [27] 王科, 游大海, 蓝海波, 等. 基于支持向量机的电力系统临界割集暂态稳定可用传输容量快速预测[J]. 高电压技术, 2015, 41(3): 800-806.
- WANG Ke, YOU Dahai, LAN Haibo, et al. Transient stability available capacity fast prediction of power system critical cutset based on support vector machine[J]. High Voltage Engineering, 2015, 41(3): 800-806.
- [28] CHANG C C, LIN C J. LIBSVM: A library for support vector machines[J]. ACM Transactions on Intelligent System Technology, 2011, 2(3): 389-396.
- 
- 收稿日期: 2016-11-08; 修回日期: 2017-02-28
- 作者简介:
- 田芳(1973—), 女, 通信作者, 博士, 教授级高级工程师, 研究方向为电力系统分析与控制、电力系统数字仿真; E-mail: tianf@epri.sgcc.com.cn
- 周孝信(1940—), 男, 教授级高工, 中国科学院院士, 中国电力科学研究院名誉院长, 研究方向为电力系统分析与控制、电力系统仿真以及 FACTS 技术等;
- 于之虹(1975—), 女, 博士, 高级工程师, 研究方向为电力系统安全稳定评估与控制、仿真分析技术等。
- (编辑 张爱琴)