

# 基于 QPSO-SVM 模型的电力系统稳定性评估<sup>①</sup>

李 强<sup>1,2</sup>, 刘晓峰<sup>3</sup>

<sup>1</sup>(山西省财政税务专科学校 信息学院, 太原 030024)

<sup>2</sup>(太原理工大学 财经学院, 太原 030024)

<sup>3</sup>(太原理工大学 数学学院, 太原 030024)

**摘 要:** 随着我国电力系统的快速发展, 超高电压输变电已经开始应用, 电网变的更加复杂, 其电力系统的稳定性和安全性问题更显得突出. 电压的稳定性一直是系统可靠性的重要指标, 而其电压质量的在线实时评估一直是研究的难题. 本文采用支持向量机(SVM)模型来提高运算精度和效率, 并通过量子行为粒子群算法(QPSO)优化并计算其参数, 提出一种基于 QPSO-SVM 的模型, 可用于实时在线评估电力系统的稳定性. 此外, 为了提高机器学习的评估指标的精准度, 采用先进的潮流计算 Jacobian 的切向量分量来作为 VSI, 可以保证评估值的绝对性, 并可以适用于各种网络结构. 最后在 WSCC9-bus 标准系统上实验证明, 该方法比 GA-SVM、一般的 SVM 和 BP 神经网络在学习时间分别提高 23.2%、63%、77.9%, 测试时间分别加快 26.2%、56.9%、72.56%, 在精度上分别提高 28.9%、42.19%、82.34%. 另外, 通过在 IEEE14 总线上做实验, 可以找到系统崩塌前的关键总线, 并与潮流计算的结果基本一致, 因此该方法是一种可以作为实时在线电力系统稳定性评估的理想方法.

**关键词:** 电力系统稳定性评估; SVM; 粒子群算法; 潮流计算; 仿真计算

## Assessment of Power System Stability Based on QPSO-SVM

LI Qiang<sup>1,2</sup>, LIU Xiao-Feng<sup>3</sup>

<sup>1</sup>(College of Information, Shanxi Finance & Taxation College, Taiyuan, 030024, China)

<sup>2</sup>(Department of Information, College of Finance & Economics, Taiyuan University of Technology, Taiyuan 030024, China)

<sup>3</sup>(College of Math, Taiyuan University of Technology, Taiyuan, 030024, China)

**Abstract:** With the fast development of national power industry, ultra high voltage power transmission has already been applied in practice. And the following features such as stability and security of power system have become more crucial owing to the complexity of the grid. On the one hand, voltage stability is the major factor accounting for the power system reliability. On the other hand, the online assessment of the voltage stability in real time has always been an obstacle in the concerning research. This paper aims to put forward a QPSO-SVM model which can be applied to the online assessment of the voltage stability in real time, based on the increasing accuracy and efficiency of calculation by means of SVM model as well as the production of parameter via the method of QPSO. In addition, it ensures the absolute assessment and the comprehensive application to all networks adopt the component of tangent vector of power flow power as VSI so as to improve the assessment accuracy of machine learning. Finally, it is approved that by means of WSCC9-bus, the learning time, the assessment time and the accuracy have been increased by 23.2%, 63%, 77.9%, and 26.2%, 56.9%, 72.56% and 28.9%, 42.19%, 82.34%, respectively, compared with GA-SVM, SVM and BPNN. Also, the method based on the IEEE14 experiment is an ideal path for the online assessment of the voltage stability for the power system in real time due to the fact that the key buses can be found before the system collapses and that it shares the same findings with the power flow calculation.

**Key words:** power system stability assessment; support vector machine; QPSO; power flow; simulation calculation

① 基金项目:国家自然科学基金(61502330);山西省高等学校科技创新项目(201611131);山西省软科学计划研究项目(2016041008-5)

收稿时间:2016-03-21;收到修改稿时间:2016-09-02 [doi:10.15888/j.cnki.csa.005677]

## 引言

电力系统具有非线性、耐受性差和缺乏有效的模型的特点,其稳定性评估一直是个难点<sup>[1]</sup>.在电力系统中评估系统的稳定性参数很多,其中电压的稳定性评估是观测整个电力系统稳定性评估的最直接的方法.监测行为指数法通常被用来评估电压的安全性,但是该方法需要花费大量的计算,因此不适合在线实时监测.

