

# 基于粒子群优化鲁棒支持向量回归机的中长期负荷预测

张雪君<sup>1</sup>, 陈刚<sup>1</sup>, 周杰<sup>1</sup>, 马爱军<sup>1</sup>, 张忠静<sup>2</sup>

(1. 输配电装备及系统安全与新技术国家重点实验室(重庆大学), 重庆 400044;  
2. 贵州电网公司贵阳供电局, 贵州 贵阳 550002)

**摘要:** 支持向量机(SVM)已经成功地应用于解决非线性回归和时间序列问题,并且已经开始用于中长期负荷预测。提出了一种基于鲁棒支持向量回归机RSVR( Robust Support Vector Regression)的中长期负荷预测的新方法。给出利用粒子群优化算法对鲁棒支持向量机系数优化选择的方法。建立基于此原理的中长期负荷预测模型,算例分析比较验证本文方法具有预测精度高、计算量小等特点和优势。

**关键词:** 中长期负荷预测; 鲁棒性; 支持向量机; 回归估计; 粒子群优化算法

## Medium and long-term load forecast based on PSO-RSVR

ZHANG Xue-jun<sup>1</sup>, CHEN Gang<sup>1</sup>, ZHOU Jie<sup>1</sup>, MA Ai-jun<sup>1</sup>, ZHANG Zhong-jing<sup>2</sup>

(1. State Key Laboratory of Power Transmission Equipment & System Security and New Technology, Chongqing University, Chongqing 400044, China; 2. Guiyang Power Supply Administration, Guizhou Power Grid, Guiyang 550002, China)

**Abstract:** Support Vector Machine (SVM) has been successfully applied to solve non-linear regression and time series problem, and has already been used for the medium and long-term load forecasting. This paper brings forward a new load forecasting method based on Robust Support Vector Regression (RSVR). It gives the use of particle swarm optimization for the robust support vector machines coefficient optimization and constructs the forecasting model. A case is presented to verify the method possessing high precision, small amount of computation and so on.

**Key words:** medium and long-term load forecasting; robust; support vector machine (SVM); regression; particle swarm optimization

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2009)21-0077-05

## 0 引言

中长期负荷预测是电力系统规划建设的依据,其预测的准确程度将直接影响到电网投资、布局和运行的合理性<sup>[1,2]</sup>。

支持向量机 SVM (support vector machine) 是一种基于统计学习理论的模式识别方法,它是由 Vapnik 等在 20 世纪 90 年代中期提出的一种新的机器学习方法<sup>[3]</sup>。该方法建立在统计学习理论的 VC 维(Vapnik-Chervonenks dimension)及结构风险最小化原则的基础上,通过求解一个二次规划问题较好地解决了小样本、非线性、高维数和局部最小点等实际应用问题,目前已成功地应用于模式识别、文本分类及短期电力系统负荷预测中<sup>[4]</sup>。随着  $\epsilon$  不敏感损失函数的引入,支持向量机开始用于非线性回归估计问题。Bo-Juen Chen<sup>[5]</sup>等将支持向量机用于电力负荷预测中,取得了较好的预测结果。Mohamed

Mohandes<sup>[6]</sup>将支持向量机用于短期电力负荷研究中,并将其与神经网络和回归模型作比较,也取得了很好的结果。

文献[7]提出的基于支持向量机的中长期电力负荷预测采用主因素分析法对样本数据降维,提高了运算速度,但对各参数没有进行优化选择,预测精度仍需提高。本文采用一种新的支持向量回归机算法-鲁棒支持向量回归机 RSVR (Robust Support Vector Regression)<sup>[8]</sup>同时采用粒子群优化算法 (Particle Swarm Optimization)<sup>[9,10]</sup>对其权重参数利用寻优算法来选择,以提高预测精度。

## 1 鲁棒支持向量回归机

### 1.1 基本原理

SVM 方法的基本思想是:通过事先定义的非线性映射  $\Phi: R^n \rightarrow R^m (m \geq n)$ , 把输入空间的数据  $x$  映射到一个高维特征空间,然后在该空间中做线性

