

基于云支持向量机模型的短期风电功率预测

凌武能, 杭乃善, 李如琦

(广西大学 电气工程学院, 广西 南宁 530004)

摘要: 将云模型和支持向量机(SVM)相结合, 提出一种适合短期风电功率预测的云支持向量机模型。该模型采用云变换方法提取风速序列的定性特征, 并通过 SVM 建立风速特征与风电功率间的关系。对未来 24 h 的风电功率预测结果显示, 该模型在某个点上的预测值是一个有稳定倾向的离散值集合。采用逆向云算法求取集合的期望值作为确定性预测结果, 并与 SVM 和自回归求和移动平均 (ARIMA) 模型的预测结果相比较, 结果表明云支持向量机具有更高的预测精度, 预测效果显著, 因此, 该模型可有效应用于短期风电功率预测。

关键词: 风电; 预测; 云模型; 云变换; 支持向量机

中图分类号: TM 614

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2013.07.006

0 引言

风电功率预测是大规模风电接入电力系统的安全保证之一。因此, 众多学者针对这一问题提出了时间序列^[1]、神经网络^[2]、支持向量机 SVM (Support Vector Machine) 和组合预测^[3-4]等风电功率预测方法。其中, SVM 因为泛化能力较强, 已广泛应用在各种短期风电功率预测系统中^[5-10]。文献[5-6]先用小波变换对风速序列进行分解, 再用 SVM 分别对各分解信号进行建模预测, 最后对各预测结果叠加得到最终预测值; 文献[7]先对风速序列进行经验模态分解 EMD (Empirical Mode Decomposition) 得到多个分解序列, 再综合 SVM 对各分解序列的预测结果得到原风速序列的预测风速, 最后利用功率曲线转换得到预测功率; 文献[8]先用 SARIMA (Seasonal Auto-Regression Integrated Moving Average) 模型对风速序列建模, 再通过分段预测得到 $N-1$ 段预测残差, 用最小二乘支持向量机对残差序列建模预测得到第 N 段的残差预测值, 用该值修正第 N 段风速预测值得到最后预测结果; 文献[9]认为采用相似数据来为 SVM 提供训练样本可以提高预测精度; 文献[10]采用蚁群优化算法来解决最小二乘支持向量机模型参数选择问题, 取得了不错的预测效果。

无论如何优化预测模型和改进预测策略, 预测精度的提高都是有限的, 历史数据中固有的随机特征是一个无法忽略的因素。因此, 针对风电功率的随机性和波动性特征, 提出一种云支持向量机模型。该模型引入云理论的云变换方法来挖掘风速的随机特征, 并将这些用 X 条件云表示的风速特征作为 SVM 的输入, 将实测风电功率作为输出, 建模预测未来 24 h 的风电功率。由于云的不确定性特征和良好的趋势预测能力, 使得某个点的预测结果不是一个固

定的预测值, 多次预测将得到一个有稳定倾向的离散点集合。但云理论对风速的特征提取, 使得 SVM 在一定程度上提高了预测精度。

1 云

1.1 云滴和云模型

云由云滴组成, 给定一个由精确数值构成的定量论域 U , c 是定义在这个论域上的定性概念, 任取 $x \in U$, 则 x 对 c 的隶属程度 $y \in [0, 1]$, 是一个有稳定倾向的随机数。取若干个 $x \in U$, 则 x 的分布就构成了云, 每一个 x 称为一个云滴。

云模型一般由 3 个数字特征 (期望、熵、超熵) 来描述。云的期望 (E_x) 是最能代表该定性概念的数值; 熵 (E_n) 反映了该定性概念的模糊程度; 超熵 (H_e) 反映了云的离散程度。如风速的一个定性概念“较快”及其数字特征如图 1 所示。由图可得: $E_x=12.6071$, $E_n=1.5537$, $H_e=0.7271$ 。