一种被称作“潮流计算 Jacobian 的切向量的分量法”的新方法可用于电压稳定性评估指数<sup>[2]</sup>.这种方法在表明电压崩塌时,非常类似于“L 指标法”.此外,在任意一个接近电压稳定极限的节点处,该方法提供了一个更有效的信息.相比较“L 指标法”,其具有更简单的计算方式和更广泛的应用范围.

使用人工智能机器学习的方法应用于实时电压稳定性评估方面的工作已经有了一些成效,例如使用人工神经网络、决策树和贝叶斯分类法用于快速电压评估等等<sup>[3][4]</sup>.其中,人工神经网络(ANN)是一个典型的静态和动态的电压评估方法<sup>[5]</sup>,例如 BP 神经网络用于电压的评估<sup>[6]</sup>.但是,ANN 需要大量的计算时间和空间,所以不太适合实时在线评估电力系统的稳定性.

本文中,以潮流计算雅可比的切向量分量为训练目标,建立一种 QPSO-SVM 机器学习模型实现电压的稳定性评估.这种模型的特点是使用先进的技术模型实现非线性的快速映射<sup>[7-10]</sup>.并且,使用切向量作为评估指数比 BP 神经网络方法<sup>[2]</sup>、一般的 SVM<sup>[7]</sup>和 GA-SVM 方法<sup>[12]</sup>,将更加高效和更加精确.最后,通过两个标准实验模型,WSCC3 机 9 线模型<sup>[13]</sup>和 IEEE 14 总线模型来证明该方法的有效性.

为了更好的使用支持向量机,需要通过经验手动设置其参数,然而这往往是非常困难的,为了解决这个问题,采用量子行为粒子群算法(QPSO)来自动实现 SVM 中的相关参数设置<sup>[14]</sup>,即构造一种带量子行为的粒子群算法优化的支持向量机(QPSO-SVM).

## 1 潮流计算 Jacobian 的切向量

对于任意一节点的潮流计算可以通过以下等式表达:

$$P_{Gi} - P_{Li} - P_{Ti} = 0, P_{Ti} = \sum_{j=1}^n V_i V_j [G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}] \quad (1)$$

$$Q_{Gi} - Q_{Li} - Q_{Ti} = 0, Q_{Ti} = \sum_{j=1}^n V_i V_j [G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}]$$

在任意一操作节点的潮流计算的 Jacobian 矩阵 (PFJ) 可以通过下式表达:

$$J_{powerflow} = \begin{pmatrix} \frac{\partial P_{Ti}}{\partial \theta_j} & \frac{\partial P_{Ti}}{\partial V_j} \\ \frac{\partial Q_{Ti}}{\partial \theta_j} & \frac{\partial Q_{Ti}}{\partial V_j} \end{pmatrix} \quad (2)$$

继续通过 PFJ 可以推导出以下切向量(TV):

$$TV = \begin{bmatrix} \Delta \theta \\ \Delta |V| \end{bmatrix} = J_{powerflow}^{-1} \begin{bmatrix} P_{Gi} - P_{Li} \\ Q_{Gi} - Q_{Li} \end{bmatrix} \quad (3)$$

由 PFJ 导出的任意一节点的切向量中的分量  $\Delta |V|$  包含可以指明总线上的电压变化幅度.当该  $\Delta |V|$  在大于 0 小于 1 之间时,可以绝对地表明系统电压是稳定的,而其值大于等于 1 时,表明系统是不稳定的.所以,建议使用该值作为电压的稳定性指标(VSI).相比较而言,使用传统的“L 指标”有两大缺点:一、只能相对地评估系统稳定性;二、是不能用于其它网络结构,如环网结构<sup>[2]</sup>.