回归<sup>[11]</sup>。

给定数据点集为  $\{(x_i, y_i), i=1, 2, \dots, N\}$ ，其中： $x_i \in R^n$  为输入向量，即筛选出的最重要的电量供需影响因素， $y_i \in R^n$  为与  $x_i$  相对应的输出向量，即决策属性：全社会用电量； $N$  是数据点总数。SVM 通过下式进行函数回归估计：

$$f(x) = \omega \cdot \Phi(x) + b \quad (1)$$

式中： $\omega$ 、 $\Phi(x)$  为  $m$  维向量；“ $\cdot$ ”表示特征空间中的点积； $b \in R$  为阈值。SVM 利用结构风险最小化来求式 (1)，结构风险最小化的核心思想是：

$$R[f] \leq R_{\text{emp}} + R_{\text{reg}} \quad (2)$$

式中： $R[f]$  为实际风险； $R_{\text{emp}}$  为经验风险，它是  $f(x)$  与样本偏差的一种度量； $R_{\text{reg}}$  是置信范围，它是  $f(x)$  复杂度的一种度量。经验风险  $R_{\text{emp}}$  由损失函数确定，不同的损失函数会构成不同的  $R_{\text{emp}}$ ，进而形成不同的 SVM。为了增加 SVM 的鲁棒性，采用下述损失函数：

$$L(e) = \begin{cases} 0 & |e| \leq \varepsilon \\ \frac{1}{2}(|e| - \varepsilon)^2 & \varepsilon \leq |e| \leq e_c \\ c(|e| - \varepsilon) - \frac{1}{2}c^2 & |e| \geq e_c \end{cases} \quad (3)$$

式中： $e_c = \varepsilon + c$ 。如图 1 所示。

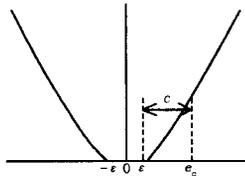


图 1 鲁棒损失函数  
Fig.1 Robust loss function

采用式 (3) 的损失函数，并把  $\frac{b^2}{2}$  项加入到调整项  $R_{\text{reg}}$  中，根据结构风险最小化式 (2)，RSVR 的问题可表示为：

$$\min \frac{1}{2}(\omega^T \omega + b^2) + C \left[ \sum_{i \in I_1} \frac{1}{2}(\xi_i^2 + \xi_i^{*2}) + \sum_{i \in I_2} c(\xi_i + \xi_i^*) \right] \quad (4)$$

$$\begin{aligned} & y_i - \omega^T \phi(x_i) - b \leq \varepsilon + \xi_i^* \\ \text{s. t. } & \omega^T \phi(x_i) + b - y_i \leq \varepsilon + \xi_i \\ & \xi_i, \xi_i^* \geq 0 \end{aligned}$$

式中： $C$  是调整参数， $I_1$  表示由松弛变量落在  $0 < \xi_i < c$  或  $0 < \xi_i^* < c$  区间的样本组合的集合， $I_2$  是由松弛变量落在  $\xi_i \geq c$  或  $\xi_i^* \geq c$  区间的样本组成的集合。根据文献[12]把  $\frac{b^2}{2}$  加入到调整项中对支持向量机的解影响不大。

对于 RSVR 所形成的优化问题，利用 KKT 条件、对偶原理及核函数技术，可以得到对偶问题的优化目标函数：

$$\begin{aligned} \bar{L} = & \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (a_i - a_i^*)(a_j - a_j^*)(K(x_i, x_j) + 1) + \\ & \varepsilon \sum_{i=1}^l (a_i + a_i^*) - \sum_{i=1}^l y_i (a_i - a_i^*) + \frac{1}{2C} \sum_{i=1}^l (a_i^2 + a_i^{*2}) \end{aligned} \quad (5)$$

在  $I_1$  集合中，优化变量的取值范围是  $0 \leq a_i, a_i^* < C \cdot c$ ，在  $I_2$  集合中， $a_i = C \cdot c$ ， $a_i^* = C \cdot c$ ，可知全部优化变量的取值范围是： $0 \leq a_i, a_i^* < C \cdot c$ 。最后可得决策函数为：

$$f(x) = \sum_{i=1}^l (a_i - a_i^*)(K(x_i, x) + 1) \quad (6)$$

### 1.2 算法设计

如上所述可知 RSVR 的对偶问题为： $\min \bar{L}$ ， $0 \leq a_i, a_i^* < C \cdot c$  (7)