图 1 风速的一个定性概念“较快”及其数字特征

Fig.1 “Faster”, a qualitative concept of wind speed, and its numerical characteristics

1.2 风速云变换

云变换是指把风速数据转换成由多个云叠加而成的定性概念。其思想主要采用基于峰值的云变换算法, 即:

$$f(x) = \sum_{i=1}^n (r_i c(E_{xi}, E_{ni}, H_{ei})) + \varepsilon \quad (1)$$

其中, $f(x)$ 为风速数据的频率分布, $c(E_{xi}, E_{ni}, H_{ei})$ 为变换后的其中一个云概念, r_i 为相应云概念的幅度系

数, n 为变换后的云概念的个数, ε 为云变换的误差。数据频率分布的局部最高点(峰值)是数据的汇聚中心,可将它所对应的横坐标作为某个云概念的期望值。峰值越大,表示数据汇集越多,越能反映某个定性概念。

采用某风电场 10 月份的历史数据,则风速的峰值云变换步骤如下。

a. 对风速数据进行归一化处理,即:

$$w_j = \frac{v_j - v_{\min}}{v_{\max} - v_{\min}} \tag{2}$$

其中, $v_j (j=1, 2, \cdots, 500)$ 为归一化前的某一风速值, $v_{\max}$ 、 $v_{\min}$ 分别为统计风速数据的最大风速和最小风速, w_j 为相对于 v_j 的归一化风速值。

b. 求取 w_j 序列的频率分布。以 a 为区间长度,将 w_j 序列分成 b 个区间,分别统计 w_j 落在每个区间内的个数,得到风速数据的频率分布 $f(x)$, 见图 2。




图 2 风速 16 个云概念概率密度期望曲线的叠加
Fig.2 Superposition of 16 expectation curves of cloud concept about wind speed

c. 找到 $f(x)$ 中的各个峰值位置,将峰值大小定义为云的幅度系数 r_i ,并将其对应横坐标定义为云的期望值 $E_{xi} (i=1, 2, \cdots, n)$ 。

d. 采用文献[11]的方法,计算用于拟合 $f(x)$ 的以 E_{xi} 为期望值的各个云概念的熵 E_{ni} ,并计算云概念的概率密度期望函数 $f_i(x)$,将 $f_i(x)$ 作为各个云的分布函数,如图 2 所示。

$$f_i(x) = e^{-(x-E_{xi})^2/(2E_{ni}^2)} \tag{3}$$

e. 用不带确定度的逆向云算法[12]求取各个云概念的超熵 H_{ei} 。

图 2 是经过云变换得到的结果,可以看出此时得到的 16 个云概念还比较粗糙,某些云相距较近,甚至一个云已把另一个云完全包含在内,造成概念的重复和多余,所以有必要对云变换之后的概念进行跃升,使每个云概念的意义更加独立和清晰。

1.3 概念跃升

所谓概念跃升,是指将云变换得到的基本概念作为泛概念树的叶结点,并考虑云之间的幅度系数影响,逐步合并距离最近的 2 个概念,以得到所需概念层次[13]。设相邻 2 个云概念分别为 $c_i(E_{xi}, E_{ni}, H_{ei})$ 和 $c_j(E_{xj}, E_{nj}, H_{ej})$,幅度系数分别为 r_i 和 r_j ,且 $E_{xi} < E_{xj}$,

