

文章编号: 1006-4710(2013)02-0176-06

基于改进 PSO-LSSVM 的风电场短期功率预测

余健明, 马小津, 倪峰, 王小星

(西安理工大学 自动化学院, 陕西 西安 710048)

摘要: 风速和风电场功率预测是风电场稳定运行及系统调度的重要保障, LSSVM 在保持 SVM 的基础上, 可以降低计算复杂性, 加快求解速度, 为风速及功率预测提供了一个新的研究方向。本研究将最小二乘支持向量机(LSSVM)用于风电场短期风速及风电场功率预测, 提出了基于 LSSVM 的风电场短期风速及功率预测模型, 同时建立改进粒子群模型对 LSSVM 进行参数优化, 以内蒙古某风电场实测数据为例进行验证, 实例验证表明, 改进的 PSO-LSSVM 模型的预测效果最优。

关键词: 最小二乘支持向量机(LSSVM); 风速; 功率; 预测; 风电场; 粒子群(PSO)

中图分类号: TM712

文献标志码: A

Short-Term Power Forecasting of Wind Farm Based on an Improved PSO-LSSVM

YU Jianming, MA Xiaojin, NI Feng, WANG Xiaoxing

(Faculty of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Wind speed and wind farm power forecasting are an important guarantee of stable operation and system scheduling for wind farm, while LSSVM can reduce the computation complexity, sped up solution speed in the foundation of SVM, provide a new research direction for the wind power forecast. This research uses LSSVM to the wind farm short-term wind speed and power forecasting, and proposes wind farm short-term wind speed and power forecast based on the LSSVM. Simultaneously, establishes the improvement PSO model to carry on the optimization to the LSSVM parameter, and carries on the confirmation test by taking the Inner Mongolian some wind farm measured data as the example, the example confirmation tests indicate that the forecast effect of improved PSO-LSSVM model is optimum.

Key words: least squares support vector machine; wind speed; power; forecast; wind farm; particle swarm optimization

大规模并网风电场对电力系统带来一些新问题, 其中很重要的一方面是对电力系统运行调度的影响^[1]。因而, 风电场功率预测对电力系统的功率平衡和经济调度具有非常重要的意义。

目前, 常用的风电场功率预测方法主要有: 持续预测法^[2]、卡尔曼滤波法^[3-4]、随机时间序列法^[4-5]、灰色预测^[6]、人工神经网络法^[5-8]、空间相关性法^[7]、支持向量机^[9-11](SVM)等。SVM 的基本思想是通过一个非线性映射, 把样本空间映射到一个高维特征空间, 然后基于结构风险最小化原则在高维特征空间中应用线性学习机的方法解决样本空间中的高度非线性分类和回归等问题。该算法是一个凸二次规划问题, 能确保找到问题的全局最优解。而 LSSVM 在保持 SVM 的基础上, 降低了计算复杂性,

加快了求解速度, 为风功率预测方法提供了一个新的研究方向^[12-13]。

应用 LSSVM 模型预测内蒙古某风电场未来 3 小时的风速及发电功率。对样本数据进行了预处理, 选择输入样本, 对核函数的选择进行分析, 建立了 LSSVM 数学模型。以内蒙古某风电场实测数据为例进行验证, 预测精度较高。同时, 考虑到模型参数的选择对预测精度的重要影响, 建立了改进粒子群模型对 LSSVM 参数进行优化, 实例验证表明, 改进 PSO-LSSVM 模型的预测效果明显提高。

1 LSSVM 原理和改进 PSO 原理

1.1 LSSVM 原理

LSSVM 是标准 SVM 的一种扩展。按结构最小

收稿日期: 2012-10-10

作者简介: 余健明, 男, 教授, 研究方向为配电网自动化和电能质量。E-mail: jianmingyu@xaut.edu.cn。

化原理,LSSVM 优化目标可表示为:

$$\min \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{1}{2}\gamma \sum_{i=1}^l e_i^2 \quad (1)$$

$$s. t. \boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_i) + b + e_i = y_i, i = 1, \dots, l$$