利用局部梯度算法来求优化问题的解。对优化问题式 (7) 的目标函数求优化变量的导数

$$\frac{\partial \bar{L}}{\partial a_i} = -E_i + \varepsilon + \frac{a_i}{C}, \quad \frac{\partial \bar{L}}{\partial a_i^*} = E_i + \varepsilon + \frac{a_i^*}{C} \quad (8)$$

式中： $E_i = y_i - \sum_{j=1}^l (a_j - a_j^*)(K(x_i, x_j) + 1)$ 。根据梯度算法，优化变量的增量可选为：

$$\delta a_i = -\eta \frac{\partial \bar{L}}{\partial a_i} = -\eta(-E_i + \varepsilon + \frac{a_i}{C}) \quad (9)$$

$$\delta a_i^* = -\eta \frac{\partial \bar{L}}{\partial a_i^*} = -\eta(E_i + \varepsilon + \frac{a_i^*}{C}) \quad (10)$$

由于优化变量有变化范围限制，即  $0 \leq a_i, a_i^* < C \cdot c$ ，取

$$\Delta a_i = \begin{cases} -a_i & \delta a_i < -a_i \\ \delta a_i & -a_i \leq \delta a_i \leq C \cdot c - a_i \\ C \cdot c - a_i & \delta a_i > C \cdot c - a_i \end{cases} \quad (11)$$

$$\Delta a_i^* = \begin{cases} -a_i^* & \delta a_i^* < -a_i^* \\ \delta a_i^* & -a_i^* \leq \delta a_i^* \leq C \cdot c - a_i^* \\ C \cdot c - a_i^* & \delta a_i^* > C \cdot c - a_i^* \end{cases} \quad (12)$$

则 RSVR 算法步骤如下:

- (1) 初始化  $a_i = 0$ ,  $a_i^* = 0$ ,  $\Delta a_i = 0$ ,  $\Delta a_i^* = 0$ ,  $i = 1, 2, \dots, l$ ;
- (2) 计算核函数  $K(x_i, x_j) + 1$ ,  $i, j = 1, 2, \dots, l$ ;
- (3) 通过以下步骤更新  $a_i$ ,  $a_i^*$ :
  - (a)  $E_i = y_i - \sum_{j=1}^l (a_j - a_j^*) (K(x_i, x_j) + 1)$ ;
  - (b) 按照式子 (9) 和 (10) 计算  $\delta a_i$  和  $\delta a_i^*$ ;
  - (c) 根据式子 (11) 和 (12) 中的条件更新  $\Delta a_i$  和  $\Delta a_i^*$ ;
  - (d) 按照以下两式子更新  $a_i$ ,  $a_i^*$ :

$$a_i = a_i + \Delta a_i \quad (13)$$

$$a_i^* = a_i^* + \Delta a_i^* \quad (14)$$

(4) 判断是否满足迭代停止条件, 若满足则输出结果, 否则转入步骤 (3)。

## 2 粒子群优化算法

假设在一个  $D$  维的目标搜索空间中, 有  $n$  个粒子组成一个群落, 其中第  $i$  个粒子表示为一个  $D$  维的向量  $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ ,  $i = 1, 2, \dots, n$ , 即第  $i$  个粒子在  $D$  维的搜索空间中的位置是  $x_i$ 。换言之, 每个粒子的位置就是一个潜在的解。将  $x_i$  代入一个目标函数就可以计算出其适应值, 根据适应值的大小衡量  $x_i$  的优劣。第  $i$  个粒子的“飞翔”速度也是一个  $D$  维的向量, 记为  $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 。记第  $i$  个粒子迄今为止搜索到的最优位置为  $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ , 整个粒子群迄今为止搜索到的最优位置为  $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 。在考虑实际优化问题时, 希望先采用全局搜索, 使搜索空间快速收敛于某一区域, 然后采用局部精细搜索以获得高精度的解。因此改进后的算法表示如下:

$$v_{id} = w \cdot v_{id} + c_1 \cdot r_1 \cdot (p_{id} - x_{id}) + c_2 \cdot r_2 \cdot (p_{gd} - x_{id}) \quad (15)$$

$$x_{id} = x_{id} + v_{id} \quad (16)$$

其中:  $i = 1, 2, \dots, n$ ,  $d = 1, 2, \dots, D$ ; 学习因子  $c_1$  和  $c_2$  是非负常数;  $r_1$  和  $r_2$  是介于  $[0, 1]$  之间的随机数;