它们的概率密度期望曲线相交于点 $d(x_d, y_d)$,合并之后的云为 $c_h(E_{xh}, E_{nh}, H_{ch})$,幅度系数为 r_{ho} 。云合并算法如下。

a. 首先计算截断熵:

$$E'_{ni} = \int_{-\infty}^{x_d} r_i e^{-(x-E_{xi})^2/(2E_{ni}^2)} dx \tag{4}$$

$$E'_{nj} = \int_{x_d}^{+\infty} r_j e^{-(x-E_{xj})^2/(2E_{nj}^2)} dx \tag{5}$$

b. 根据截断熵和相邻云的数字特征,得到合并云 c_h 的数字特征。

期望值:

$$E_{xh} = \frac{E_{xi} E'_{ni} + E_{xj} E'_{nj}}{E'_{ni} + E'_{nj}} \tag{6}$$

熵:

$$E_{nh} = \frac{E'_{ni}}{r_i} + \frac{E'_{nj}}{r_j} \tag{7}$$

超熵:

$$H_{ch} = \frac{H_{ei} E'_{ni} + H_{ej} E'_{nj}}{E'_{ni} + E'_{nj}} \tag{8}$$

c. 最后还可以得到合并云 c_h 的幅度系数:

$$r_h = \frac{E'_{ni} + E'_{nj}}{E_{nh}} \tag{9}$$

根据人的认知特点(同时只能认知最多 7 ± 2 个概念[14]),并根据各个云的分布情况,选取疏密合适的概念个数,按照以上云合并算法,最后将风速的 16 个原始概念压缩至 9 个跃升概念。同时可认为风速的定性特征表现为“快”、“很快”等,因此,假设风速的 9 个云概念分别为: {超慢,很慢,慢,较慢,中等,较快,快,很快,超快},则它们的数字特征如表 1 所示。

表 1 风速各个云概念的数字特征
Tab.1 Numerical characteristics of different cloud concepts about wind speed

云概念	期望值	熵	超熵
超慢	0.0530	0.0316	0.0012
很慢	0.2297	0.0456	0.0023
慢	0.3030	0.0166	0.0024
较慢	0.3530	0.0166	0.0024
中等	0.4030	0.0241	0.0017
较快	0.5030	0.0616	0.0054
快	0.6030	0.0166	0.0024
很快	0.7147	0.0755	0.0042
超快	0.9530	0.0730	0.0044

抽离每个云概念的幅度系数,用云滴分布来描述每个云概念的数字特征,并且使用半云(或半梯形云)来描述最接近论域边界的 2 个定性概念,则风速 9 个跃升概念的概率密度期望曲线和云滴分布分别如图 3 和图 4 所示。从图 3 可以看出跃升之后的风速特征更加明显,避免了概念冗余。图 4 的相邻概念之间出现交叠,体现了云模型的不确定性。

1.4 X 条件云

已知论域 U 内的某个特定点 m 和定义在 U 上




图 3 风速 9 个跃升概念的概率密度期望曲线

Fig.3 9 expectation curves of zooming concept about wind speed




图 4 风速 9 个特征概念的云滴分布

Fig.4 Cloud drop distribution of 9 feature concepts about wind speed

的某个定性概念 c_k 的数字特征 (E_{sk}, E_{nk}, H_{ek}) , 而点 m 对 c_k 的隶属度未知, 像这样的云就叫做 X 条件云。通过 X 条件云发生器, 可以求得点 m 对 c_k 的隶属度, 简单算法如下。

a. 生成以 E_{nk} 为期望值、 H_{ek}^2 为方差的一个正态随机数 E'_{nk} 。

b. 计算点 m 对 c_k 的隶属度:

$$h_k = e^{-(m-E_{nk})^2 / [2(E'_{nk})^2]} \quad (10)$$

若 m 是由多个风速值构成的一个样本 (即多维向量), 则根据式 (10) 得到的 h_k 应是一个多维向量。根据极大判定法, 以 h_k 中的最大分量作为该样本 m 对定性概念 c_k 的最终隶属度。

2 云支持向量机

2.1 SVM

根据统计学理论发展起来的 SVM, 利用非线性核函数把输入样本映射到高维空间, 并在高维空间中解决了输入样本的非线性回归问题^[15]。与人工神经网络相比, SVM 训练效率高、泛化能力强, 且不易陷入局部最优, 因此, 它是解决短期风电功率非线性回归问题的有力工具。