式中, $\boldsymbol{\omega}$ 是权向量, b 是偏置值, $\boldsymbol{\varphi}(\cdot)$ 为线性映射,将输入向量映射到一个高维空间、 \mathbf{x}_i 为输入量、 y_i 为输出量。 e_i 为误差, γ 为正则化参数。引入 Lagrange 乘子, $\boldsymbol{\lambda} \in \mathbf{R}^{l \times 1}$,式(1)转化为:

$$\min J = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \frac{1}{2}\gamma \sum_{i=1}^l e_i^2 - \sum_{i=1}^l \lambda_i (\boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_i) + b + e_i - y_i) \quad (2)$$

由 KKT 条件,得:

$$\begin{cases} \frac{\partial J}{\partial \boldsymbol{\omega}} = 0 \rightarrow \boldsymbol{\omega} = \sum_{i=1}^l \lambda_i \boldsymbol{\varphi}(\mathbf{x}_i) \\ \frac{\partial J}{\partial b} = 0 \rightarrow \sum_{i=1}^l \lambda_i = 0 \\ \frac{\partial J}{\partial e_i} = 0 \rightarrow \lambda_i = \gamma e_i, i = 1, 2, \dots, l \\ \frac{\partial J}{\partial \lambda_i} = 0 \rightarrow \boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_i) + b + e_i - y_i = 0, \\ i = 1, 2, \dots, l \end{cases} \quad (3)$$

消去 $\boldsymbol{\omega}$ 和 e ,则式子(3)的解为:

$$|y(d, t) - \overline{y(t)}| > \theta$$

则:

$$y(d, t) = \begin{cases} \overline{y(t)} + \theta y(d, t) > \overline{y(t)} \\ \overline{y(t)} - \theta y(d, t) < \overline{y(t)} \end{cases} \quad (4)$$

式中, $\bar{\boldsymbol{\lambda}} = [\lambda_1, \lambda_2, \dots, \lambda_l]^T$, $\bar{\mathbf{I}} = [1, 1, \dots, 1]^T$ 为 l 维列向量, $\mathbf{Y} = [y_1, y_2, \dots, y_l]^T$, $\boldsymbol{\Omega} \in \mathbf{R}^{l \times l}$, $\Omega_{ij} = \boldsymbol{\varphi}(\mathbf{x}_i)^T * \boldsymbol{\varphi}(\mathbf{x}_j) = K(\mathbf{x}_i, \mathbf{x}_j)$, K 为满足 Mercer 条件的核函数, $K(\mathbf{x}_i, \mathbf{x}_j) = \boldsymbol{\varphi}(\mathbf{x}_i)^T \boldsymbol{\varphi}(\mathbf{x}_j)$ 。因此非线性预测模型的表达式为:

$$y = \sum_{i=1}^l \lambda_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (5)$$

式中, $K(*, *)$ 表示从输入空间到高维特征空间的非线性映射。

对于 LSSVM 来说,在确定选用高斯径向基核函数的条件下,需要选取的参数只有超参数 γ 和核函数中的 σ 。 γ 过小,训练误差变大,学习机器的推广能力有所提高,反之,训练误差变小,推广能力变差。小的 σ 意味着核更易局部化,有过训练的危险,而大 σ 容易造成欠训练。所以,为了使 LSSVM 有更好的预测精度,采用粒子群优化算法对这些参数进行优化选取。

1.2 粒子群算法优化原理

针对 LSSVM,标准粒子群算法优化的思想是,

将 LSSVM 中需要选择的参数 γ 和 σ 看作两个粒子,这两个粒子不断的更新位置和速度,并由目标函数计算其适应度值,从而达到全局最优,即得到 γ 和 σ 的最优值。

1.2.1 标准粒子群算法

假设在一个 d 维的搜索空间中,有 m 个粒子,其中第 i 个粒子表示为一个 d 维的向量 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id})$, $i = 1, 2, \dots, m$ 。第 i 个粒子的飞行速度记为 $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{id})$,第 i 个粒子至今为止搜索到的最优位置为 $\mathbf{p}_i = (p_{i1}, p_{i2}, \dots, p_{id})$,整个种群至今为止搜索到的最优位置为 $\mathbf{p}_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ 。