但是,通过数学的分析方法实时求解任意一节点的切向量仍然计算量是非常庞大的.因此,在本文中,提出一种 QPSO-SVM 模型方法求解该切向量的值,来实现快速、实时和精确地判断系统稳定状态.

## 2 支持向量机的拟合方法

支持向量机是在函数拟合,状态监测和数据分类等方面表现优秀的一种方法.SVM 回归法主要用来解决线性和非线性问题的<sup>[7]</sup>.这里有一组数据样本需要去训练向量机,集合  $\text{set}\{x_i, y_i\} \quad i=1, 2, \dots, n$ , 其中  $x_i \in \mathbb{R}^d$  作为输入向量,  $y_i \in \mathbb{R}$  将作为输出值.在线性的情况下,该函数回归函数被定义为以下表达式:

$$f(x) = w^T x + b = 0 \quad (4)$$

这个线性回归方法需要最小化两个参数,一个是钝化损失( $\epsilon$ ),另一个是线性范化参数( $\|\omega\|^2$ ).通过引入松弛变量  $\zeta_i$ ,来解决某一向量  $x_i$  站错位置的问题,因此,简化 SVM 回归函数为以下表达式:

$$\text{Minimize } \Phi(\omega) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^M (\zeta_i + \zeta_i^T), \quad C > 0 \quad (5)$$

其约束条件为:

$$\begin{cases} y_i - \omega \cdot x_i - b \leq \epsilon + \zeta_i \\ \omega \cdot x_i + b - y_i \leq \epsilon + \zeta_i^T \\ \zeta_i, \zeta_i^T \geq 0, i=1, 2, \dots, n \end{cases} \quad (6)$$

其中参数  $\varepsilon$  被用于调整精度. 再通过拉格朗日乘数  $\alpha_i, \alpha_i^T, \eta_i, \eta_i^T$  解决此类约束问题:

$$\begin{aligned} L(\omega, b, \xi, \xi^T) = & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^T) \\ & - \sum_{i=1}^n \alpha_i (\varepsilon_i + \xi_i - y_i + \omega \cdot x_i + b) \\ & - \sum_{i=1}^n \alpha_i^T (\varepsilon_i + \xi_i^T + y_i - \omega \cdot x_i + b) \\ & - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^T \xi_i^T), \quad \alpha_i, \alpha_i^T, \eta_i, \eta_i^T \geq 0 \end{aligned} \quad (7)$$

由此, 以上表达式可以变化为拉格朗日对偶问题:

$$\begin{aligned} \text{Maximize } W(\alpha) = & \sum_{i=1}^n y_i (\alpha_i - \alpha_i^T) - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^T) \\ & - \frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^T) (\alpha_j + \alpha_j^T) (x_i \cdot x_j) \end{aligned} \quad (8)$$

约束条件为:

$$\text{Subject to } \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^T) = 0 \\ 0 \leq \alpha_i, \alpha_i^T \leq C \end{cases} \quad (9)$$

最后, 经过再次拉格朗日变化得到以下最终的拟合函数:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^T) \cdot (x_i \cdot x) + b \quad (10)$$

此外, 为了解决非线性问题, 需要做从非线性空间到高维特征线性空间的转换.

定义函数为:  $K(x_i, x_j) = \Phi(x_i) \bullet \Phi(x_j)$  (11)

为了实现转换, 使用核函数  $K(x_i, y_j)$ . 要作为核函数必须满足 Mercer 理论条件, 核函数将在特征空间中实现点积. 引入核函数的目的在于为支持向量机实现减少运算量. 通过非线性映射函数  $\Phi(x_i)$  将数据映射到高维特征空间中去. 在这个新的空间中, 线性函数将满足回归条件. 因此非线性函数可以采用以下形式表达:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^T) \cdot K(x_i \cdot x) + b \quad (12)$$