$-V^{\max} \leq v_{id} \leq V^{\max}$ ,  $V^{\max}$  是事先确定的正常数, 限制速度的变化范围。迭代终止条件根据具体问题一般选为最大迭代次数或粒子群迄今为止搜索到的最优位置且满足预定最小适应阈值。

## 3 基于 PSO 的 RSVR 参数优化算法改进

PSO 是一种模仿自然界群体行为智能的算法之一, 对各个粒子采用速度和方向两个量确定其位置, 每个粒子在每个位置对应一个适应度函数值, 根据适应度函数值的大小来更新该粒子的速度, 进而更新粒子的位置, 这些粒子会根据自身的适应度调整位置, 最终聚积在最优值附近。

利用 PSO 进行参数优化的具体步骤如下:

- (1) 训练一次 RSVR
  - a) 初始化常数  $\epsilon = 0.01$ ,  $r = 0.05$ , 参数  $C$  和  $c$  分别是一个随机数, 拉格朗日乘子  $a = 0$ ,  $ax = 0$ , 核函数矩阵  $H = 0$ ;
  - b) 计算核函数  $K(x_i, x_j) + 1$ ,  $i, j = 1, 2, \dots, l$ ;
- 核函数采用 RBF 核函数, 即
 
$$K(x, x_i) = \exp\left(-\frac{(x - x_i)^2}{2\sigma^2}\right), \text{ 其中 } \sigma = 2;$$
- c) 根据公式  $E_i = y_i - \sum_{j=1}^l (a_j - a_j^*) (K(x_i, x_j) + 1)$  计算误差  $E_i$ ;
- d) 根据公式 (9)、(10) 计算梯度  $\delta ta(i)$  和  $\delta ta^*(i)$ , 并根据条件 (11)、(12) 更新  $\Delta ta(i)$  和  $\Delta ta^*(i)$ ;
- e) 根据公式 (13) 和 (14) 更新  $a_i$  和  $a_i^*$ ;
- f) 判断是否满足停止条件 (迭代 50 次), 若满足则终止迭代, 否则返回 c);
- g) 输出结果  $y_{out}$ ;
- h) 根据以下公式计算均方误差 (NMSE), 该均方误差也是 PSO 算法中粒子的适应度函数。

$$xerr = \left( \sum_{i=1}^l (y - \bar{y}_i)^2 \right)^{\frac{1}{2}}, i = 1, 2, \dots, l \quad (17)$$

### (2) POS 优化过程

- a) 初始化常数  $m = 10$ ,  $c_1 = c_2 = 1.4$ ,  $Maxiter = 20$ ,  $vmax = 1$ 。
- b) 把寻优目标参数  $C$  和  $c$  作为粒子, 它们的初始值分别为 1.a) 中参数  $C$  和  $c$  的值, 并将它们作为当前个体最优解。
- c) 将 1.g) 中的均方误差  $xerr$  作为粒子的初始适应值。搜寻其中的最优值作为全局最优适应值,

并将其相对应的粒子作为当前全局最优解。

d) 迭代寻优过程开始。根据下列公式调整惯性权重值  $w(t)$  :

$$w(t) = 0.7 * (Maxiter - t) / Maxiter + 0.4 \quad (18)$$

e) 根据公式(17)、(18)更新速度和位置向量; 判断速度向量是否满足约束条件  $-v^{max} \leq v_{id} \leq v^{max}$ , 若不满足则将速度值  $v_{id}$  更新为  $v_{id} = -v^{max}$ , 如果  $v_{id} \leq -v^{max}$ ; 或者  $v_{id} = v^{max}$ , 如果  $v_{id} \geq v^{max}$ 。

f) 将更新后的参数  $C$  和  $c$  的值重新代入 PSO-RSVR 模型, 并根据(1)所叙述的过程重新进行 RSVR 的训练, 保存其输出结果, 计算粒子的适应值。

g) 将 2. f) 中的适应值与当前的粒子适应值作比较, 如果优于当前的粒子适应值, 则更新当前的粒子适应值, 并将当前的粒子相对应的个体最优值更新为与 2. f) 中适应值相对应的粒子值。