标准粒子群优化算法对粒子速度和位置进行更新的公式为:

$$v_{id} = wv_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{id}) \quad (6)$$

$$x_{id} = x_{id} + v_{id} \quad (7)$$

式中, w 为惯性权重系数, c_1 和 c_2 是两个非负常数,称为加速常数, c_1 较大时,粒子会过多的在局部范围徘徊, c_2 较大时,粒子会过早收敛到局部最小值, r_1 和 r_2 是 $[0, 1]$ 之间的随机数^[14,15]。

1.2.2 改进粒子群优化理论

针对粒子群的早熟收敛问题,通过控制种群多样性来提高算法总体性能。具体实现包括选取初始种群和判断早熟收敛两个方面。

1) 选取初始种群

初始种群是一个粒子速度和位置在一定范围内的随机矩阵。理想状况下其位置应遍布整个解空间以增加搜索到全局最优解的概率。但是粒子的个数是有限的,解空间又相对较大,如果不能保证有限个粒子均匀分布在解空间,就加大了陷于局部最优的可能。平均粒距表示种群中各个粒子彼此间分布的离散程度, $D(t)$ 越小,表示种群越集中, $D(t)$ 越大,表示种群越分散。 $D(t)$ 应该不小于某个给定的阈值 α ,从而尽可能使粒子的轨迹遍历搜索区间。为此,引入平均粒距的概念,定义为:

$$D(t) = \frac{1}{mL} \sum_{i=1}^m \sqrt{\sum_{d=1}^n (p_{id} - \overline{p_d})^2} \quad (8)$$

式中, L 为搜索空间对角最大长度, m 为种群规模, n 为解空间维数, p_{id} 表示第 i 个粒子位置的第 d 维坐标值, $\overline{p_d}$ 表示所有粒子位置的第 d 维坐标值的均值。

2) 判断早熟收敛

标准粒子群算法随着种群的不断进化,粒子个体之间的差异越来越小,粒子位置决定粒子适应度

的大小。因此,根据种群中所有粒子适应度的整体变化可以判断出种群当前所处的状态。若设第 i 个粒子当前的适应度为 f_i , 种群当前的平均适应度为 \bar{f} , 则可定义种群的适应度方差为:

$$\rho^2 = \sum_{i=1}^m \left(\frac{f_i - \bar{f}}{f} \right)^2 \quad (9)$$

式中, m 为种群粒子数目, f 为归一化定标因子, 用来限制 ρ^2 的大小, 取值公式为:

$$f = \begin{cases} \max |f_i - \bar{f}|, \max |f_i - \bar{f}| > 1 \\ 1, & \text{其它} \end{cases} \quad (10)$$

适应度方差反映的是种群中粒子的聚集程度, σ^2 越小, 则种群中粒子的聚集程度越大, 反之, 则聚集程度越小。随着迭代次数的增加, 种群中粒子的适应度会越来越接近, σ^2 就会越来越小。当 $\sigma^2 < \beta$ (β 为某一给定的阈值) 时, 认为算法进入后期搜索阶段, 此时种群容易陷入局部最优而出现早熟收敛现象。

前述提到的平均粒距从空间角度反映各个粒子之间的分布离散程度, 而种群的适应度方差从适应度函数值方面反映了粒子的分布情况。寻优过程中常出现这样的情况, 即: 当种群收敛于若干个分散的局部极小点时, 这几个极小点对应的适应值相差并不大, 则此时种群的平均粒距很大, 适应度方差却很小。因此, 同时采用这两个指标衡量种群的多样性, 对种群是否早熟陷入停滞进行判断。

2 预测模型

2.1 输入变量选择

风力机捕获的功率可以表示为:

$$P = \frac{1}{2} C_p A \rho v^3$$

式中, P 为风轮输出功率, C_p 为风轮的功率系数, ρ 为空气密度, A 为风轮扫掠面积, v 为风速。风力机捕获的功率受到多个因素的影响, 作风速预测以及发电功率预测时应考虑各因素的变化。同时, 由于风电场数据条件有限, 只能获取少量数据, 因而依据地理和气候特征选取代表性的风电机组, 以该机组的运行状况代表该片区风电机组的运行状况。选取的输入向量为:

① 风速预测的输入量, 即: 预测点前十分钟的平均温度、平均风速、最大、最小风速、发电功率; 预测点前二十分钟的平均风速、最大、最小风速; 预测点的平均温度、发电功率。