2.2 云支持向量机

根据历史数据的原始分布情况, 采用云理论来挖掘数据的本质特征, 并用 X 条件云定性表示该特征。假设 $\{(x_i, y_i), i=1, \dots, N, x_i \in \mathbf{R}^n, y_i \in \mathbf{R}\}$ 为训练样本数据, $c_i (i=1, \dots, K)$ 是表示风速特征的 K 个 X 条件云, 根据 1.4 节, c_i 相对于每个样本 x_i 的输出 h_i 都是一个 n 维向量, 依据云模型的极大判定理论, h_i 中的最大分量 $h_{\max}$ 体现了该风速样本对相应的风速特征的最大激活强度, 则以 $h_{\max}$ 作为该样本 x_i 对风速特

征 c_i 的最终隶属度, 并将其作为 SVM 的训练输入。

2.3 基于云支持向量机的短期风电功率预测方法

常用的预测策略有提前 1 步的滚动预测和提前 N 步的直接预测^[16]等。由于滚动预测会导致误差的累积从而影响预测精度, 本文采用提前 24 步的直接预测法来预测未来 24 h 的风电功率, 并用时间序列模型选择训练的输入变量^[17]。利用计量经济分析软件 EViews 对风速数据进行统计, 得到:

$$x_t = 1.4057x_{t-24} - 0.5712x_{t-25} - 0.1138x_{t-28} + \varepsilon_t \quad (11)$$

其中, x_t 为当前时刻的风速值, x_{t-24} , x_{t-25} 和 x_{t-28} 分别为由 x_t 往前推 24、25 和 28 个时刻的风速值, ε_t 为时间序列模型的拟合残差。

式 (11) 的赤池信息准则 AIC (Akaike's Information Criterion) 结果较理想, 说明该式可以较好地诠释风速数据, 包含了较大的信息量, 也说明当前风速 x_t 和风功率 y_t 受 x_{t-24} , x_{t-25} 和 x_{t-28} 的影响较大, 以它们作为模型的训练输入, y_t 作为训练输出, 以此组成训练样本集将可以提高预测精度。

SVM 采用 v 支持向量机回归模型, 基于云支持向量机模型的短期风电功率预测步骤如下:

- 将风速、风功率的历史数据归一化到 $[0, 1]$;
- 根据 1.2 节的内容对风速数据进行云变换;
- 根据 1.3 节的内容对云变换得到的原始云进行概念跃升, 并得到 K 个 X 条件云 $c_i (i=1, \dots, K)$;
- 根据式 (11) 形成训练样本集 $\{(x_i, y_i), i=1, \dots, N, x_i \in \mathbf{R}^n, y_i \in \mathbf{R}\}$;
- 根据 2.2 节建立风电功率的预测模型;
- 利用该预测模型提前 24 步直接预测未来 24 h 的风电功率 $p'_i (p'_i \in \mathbf{R}, i=1, \dots, 24)$ 。

由于云支持向量机的预测方法本质上是基于云模型的时间序列预测, 因此, 多次运行云支持向量机对某个点进行预测, 模型的输出是服从正态分布的多个云滴^[18-19] (即得到一个小幅波动的离散值集合)。按照文献^[19]方法, 本文采用逆向云算法^[12]求取集合的期望值作为预测点的确定性结果。

3 实例分析

实例分析采用我国某风电场 (风电场 1) 一个月内的 500 组历史数据, 每组数据包含风速和风功率 2 类数据, 数据时间间隔为 1 h。实验中的云支持向量机采用 9 个 X 条件云描述风速特征, 训练样本输入 $x_i \in \mathbf{R}^3$, 输出 $y_i \in \mathbf{R}$, 其中 $i=1, \dots, 472$ 。

利用云支持向量机预测 50 次, 每个预测点都得到由 50 个离散值构成的集合, 采用逆向云算法求取每个集合的期望值作为确定的预测值, 将其结果与单纯使用 ARIMA 模型和 SVM 的预测结果相比较, 如