h) 如果当前的粒子适应值优于全局最优适应

值, 则更新全局最优适应值为当前的粒子适应值, 并更新全局最优解为当前的粒子适应值所对应的粒子值。

i) 判断是否满足停止条件(迭代 20 次), 若满足则终止迭代, 否则返回 d)。

(3) 输出最优解。

(4) 结束算法。

## 4 算例分析

### 4.1 选择训练数据

中长期负荷预测以年为单位进行预测, 本文采用某地区经济及电网的年负荷原始数据如表 1 所示。由于各地气候差异太大, 本文暂未考虑气候情况。

### 4.2 预测结果

利用训练后的模型来预测 2004 到 2007 年的负荷, 下面我们以该地区供电量为例, 运用以上介绍的方法进行供电总量预测, 并将预测效果与其他几种预测方法进行分析比较。如表 2 所示。

表 1 某地区 1996~2007 年经济和负荷数据

Tab.1 1996-2007 economic and load data in a region

年份	GDP/亿元	地区人口/万人	第一产业产值/亿元	第二产业产值/亿元	第三产业产值/亿元	人均耗电量/kW·h	全社会用电量/万 kW·h
1996	44.62	68.57	5.75	24.85	10.01	3 964.99	271 880
1997	47.58	68.84	6.19	26.51	11.80	4 438.31	305 533
1998	49.95	69.17	6.56	28.46	12.85	5 156.17	356 680
1999	52.04	69.36	6.42	30.55	14.38	5 750.81	398 876
2000	54.68	69.51	6.70	33.54	15.60	6 269.16	435 769
2001	55.30	69.66	6.90	32.00	16.40	6 364.31	443 338
2002	58.00	70.04	6.80	31.50	19.70	6 357.95	445 311
2003	69.00	72.78	7.00	40.00	22.00	7 486.11	544 839
2004	89.80	72.62	8.10	56.80	24.90	12 045.43	874 739
2005	109.53	73.23	8.68	68.87	31.98	11 655.81	853 555
2006	129.49	73.01	9.31	84.60	35.58	14 349.55	1 047 661
2007	162.97	73.04	11.39	110.56	41.02	16 934.14	1 236 139

表 2 各模型对历史年供电量拟合结果一览表 单位: 万千瓦时

Tab.2 Fitting capacity in the history of every model

年份	实际值	PSO-RSVR	SVR	一阶灰色	灰色等维新息	指数曲线	二次滑动平均
2004	874 739	885 498	837 912	828 028	885 673	898 794	834 676
2005	853 555	847 153	834 264	885 563	845 190	818 879	899 817
2006	1 047 661	1 056 776	1 069 976	1 003 240	1 058 347	1 101 091	1 079 300
2007	1 236 139	1 228 351	1 196 088	1 194 728	1 225 384	1 263 457	1 263 458
平均相对误差	-	0.008 7	0.029 5	0.041 7	0.010 3	0.035 3	0.047 8

以上误差对比结果可以看出, 基于 PSO-RSVR 预测法的平均相对误差为 0.008 7 小于其他各种预

测方法。所以可以一定程度上降低预测时的风险, 适用于电力投资规划决策的谨慎性要求。

为了能进行直观对比,给出了各模型对规划年(2008~2012)供电量预测结果的曲线图。如图2所示。

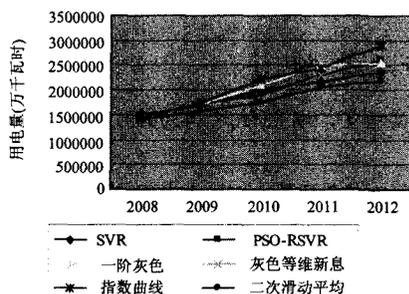


图2 各模型预测结果曲线对比图

Fig.2 Forecasting curve comparison chart

## 5 结论

中长期电力负荷预测是城市电网规划中的基础性工作,也是电力系统安全经济运行的前提,其预测精度的高低直接影响到城市电网规划质量的优劣。本文提出基于粒子群优化算法改进的鲁棒支持向量机的中长期负荷预测方法,通过算例分析验证了该方法可以极大地提高负荷预测的精度。