有很多的核函数可以在应用中被选择, 主要有线性核函数、多项式核函数和高斯核函数. 决定使用哪个核函数是关键的一步, 因为训练的样本将在核函数决定的空间内做运算. 一个被定义的核函数必须满足 Mercer 的两个条件, 一个是连续, 另一个是正定. 以下是常用的三个核函数:

$$\text{线性核函数: } K(x, x_i) = x^T \cdot x_i \quad (13)$$

$$\text{多项式核函数: } K(x, x_i) = x^T \cdot x_i \quad (14)$$

$$\text{高斯核函数: } K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (15)$$

在本模型中, 将使用高斯核函数实现非线性映射. 其中惩罚因子  $C$  和核函数宽度半径参数  $\delta$  扮演者非常重要的角色, 影响着 SVM 分类的效率和效果.

### 3 QPSO-SVM算法描述

#### 3.1 PSO 算法描述

粒子群算法(QPSO)其思想来源于鸟群觅食过程的启发. 在鸟群觅食过程中, 每个鸟既是独立的个体, 又受群体的影响. 通过群体智慧, 最终整个鸟群的觅食搜索演变成了寻找问题空间中的最优解.

当使用粒子群算法解决优化问题时, 问题被转化为鸟在搜索空间中寻找的位置, 此时鸟被称作“粒子”. 每一个粒子都有其自己的位置和运动速度, 还有一个用来测量每一个粒子优越性的适应度函数. 每一个粒子记忆和趋向当前最优粒子运动, 并在解决空间中搜索.

粒子群算法开始随机初始化一组粒子, 并且每一个粒子在解决空间中同时趋近于两点. 一个点是在历史搜索中所有粒子中最佳的位置, 被称为全局最优解  $p_g$ ; 另一个点是第  $i$  个粒子在自己的搜索过程中最佳的位置, 被称为  $p_i$ ; 当粒子搜索这两点时, 每一个粒子更新自己的位置和运动速度, 如下式所示:

$$\begin{aligned} v_{i,j}^k = & w \cdot v_{i,j}^{k-1} + c_1 r_1 (p_{i,j} - x_{i,j}^{k-1}) + c_2 r_2 (p_{g,j} - x_{i,j}^{k-1}) \\ x_{i,j}^k = & x_{i,j}^{k-1} + \beta \cdot v_{i,j}^k \end{aligned} \quad (17)$$

其中,  $p$  是当前位置,  $v$  是当前速度, 这俩决定了下一个位置的方向.  $\beta$  是一个约束因子, 它控制速度的权重.  $C1$  和  $c2$  是两个被称为加速因子的正数常量.  $R1$  和  $r2$  是两个在 0 和 1 之间的随机值.  $w$  是一个可以改变搜索能力的记忆参数.

#### 3.2 使用量子行为改进 PSO 算法

PSO 虽然在解决路径规划等方面表现非常优秀, 但是在实践中该算法仍然具有收敛速度较慢, 容易早熟, 易停留在局部最优点等问题. 为了改良该 PSO 算法, 本文将采用量子行为思想来改进粒子群算法, 增强其在全局的搜索能力, 即具有量子行为的粒子群算法(QPSO). 该算法具有加速收敛和提高粒子协同的能力的特点. 引入势点  $q$ ,  $q$  点成为每一个粒子的收敛随机点<sup>[14]</sup>,  $p$  点如下式表示, 其中,  $i$  为第  $i$  个粒子, 共有  $m$  个粒子, 每个粒子  $n$  维,  $k$  为迭代次数.

$$q_i^k = \{q_{i,1}^k, q_{i,2}^k, \dots, q_{i,n}^k\}, \quad i=1,2,\dots,N \quad (18)$$

定义评估函数用于评价每个粒子当前的位置的好坏.

$$f(x) = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i(x) - y'_i(x))^2} \quad (19)$$

以上式中,  $y_i$  为 SVM 的计算值,  $y'_i$  为训练目标值, 该函数用来计算待求参数  $x$  的 SVM 计算值和目标值的偏差.