② 风电功率预测的输入量, 即: 预测点前十分钟

的平均风速、最大、最小风速、平均温度、发电功率; 预测点前二十分钟的发电功率; 预测点的平均温度、平均风速、最大、最小风速。

2.2 核函数的选择

常用的核函数有线性核函数、多项式核函数、径向基核函数、Sigmoid 核函数、傅立叶核函数。

对于多项式核函数, 当特征空间维数很高时, 计算量激增, 甚至对某些情况不能得到正确结果。由于核参数能够反映模型选择的复杂度, 而且它直接反映两个数据的距离, 易于数值计算, 不存在无穷大点和奇异点的问题。RBF 核函数是一个普适的核函数, 通过参数的选择, 可以适用任意分布的样本。因此, 在进行风速及风电功率预测时也选择高斯径向基核函数。具体形式为:

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / \sigma^2)$$

式中, \mathbf{x} 是 m 维输入向量, \mathbf{x}_i 是第 i 个径向基函数的中心, 与 \mathbf{x} 具有相同维数, σ 是标准化参数, 决定了该函数围绕中心点的宽度, $\|\mathbf{x} - \mathbf{x}_i\|$ 是向量 $\mathbf{x} - \mathbf{x}_i$ 的范数, 表示 \mathbf{x} 与 \mathbf{x}_i 之间的距离。

2.3 数据预处理

① 风速归一化

对风速的归一化可不必拘泥, 本研究采用风速归一化方法为:

$$v_g = \frac{v_i - v_{\min}}{v_{\max} - v_{\min}}$$

式中, v_i 是归一化前风速值, v_g 是归一化后风速值。温度的归一化依此方法进行。

② 风向归一化

单取风向的正弦值或余弦值不能完全区分 $0^\circ \sim 360^\circ$ 的所有风向, 因此, 风向归一化后为两个值, 一个为风向的正弦值, 一个为余弦值。

③ 功率归一化

功率的归一化取常用对数, 即:

$$p_g = \lg(p_i)$$

式中, p_i 风电场单台风机的实测功率, p_g 是单台风机归一化后的功率。

3 仿真分析

3.1 风速预测

3.1.1 LSSVM 风速预测

仿真环境为 MATLAB2008a, 选用高斯径向基核函数。以内蒙古风电场 2011 年 9 月 13 日的实测数据为例, 时间间隔为 10 min, 预测未来 3 h 风速。预测结果采用平均绝对百分比误差 (MAPE) 描述, 仿真结果见图 1。平均绝对百分比误差定义为:

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{L_i - \hat{L}_i}{L_i} \right| \times 100\%$$

式中, L 、 \hat{L} 分别为实际风速和预测风速。 n 是风速数据的个数。




图1 LSSVM 风速预测曲线

Fig. 1 Curves of LSSVM wind speed forecast

由图1中可以看出,采用LSSVM预测模型的平均绝对百分比误差为6.05%,误差除数据样本不够完善之外,也跟模型输入参数有很大关系。

3.1.2 改进 PSO-LSSVM 模型风速预测

设定惩罚系数和核函数参数搜索范围为 $C \in [0.1, 100]$, $\sigma \in [0, 10]$ 。粒子数 m 取 20, 最大迭代次数 T_{max} 取 100。惯性权重系数 w 取值范围选作 $[0.4, 0.9]$ 。通过仿真分析, c_1 和 c_2 均为 2 时, 预测效果最好。输入指标、训练样本和 LSSVM 模型中的相同。改进 PSO-LSSVM 优化的风速仿真结果见图 2。




图2 改进 PSO-LSSVM 风速预测曲线

Fig. 2 Curves of improved PSO-LSSVM wind speed forecast

可以看出,经过参数优化,预测模型的精度提高到 5.21%,整体预测效果较好,无较大偏移。

3.2 风电场功率预测

3.2.1 LSSVM 风功率预测

仿真环境、训练样本和 LSSVM 风速预测相同。预测该风电场未来 3 h 发电功率。预测结果见图 3。

表 1 是 LSSVM 功率预测的统计分析结果。

从预测结果对比分析可见,采用 LSSVM 功率预测的平均绝对误差为 8.98%,最大误差达到 26.84%。功率预测误差较风速误差大,因为风速在经过功率特性曲线转换后,规律性被部分破坏,得到