## 参考文献

- [1] 牛东晓,曹树华,赵磊,等. 电力负荷预测技术及其应用[M]. 北京:中国电力出版社,1998.  
NIU Dong-xiao,CAO Shu-hua,ZHAO Lei,et al. Load Forecasting Technology and Its Applications[J]. Beijing: China Electric Power Press, 1998.
- [2] 肖国泉,王春,张福伟. 电力负荷预测[M]. 北京:中国电力出版社,2001.  
XIAO Guo-quan,WANG Chun,ZHANG Fu-wei.Load Forecasting[M]. Beijing: China Electric Power Press, 2001.
- [3] Vapnik N. The Nature of Statistical Learning Theory[M]. Newyork: Springer-Verlag, 1995.
- [4] Smola A,Scholkopf B. A Tutorial on Support Vector Regression[R].London: Royal Holloway Coll,Univ, 1998.
- [5] Chen Bo-juen, Chang Ming-wei, LIN Chih-jen.Load Forecasting Using Support Vector Machines:a Study on EUNITE Competition[J].2004,19(4):1821-1830.
- [6] Mohandes M.Support Vector Machines for Short-term Electrical Load Forecasting[J]. International Journal of Energy Research, 2002,26(4): 335-345.
- [7] 靳忠伟,陈康民,闫伟,等.基于支持向量机的中长期负荷预测研究与应用[J].上海理工大学学报,2008,(2):31-34.  
JIN Zhong-wei,CHEN Kang-min,YAN wei, et al. Study and Application of Support Vector Machine to Forecast Mid-long-term Electric Power Load[J]. J of University of Shanghai for Science and Technology,2008,(2):31-34.
- [8] ZHANG Hao-ran,WANG Xiao-dong,ZHANG Chang-jiang, et al.A New Support Vector Mahine for Data Mining[J]. New York: Springer-Verlag,2005.
- [9] Kennedy J, Eberhart R.Particle Swarm Optimization[A]. in: Proceeding of IEEE Int Conf on Neural Networks[C]. Piscataway: 1995.1942-1948.
- [10] Eberhart R, Kennedy J. A New Optimizer Using Particle Swarm Theory[A].in: Proc 6<sup>th</sup> Int.Symposium on Micro Machine and Human Science[C].Nagoya: 1995.39-43.
- [11] 邓乃扬,田英杰. 数据挖掘中的新方法-支持向量机[M]. 北京:科学出版社,2004.  
DENG Nai-yang,TIAN Ying-jie. The New Data Mining Method-support Vector Machine[M]. Beijing: Science Press,2004.
- [12] Mangasarian O L, Musicant D R.Lagrangian Support Vercor Machines[J].Journal of Machine Learning Research, 2001,1(1):161-177.

收稿日期: 2008-11-04; 修回日期: 2008-12-30

作者简介:

张雪君(1982-),女,硕士研究生,从事电力系统及其自动化,负荷预测方向研究; E-mail: xiaofeizxj@163.com

陈刚(1964-),男,副研究员,硕士生导师,主要从事电力系统运行与控制、微机在电力系统中的应用、电力MIS系统及负荷预测方向研究;

周杰(1984-),男,硕士研究生,从事电力系统及其自动化,负荷预测方向研究。

(上接第20页 continued from page 20)

- [7] 丁明,罗初田. LOLE指标的参数不确定性分析[J]. 合肥工业大学学报(自然科学版), 1991,14(1):105-112.  
DING Ming, LUO Chu-tian.Uncertainty Analysis for LOLE Index[J]. Journal of Hefei University of Technology(Natural Science), 1991,14(1):105-112.
- [8] 郭永基. 电力系统可靠性原理和应用[M].北京:清华大学出版社,1986.  
GUO Yong-ji. Reliability Theory and Application of Power System[M]. Beijing: Tsinghua University Press, 1986.
- [9] Reliability Test System Task Force. IEEE Reliability Test System[J]. IEEE Trans on Power Apparatus and Systems, 1979,98 (6): 2047-2054.

收稿日期: 2008-11-14; 修回日期: 2009-01-14

作者简介:

万军平(1979-),男,本科,主要研究方向为继电保护和电力系统运行,可靠性分析等。E-mail: srf05@mails.tsinghua.edu.cn