第  $k$  次迭代, 粒子位置的更新规则为, 如果粒子的新位置的适应度值优于第  $k-1$  次, 则更新粒子的新位置; 否则, 保持不变.

$$q_{i,j}^k = (1-\alpha) p_{i,j}^k + \alpha p_{g,j}^k \quad (20)$$

式(20)定义了势点  $q$ , 其中  $\alpha$  是在 0 至 1 之间的随机数.

粒子值的更新规则为下式:

$$x_{i,j}^k = q_{i,j}^{k-1} \pm \lambda \left| p_{best}^{k-1} - x_{i,j}^{k-1} \right| \cdot \ln\left(\frac{1}{\theta}\right), \quad (21)$$

$$p_{best}^{k-1} = \frac{\sum_{i=1}^m p_i^{k-1}}{m}$$

其中,  $\theta \geq 1/2$  时, 上式取负号, 否则取正号;  $\lambda$  是速度因数, 该值会影响收敛速度<sup>[14]</sup>,  $\lambda$  可以按下式取值.

$$\lambda = \frac{0.3 \cdot (h_{max} + k)}{h_{max}} + 0.3 \quad (22)$$

其中,  $h_{max}$  是预设的迭代次数.

### 3.3 QPSO 求解 SVM 的参数的算法步骤

在本文中 will 使用基于量子行为改进粒子群算法来搜索这些参数最佳的组合, 具体步骤如下:

- 第 1 步, 编码待求参数,  $x = \{C, \delta\}$ .
- 第 2 步, 建立训练样本集合.
- 第 3 步, 确定 SVM 网络结构, 以及核函数的选择.
- 第 4 步, 计算粒子和粒子群的最优位置.
- 第 5 步, 依据更新公式, 更新粒子位置.
- 第 6 步, 在本次迭代结束后, 如果迭代的次数超过了预设值或者计算误差达到预设值, 则满足精度要求, 输出其计算值, 否则转到第 4 步.

## 4 实验和分析

### 4.1 WSCC 3 机 9 线系统模型

#### 4.1.1 SVM 模型的结构

这个算法使用 QPSO-SVM 模型来评价系统的状态, 其中输入参数包括发电机端电压, 发电机的有功功率和无功率, 以及负载. 输出值为电力系统潮流

计算的切向量分量. 通过机器学习, 建立系统工作环境变量和电力系统状态指标之间的非线性映射关系, 最终, 计算实时在线的系统状态评估值.

#### 4.1.2 训练工具

使用 Matlab 支持向量机软件包和粒子群算法软件包去搜索向量机的最佳组合参数. 并使用电力系统分析软件包(PSASP)生成所有的实验数据.

#### 4.1.3 机器训练

在 WSCC3 机 9 线标准系统模型<sup>[14]</sup>上产生的数据将被训练. 150 个离线潮流计算的样本数据从电力系统分析软件包中生成, 其中 90 个被作为训练机器的样本, 剩余 60 个被用来测试数据. 在这个标准系统模型里, 通过改变一个负载总线上的有功和无功功率, 并保持其它总线参数不变, 来产生整个系统的数据.