的发电功率规律性更弱。其次,跟基础数据不完善和模型参数的选择有关系。




图3 LSSVM 功率预测曲线

Fig. 3 Curves of LSSVM power forecast

表1 预测误差比较

Tab. 1 Comparison of forecast error

序号	真实值/ kW	预测值/ kW	平均绝对 误差/%
1	579.1	669.4	15.59
2	705.0	701.5	0.49
3	936.5	887.1	5.28
4	708.0	757.5	6.99
5	632.7	802.5	26.84
6	631.5	663.7	5.10
7	706.8	815.7	15.41
8	613.9	584.7	4.76
9	561.4	661.7	17.87
10	672.1	657.5	2.17
11	795.3	868.2	9.17
12	580.6	635.4	9.43
13	571.8	619.3	8.31
14	598.1	630.8	5.46
15	714.7	726.5	1.64
16	953.6	857.5	10.08
17	838.8	826.6	1.45
18	852.3	720.2	15.49

3.2.2 改进 PSO-LSSVM 风电功率预测

仿真环境、训练样本和改进 PSO-LSSVM 风速预测相同。改进 PSO-LSSVM 优化后的功率预测结果如图 4 所示。

表 2 是改进 PSO-LSSVM 功率预测的分析结果。

预测结果显示,改进 PSO-LSSVM 模型具有更强的寻优能力和较高的搜索精度。预测模型的平均绝对误差为 7.04%,较 LSSVM 模型有明显提高。




图4 改进 PSO-LSSVM 功率预测曲线

Fig.4 Curves of improved PSO-LSSVM power forecast

表2 预测误差比较

Tab.2 Comparison of forecast error

序号	真实值/ kW	预测值/ kW	平均绝对 误差/%
1	579.1	660.9	14.12
2	705.0	671.7	4.73
3	936.5	846.8	9.58
4	708.0	723.1	2.13
5	632.7	675.2	6.72
6	631.5	628.8	0.43
7	706.8	752.9	6.52
8	613.9	572.7	6.72
9	561.4	611.8	8.98
10	672.1	622.6	7.37
11	795.3	795.3	0.003
12	580.6	598.4	3.06
13	571.8	592.3	3.58
14	598.1	597.8	0.05
15	714.7	671.2	6.09
16	953.6	827.2	13.26
17	838.8	759.6	9.44
18	852.3	628.1	26.30

表3列出了应用改进 PSO-LSSVM 算法对多个样本进行预测的结果。结果表明,改进 PSO-LSSVM 算法对不同训练样本的收敛性和稳定性是一致的。

表3 不同训练样本预测结果

Tab.3 Results of different Samples

日期	2011.9.13	2011.9.14	2011.10.21	2012.2.24	2012.2.25
误差/%	7.17	5.68	12.09	9.78	17.34
平均 误差/%	10.412				

针对不同样本,采用本研究预测模型所得平均误差为 10.412%,精度均高于表4所列的文献。可

以看出,本研究方法用于风速及发电功率的预测是可行的。

表4 不同算法下的预测结果比较

Tab.4 Comparisons of forecasting result with different algorithm

算法	卡尔曼 滤波 ^[2]	SVM ^[3]	改进持 续法 ^[11]	本研究 方法
平均绝对 百分比 误差/%	11.32	10.84	11.81	10.412

4 结论

1) 在 LSSVM 预测模型的基础上,加入粒子群优化算法,针对粒子群的局部最优和早熟收敛问题,提出了改进 PSO-LSSVM 模型;

2) 实例研究结果表明,训练样本及模型参数的选取对预测结果的影响很大;

3) 改进 PSO-LSSVM 模型对风速及风电功率预测都能够有效提高精度;

4) 针对风电场短期功率预测而言,不同的训练样本情况下,该方法的收敛性和稳定性是一致的。

参考文献:

- [1] 范高锋,刘纯,王伟胜,等. 风电功率预测的多扇区 BP 神经网络模型[C]//中国电机工程学会年会论文集. 天津,2009.
Fan Gaofeng, Liu Chun, Wang Weisheng, et al. Wind power prediction based on multi-sector BP neural network model[C]//Chinese Society of Electrical Engineering Annual Meeting Papers. Tianjin, China,2009.
- [2] 李丽,叶林. 基于改进持续法的短期风电功率预测[J]. 农业工程学报,2010,26(12):182-187.
Li Li, Ye Lin. Short-term wind power forecasting based on an improved persistence approach[J]. Transactions of the CSAE,2010, 26(12): 182-187.
- [3] 赵攀,戴义平,夏俊荣,等. 卡尔曼滤波修正的风电场短期功率预测模型[J]. 西安交通大学学报,2011, 45(5): 47-51.
Zhao Pan, Dai Yiping, Xia Junrong, et al. A kalman filter based correction model for short term wind power prediction [J]. Journal of Xi'an JiaoTong University, 2011, 45(5): 47-51.
- [4] 王健,严干贵,宋薇,等. 风电功率预测技术综述[J]. 东北电力大学学报,2011,31(3):20-24.
Wang Jian, Yan Gangui, Song Wei, et al. Review wind power prediction[J]. Journal of Northeast Dianli University,2011, 31(3): 20-24.
- [5] 杨秀媛,肖洋,陈树勇. 风电场风速和发电功率预测研究[J]. 中国电机工程学报,2005,25(11):1-5.

- Yang Xiuyuan, Xiao Yang, Chen Shuyong. Wind speed and generated power forecasting in wind farm[J]. Proceedings of the CSEE, 2005, 25(11):1-5.
- [6] 李俊芳,张步涵,谢光龙,等. 基于灰色模型的风速-风电功率预测研究[J]. 电力系统保护与控制, 2010, 38(19):151-159.
- Li Junfang, Zhang Buhuan, Xie Guanglong, et al. Grey predictor models for wind speed-wind power prediction[J]. Power System Protection and Control, 2010, 38(19):151-159.
- [7] 王颖,魏云军. 风电场风速及风功率预测方法研究综述[J]. 陕西电力, 2011, 39(11):18-21, 30.
- Wang Ying, Wei Yunjun. Review on forecasting model of wind speed and wind power[J]. Shaanxi Electric Power, 2011, 39(11):18-21, 30.
- [8] Han Shuang, Yang Yongping, Liu Yongqian. The comparison of BP network and RBF network in wind power prediction application[J]. IEEE, 2007, 16(5):173-176.
- [9] Shi Jie, Liu Yongqian, Yang Yongping, et al. The research and application of wavelet-support vector machine on short-term wind power prediction[C]//The World Congress on Intelligent Control and Automation (WCICA). Beijing, 2010.
- [10] 栗然,柯拥勤,张孝乾,等. 基于时序-支持向量机的风电场发电功率预测[J]. 中国电力, 2012, 45(1):64-68.
- Li Ran, Ke Yongqian, Zhang Xiaoqian, et al. Wind power forecasting based on time series and SVM[J]. Electric Power, 2012, 45(1):64-68.
- [11] 戚双斌,王维庆,张新燕. 基于支持向量机的风速与风功率预测方法研究[J]. 华东电力, 2009, 37(9):1600-1603.
- Qi Shuangbin, Wang Weiqing, Zhang Xinyan. Wind speed and wind power prediction based on SVM[J]. East China Electric Power, 2009, 37(9):1600-1603.
- [12] Wang Xiaolan, Li Hui. One-month ahead prediction of wind speed and output power based on EMD and LSSVM[C]//International Conference on Energy and Environment Technology. Lanzhou, China, 2009.
- [13] 李智,韩学山,韩力,等. 地区电网风电场功率超短期预测方法[J]. 电力系统自动化, 2010, 34(7):90-94.
- Li Zhi, Han Xueshan, Han Li, et al. An ultra short term wind power forecasting method in regional grids[J]. Automation of Electric Power Systems, 2010, 34(7):90-94.
- [14] 杨志凌,刘永前. 应用粒子群优化算法的短期风电功率预测[J]. 电网技术, 2011, 35(5):159-164.
- Yang Zhiling, Liu Yongqian. Short-term wind power prediction with particle swarm optimization[J]. Power System Technology, 2011, 35(5):159-164.
- [15] Pousinho H M I, Catalão J P S, Mendes V M F. Wind power short-term prediction by a hybrid PSO-ANFIS approach[C]//Mediterranean Electrotechnical Conference. Beira Interior, 2010.

(责任编辑 李虹燕)