图 5 所示(图中纵轴为归一化值)。




图 5 未来 24 h 的风电功率预测值与实际值比较图(风电场 1)

Fig.5 Comparison between actual and forecasted wind powers for next 24 hours(wind farm 1)

为了便于分析比较,同时对预测模型的整体性能进行客观评价,定义以下误差指标:

$$\left\{\begin{aligned} e_{\text{MRE}} &= \frac{1}{N} \sum_{i=1}^N \left| \frac{p_i - p'_i}{p_i} \right| \\ e_{\text{MAE}} &= \frac{1}{N} \sum_{i=1}^N |p_i - p'_i| \\ e_{\text{RMSE}} &= \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - p'_i)^2} \end{aligned}\right. \quad (12)$$

其中, e_{MRE} 、 e_{MAE} 和 e_{RMSE} 分别为平均相对误差、平均绝对误差和均方根误差, N 为预测点数, p_i 为风电功率实测值, p'_i 为风电功率预测值。

各预测方法的误差比较如表 2 所示。从指标 e_{MRE} 来看,云支持向量机较 SVM 和 ARIMA 模型分别下降了 9.76% 和 26.79%,总体上显示了较高的预测精度;指标 e_{MAE} 反映了预测误差的平均幅值,云支持向量机在该指标上的表现亦优于 SVM 和 ARIMA,较两者分别下降了 0.027 5 和 0.065 1;指标 e_{RMSE} 衡量了预测误差的分散程度^[20],云支持向量机的 e_{RMSE} 值较 SVM 和 ARIMA 模型分别下降了 3.15% 和 7.07%,可见,云支持向量机的预测误差相对集中,预测结果比较稳定,有利于用户对风电预测值进行分析决策。

表 2 不同预测方法的误差比较(风电场 1)
Tab.2 Comparison of forecast error among different prediction methods(wind farm 1)

预测方法	$e_{\text{MRE}}/\%$	$e_{\text{MAE}}/(\text{h}^{-1})$	$e_{\text{RMSE}}/\%$
云支持向量机	11.68	0.038 0	4.63
SVM	21.44	0.065 5	7.78
ARIMA	38.47	0.103 1	11.70

为了检验云支持向量机的泛化能力,采用另一个风电场(风电场 2)一个月的历史数据,该风电场一共有 58 台风电机组,每台机组的额定输出功率均为 850 kW,对该风电场未来 24 h 的风电功率预测结果如图 6 所示(图中纵轴为归一化值)。云支持向量机与 SVM 和 ARIMA 模型的预测误差比较如表 3 所示。从图 6 和表 3 可以看出,云支持向量机对另一个风电场的功率预测结果依然保持了比 SVM 和 ARIMA 更高的预测精度,具有较强的泛化能力。




图 6 未来 24 h 的风电功率预测值与实际值比较图(风电场 2)

Fig.6 Comparison between actual and forecasted wind powers for next 24 hours(wind farm 2)

表 3 不同预测方法的误差比较(风电场 2)
Tab.3 Comparison of forecast error among different prediction methods(wind farm 2)

预测方法	$e_{\text{MRE}}/\%$	$e_{\text{MAE}}/(\text{h}^{-1})$	$e_{\text{RMSE}}/\%$
云支持向量机	9.21	0.059 2	6.83
SVM	15.18	0.102 4	11.35
ARIMA	24.06	0.157 4	16.69

4 结论

风速是影响风电场出力的主要因素,为此提出云支持向量机模型来提取风速序列的定性特征,进而预测未来 24 h 的风电功率,通过 2 个预测实例得到如下结论:

- a. 云理论可以有效挖掘风速的随机特征,进而增强了后期 SVM 的预测输入数据的规律性,并为 SVM 的精确预测提供了坚实基础;
- b. 云支持向量机的预测精度较传统 SVM 方法有所提高,预测误差相对集中,有利于风电调度的分析决策;
- c. 云支持向量机保持了 SVM 原有的泛化能力,可用于未来 24 h 的短期风电功率确定性预测。

参考文献:

[1] 丁明,张立军,吴义纯. 基于时间序列分析的风电场风速预测模型[J]. 电力自动化设备,2005,25(8):32-34.
DING Ming,ZHANG Lijun,WU Yichun. Wind speed forecast model for wind farms based on time series analysis[J]. Electric Power Automation Equipment,2005,25(8):32-34.
[2] 李文良,卫志农,孙国强,等. 基于改进空间相关法和径向基神经网络的风电场短期风速分时预测模型[J]. 电力自动化设备,2009,29(6):89-92.
LI Wenliang,WEI Zhinong,SUN Guoqiang,et al. Multi-interval wind speed forecast model based on improved spatial correlation and RBF neural network[J]. Electric Power Automation Equipment,2009,29(6):89-92.
[3] 刘纯,范高锋,王伟胜,等. 风电场输出功率的组合预测模型[J]. 电网技术,2009,33(13):74-79.
LIU Chun,FAN Gaofeng,WANG Weisheng,et al. A combination forecasting model for wind farm output power[J]. Power System Technology,2009,33(13):74-79.
[4] 陈宁,沙倩,汤爽,等. 基于交叉熵理论的风电功率组合预测方法[J]. 中国电机工程学报,2012,32(4):29-34.