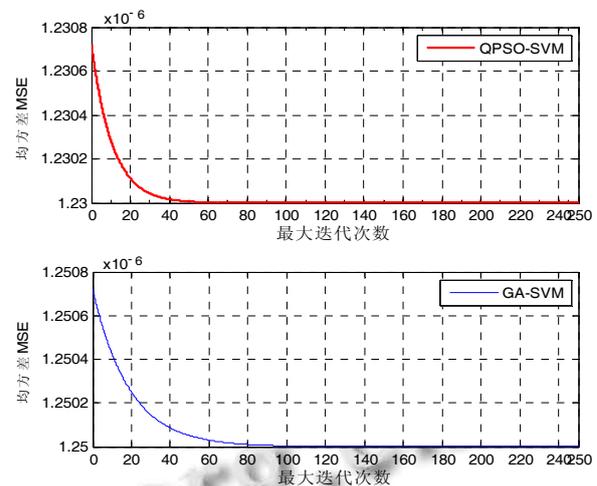


图 1 QPSO-SVM 和 GA-SVM 收敛误差比较

表 1 QPSO 算法的结果

算法的名称	平均迭代次数	收敛时间	全局优化概率(%)
GA	93	102	70.51
QPSO	42	85	73.41

表 2 为 SVM 设置的参数

参数名	GA 计算值	QPSO 计算值	人工经验设置值
C	30	25	50
$\delta$	1.25	1.14	2.5

设置粒子群的维数为 2, 最大迭代次数为  $N_{max}=250$ , 记忆参数设置为  $w=2$ , 初始化惩罚因子 C 和核函数宽度  $\delta$  为  $\{20, 10\}$ . 在 QPSO-SVM 迭代过程中, 可以注意到 QPSO-SVM 在迭代到 42 次时算法开

始收敛,核函数宽度  $\delta$  该值迅速掉到 1.14 附近,而 GA-SVM 在 93 次附近开始收敛,在 GA-SVM 迭代过程中,该值由 10 迅速下降到 1.25; 所以 QPSO-SVM 在

计算参数时,收敛速度要优于 GA-SVM 算法. 如图 1、表 1 和表 2 所示.

表 3 每一负载线的参数

$P_{GI}$	$Q_{GI}$	$V_A$	$V_B$	$V_C$	$TV_A$	$TV_B$	$TV_C$
0.5632	0.2525	1.0243	1.0140	0.8886	0.0447	0.0429	0.0532
1.3971	0.2883	1.0121	1.0097	0.8732	0.0531	0.0471	0.1308
1.9182	0.8832	1.0089	0.8979	0.9329	0.0631	0.0669	0.1719
2.9977	1.5968	0.9299	0.9792	0.9923	0.0429	0.0582	1.2932
0.5531	0.2423	1.0261	1.0141	0.8983	0.0449	0.0429	0.0519
1.3868	0.2979	1.0120	1.0092	0.8730	0.0531	0.0472	0.1323
3.9589	2.2829	0.9729	0.9659	0.9187	0.0481	0.0731	1.4541
4.3831	2.9982	0.9759	0.9677	0.8919	0.0522	0.0789	1.5341
5.1281	3.7262	0.9934	0.9852	0.8491	0.0623	0.0981	1.6252
0.9279	0.3769	1.0239	1.0209	0.9747	0.0230	0.0329	0.0870
1.8368	0.3880	1.0219	0.9388	0.9809	0.0503	0.0331	0.0868
4.8281	3.2161	0.9809	0.9751	0.8381	0.0541	0.0809	1.5781

在表 3 中列举了其中前 10 个训练数据样本. 并且从表 3 中,观测电压稳定性指标的值,很容易发现总线 c 上存在问题.

表 4 QPSO-SVM、GA-SVM、SVM 和 BP 神经网络的比较

算法名称	学习时间(ms)	测试时间(ms)	均方差	最大误差
QPSO-SVM	192	33	1.2323e-006	0.017
GA-SVM	253	45	1.7330e-006	0.043
SVM	522	73	2.1313e-006	0.022
BPNN	877	115	6.9788e-006	0.048

在表 4 中,将 QPSO-SVM 算法、SVM 算法、QPSO-SVM 算法、BPNN 算法的执行效率参数和精度进行了比较. 其中, QPSO-SVM 可以满足电压稳定性评估的需要,也就是说该模型计算值可以在线或离线实时反应系统的电压稳定状态. 通过比较,表 4 中的结果在 3 机 9 线标准系统上实验比较证明,该 QPSO 方法比 GA-SVM、SVM 和 BPNN 在学习时间上分别可以提高 23.2%、63%、77.9%,在测试时间上分别可以提升 26.2%、56.9%、72.56%,在计算精度上分别增加 28.9%、42.19%、82.34%,该实验结果说明 QPSO-SVM 方法在学习时间、测试时间和精度上更优于比其它 3 种方法.

#### 4.2 IEEE14 总线系统模型

在 4.1 部分里,实现了在 IEEE14 总线标准模型系统上对 QPSO-SVM 算法的应用. 主要的目的是,测试

QPSO-SVM 算法计算的值和潮流计算切向量分量的值之间的差别,判断是否该方法计算的值是否可以作为潮流计算切向量的一种替代.

为了这项研究,给 14 总线系统模型引入一个乘数  $\lambda=4.05$  作为系统的负载极限. 在基本情况下,负载和发电机使用连续性潮流计算法. 在基本情况下,通过潮流计算的 TV 值和 QPSO-SVM 得出的值可以通过图 2 和表 5 进行比较. 从中可以发现倾向于电压崩溃的最关键的总线是 14 总线. 同时,通过比较,也可以看到 QPSO-SVM 计算值作为指标值与潮流计算的切向量分量值非常接近,都可以用来标明系统电压稳定的脆弱位置.

表 5 在基本负载 QPSO-SVM 和 TV 的比较

总线编号	QPSO-SVM	TV 值	绝对误差
4	0.264	0.273	0.011
5	0.284	0.287	-0.003
6	0.241	0.245	-0.002
7	0.260	0.266	-0.006
8	0.309	0.312	-0.003
9	0.433	0.433	0
10	0.419	0.415	0.04
11	0.237	0.242	0.005
12	0.152	0.160	-0.008
13	0.212	0.221	-0.009
14	0.543	0.535	0.012