- CHEN Ning, SHA Qian, TANG Yi, et al. A combination method for wind power prediction based on cross entropy theory [J]. Proceedings of the CSEE, 2012, 32(4): 29-34.
- [5] 彭春华, 刘刚, 孙惠娟. 基于小波分解和微分进化支持向量机的风电场风速预测[J]. 电力自动化设备, 2012, 32(1): 9-13.
- PENG Chunhua, LIU Gang, SUN Huijuan. Wind speed forecasting based on wavelet decomposition and differential evolution-support vector machine for wind farms[J]. Electric Power Automation Equipment, 2012, 32(1): 9-13.
- [6] 张华, 郁永静, 冯志军, 等. 基于小波分解与支持向量机的风速预测模型[J]. 水力发电学报, 2012, 31(1): 208-212.
- ZHANG Hua, YU Yongjing, FENG Zhijun, et al. Wind speed forecasting model based on wavelet decomposition and support vector machine[J]. Journal of Hydroelectric Engineering, 2012, 31(1): 208-212.
- [7] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.
- YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.
- [8] GUO Zhenhai, ZHAO Jing, ZHANG Wenyu, et al. A corrected hybrid approach for wind speed prediction in Hexi Corridor of China[J]. Energy, 2011, 36(3): 1668-1679.
- [9] 杨锡运, 孙宝君, 张新房, 等. 基于相似数据的支持向量机短期风速预测仿真研究[J]. 中国电机工程学报, 2012, 32(4): 35-42.
- YANG Xiyun, SUN Baojun, ZHANG Xinfang, et al. Short-term wind speed forecasting based on support vector machine with similar data[J]. Proceedings of the CSEE, 2012, 32(4): 35-42.
- [10] 曾杰, 张华. 基于蚁群优化的最小二乘支持向量机风速预测模型研究[J]. 太阳能学报, 2011, 32(3): 296-300.
- ZENG Jie, ZHANG Hua. Wind speed forecasting model study based on least squares support vector machine and ant colony optimization[J]. Acta Energaie Solaris Sinica, 2011, 32(3): 296-300.
- [11] 秦昆, 王佩. 基于云变换的曲线拟合新方法[J]. 计算机工程与应用, 2008, 44(23): 56-58.
- QIN Kun, WANG Pei. New method of curve fitting based on cloud transform[J]. Computer Engineering and Applications, 2008, 44(23): 56-58.
- [12] 刘常昱, 冯芒, 戴晓军, 等. 基于云X信息的逆向云新算法[J]. 系统仿真学报, 2004, 16(11): 2417-2420.
- LIU Changyu, FENG Mang, DAI Xiaojun, et al. A new algorithm of backward cloud[J]. Journal of System Simulation, 2004, 16(11): 2417-2420.
- [13] 孟晖, 王树良, 李德毅. 基于云变换的概念提取及概念层次构建方法[J]. 吉林大学学报: 工学版, 2010, 40(3): 782-787.
- MENG Hui, WANG Shuliang, LI Deyi. Concept extraction and concept hierarchy construction based on cloud transformation[J]. Journal of Jilin University: Engineering and Technology Edition, 2010, 40(3): 782-787.
- [14] 李德毅, 杜鹃. 不确定性人工智能[M]. 北京: 国防工业出版社, 2005: 217-234.
- [15] 邓乃扬, 田英杰. 支持向量机的理论、算法与拓展[M]. 北京: 科学出版社, 2009: 182-189.
- [16] 秦磊, 邹斌. 基于小波神经网络的电价滚动预测模型[J]. 江南大学学报: 自然科学版, 2008, 7(2): 170-174.
- QIN Lei, ZOU Bin. Electricity price forecasting model based on wavelet-neural network[J]. Journal of Jiangnan University: Natural Science Edition, 2008, 7(2): 170-174.
- [17] 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.
- [18] 刘常昱, 李德毅, 杜鹃, 等. 正态云模型的统计分析[J]. 信息与控制, 2005, 34(2): 236-240.
- LIU Changyu, LI Deyi, DU Yi, et al. Some statistical analysis of the normal cloud model[J]. Information and Control, 2005, 34(2): 236-240.
- [19] 栗然, 崔天宝, 肖进永. 基于云模型的短期电价预测[J]. 电网技术, 2009, 33(17): 185-190.
- LI Ran, CUI Tianbao, XIAO Jinyong. Short-term electricity price forecasting based on cloud model[J]. Power System Technology, 2009, 33(17): 185-190.
- [20] 徐曼, 乔颖, 鲁宗相. 短期风电功率预测误差综合评价方法[J]. 电力系统自动化, 2011, 35(12): 20-26.
- XU Man, QIAO Ying, LU Zongxiang. A comprehensive error evaluation method for short-term wind power prediction[J]. Automation of Electric Power Systems, 2011, 35(12): 20-26.

作者简介:

凌武能(1983-), 男, 广西百色人, 博士研究生, 主要从事风电功率预测及电力系统稳定分析研究(E-mail: lingwuneng@163.com);

杭乃善(1949-), 男, 广西南宁人, 教授, 博士研究生导师, 主要从事电力系统稳定分析及电力电子技术在电力系统中的应用研究;

李如琦(1959-), 女, 广西南宁人, 教授, 主要从事电力系统的最优运行与规划研究。

Short-term wind power forecasting based on cloud SVM model

LING Wuneng, HANG Naishan, LI Ruqi

(School of Electrical Engineering, Guangxi University, Nanning 530004, China)

Abstract: A CSVM(Cloud Support Vector Machine) model combining the cloud model and the SVM(Support Vector Machine) is proposed for the short-term wind power forecasting, which applies the cloud transformation to extract the qualitative attribute of wind speed data and uses SVM to build the relationship between wind speed and wind power. The forecasts for the next 24 hours' wind power show that, the forecasts at a particular point of the presented model is a set of discrete values with stabilized bias. The backward cloud algorithm is applied to calculate the expectation of the forecast set as the deterministic prediction, which is more accurate than that forecasted by SVM model or ARIMA(Auto-Regressive Integrated Moving Average) model. The presented model is effective for short-term wind power forecasting.

Key words: wind power; forecasting; cloud model; cloud transformation; support vector machines