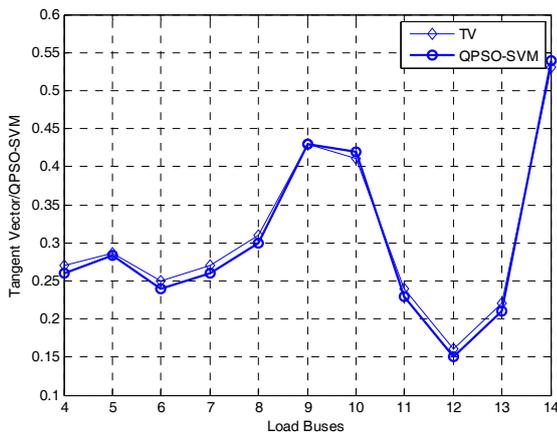


图2 基本负载下 QPSO-SVM 和 Tangent Vector 的比较

从图 3 中, 可以看到在不同的负载级别下, 这两个计算指标值。

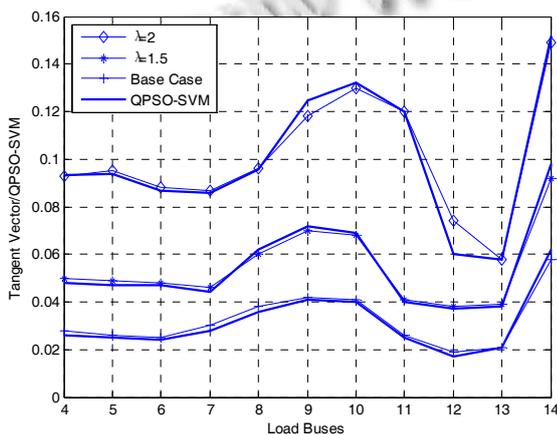


图3 在不同负载级别下 QPSO-SVM 和 TV 的比较

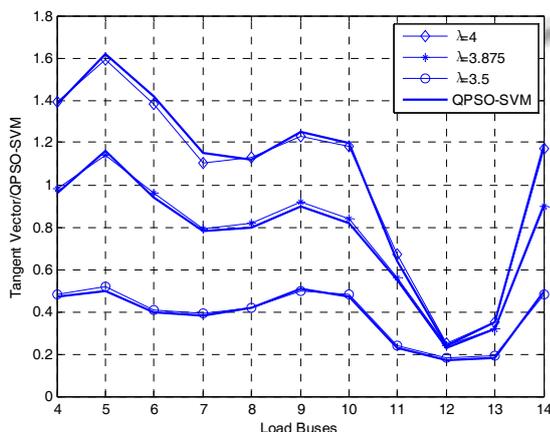


图4 在极限负载情况下 QPSO-SVM 和 TV 的比较

图 4 中, 在接近负载极限的位置节点上,

QPSO-SVM 方法计算的指标值和关键总线可以同时被发现. 从图中, 可以发现总线 5 是一个关键总线, 在该位置上将接近负载的极限. 但是, 在较低负载的等级下, 14 总线已经被发现并认定为也是一关键总线. 根据这个发现, 一项有意义的研究已经被展开<sup>[2]</sup>.

这个特点可以通过 QPSO-SVM 方法捕获, 如同潮流计算的切向量计算的结果.

### 5 结论

本文中, 提出一种新的 QPSO-SVM 方法, 并以潮流计算的切向量分量作为评价指标来实现电力系统的电压稳定性评估. 在该方法中, 使用基于量子行为的粒子群算法 QPSO 用来自适应设置 SVM 的参数, 来提高 SVM 的精度. 此外, 潮流计算中的切向量分量作为 SVM 学习的目标来提升计算结果的有效性. 这个实验表明, QPSO-SVM 的计算的精度和效率要优于一般的 SVM 和 BP 神经网络, 这也预示了该方法是评估电力系统稳定性的一种非常有前途的算法. 同时, 这里还存在着很多研究的空间, 在下一步的研究工作中, 大规模电力网络的划分和稳定性评估方法将被继续探索, 以及该方法在环形网络中评估有效性的实验证明等.

### 参考文献

- 1 Sauer PW, Pai MA. Power system dynamics and stability. Prentice Hall, 1998.
- 2 Acharya NV, Rao PSN. A new voltage stability index based on the tangent vector of the power flow jacobian. 2013 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia). 2013. 1-6.
- 3 Patidar NP, Sharma J. Load ability margin estimation of power system using Model Trees. 2006 IEEE Power India Conference. 2006.
- 4 Kessel P, Glavitch H. Estimating the voltage stability of power systems. IEEE Trans. on Power Delivery, 1986, 1(3): 346-354.
- 5 陈祥光, 裴旭东. 人工神经网络技术及应用. 北京: 中国电力出版社, 2003.
- 6 Han X, Zheng Z, Tian N, et al. Voltage stability assessment based on BP neural network. Asia-Pacific Power & Energy Engineering Conference. 2009. 1-4.

- 7 An JL, Yang QX, Ma ZP. Study on SVM on-line function regression method for mass data. Machine Learning and Cybernetics. 2007 International Conference. 2007. 2773–2777.
- 8 Li H, Zhang YX. An algorithm of soft fault diagnosis for analog. Electronic Measurement & Instruments, 2009, 4-1023–4-1027.
- 9 Zhou J, Bai T, Tian J, et al. The study of SVM optimized by culture particle swarm optimization on predicting financial distress. 2008 IEEE International Conference on Automation and Logistics. 2008. 1054–1059.
- 10 Vahid R, Ata E, Reza G. Application of the QPSO-SVM model for reconnection of control chart patterns. ISA Trans., 2010, 49(4): 577–586.
- 11 Lin SW, Ying KC, Chen SC, et al. Particle swarm optimization for parameter determination and feature selection of support vector machines. Expert Systems with Application, 2008, 35(4): 1817–1824.
- 12 Li Q. The Analysis and assessment of voltage stability based on GA-SVM. Journal of System Simulation, 2014, 10: 2369–2373, 2406.
- 13 Meah K, Ula AHMS. Simulation study of the CIGRE HVDC benchmark model with the WSCC nine-bus power system network. Power Systems Conference and Exposition. 2009. 1–5.
- 14 Sun J, Fang W, Palade V, et al. Quantum-behaved particle swarm optimization with Gaussian distributed local attractor point. Applied Mathematics and Computation, 2011, 218(7): 3763–3775.