

# 考虑相关因素的最小二乘支持向量机风速预测方法

栗然<sup>1</sup>, 陈倩<sup>1</sup>, 徐宏锐<sup>2</sup>

(1. 华北电力大学电气工程学院, 河北 保定 071003; 2. 山西省电力公司调度通信中心, 山西 太原 030001)

**摘要:** 准确的短期风速预测对电网的安全稳定性及降低运行成本具有重要意义。提出了考虑相关因素的最小二乘支持向量机风速预测方法, 通过相关性分析, 寻找对风速影响较大的因素, 作为预测风速的信息特征参考量, 并利用灰色关联分析方法, 对风速数据进行预处理, 筛选出某些与预测日特征相似的历史样本作为最小二乘支持向量机模型的训练样本, 定量分析了预测模型的输入变量。由于训练样本与预测日风速信息的相似度极高, 通过实例验证, 有效提高了预测结果的可信度和精确度。

**关键词:** 风速预测; 相关因素; 灰色关联; 最小二乘支持向量机; 参数优化

## Wind speed forecasting method based on LS-SVM considering the related factors

LI Ran<sup>1</sup>, CHEN Qian<sup>1</sup>, XU Hong-rui<sup>2</sup>

(1. School of Electric Engineering, North China Electric Power University, Baoding 071003, China;

2. Shanxi Electric Power Company Dispatching and Communication Center, Taiyuan 030001, China)

**Abstract:** Accurate short-term wind speed forecasting is very important for improving the security and stability of power grid and reducing the running cost. A forecasting method based on LS-SVM considering the factors related is proposed to choose factors having significant impacts on the wind speed through correlation analysis as the reference quantity for information characteristics of the wind speed, to adopt grey relation analysis to pretreat the speed data, and search the historical speed with highly similar features to the forecasting day as the training samples of the LS-SVM model. It also analyzes the input variables of the model quantitatively. Due to the high similarity between the training samples and the speed of the forecasting day, the actual examples prove that the wind speed forecasting accuracy and reliability are effectively improved.

**Key words:** wind speed forecasting; related factors; grey relation; LS-SVM; parameter optimization

中图分类号: TM715 文献标识码: A 文章编号: 1674-3415(2010)21-0146-06

## 0 引言

由于风电具有很强的随机性, 大规模风电的接入对电力系统的安全稳定运行带来了新挑战。对风电场风速或风电功率进行比较准确的预测, 有利于电力系统调度部门及时调整调度计划, 从而有效减轻风电对电网的影响, 还可以减少电力系统运行成本和旋转备用, 提高风电穿透功率极限, 同时提高风电场在电力市场中的竞争能力<sup>[1-4]</sup>。

对风电场做短期风速预测, 再由风电场功率曲线得到风力发电功率的预测值, 这是进行风力发电功率预测的有效途径之一。目前, 国内对风电功率预测的研究较少。常用的预测方法有空间相关性法<sup>[5]</sup>、时间序列法<sup>[6]</sup>、人工神经网络法<sup>[7]</sup>等。空间相关性法需要考虑风电场以及与之相近几个地点的多

组风速数据, 运用几个地点风速之间的空间相关性, 进行风速预测, 该方法对原始数据要求很高<sup>[8]</sup>。时间序列法需要大量的历史数据来建模, 只需单一风速时间序列即可建立模型, 不考虑相关因素与风速之间相互依存的因果关系, 只适用于超短期风速预测, 在气候变化很大的情况下预测结果不理想。人工神经网络法具有自学习、自组织、自适应性, 可以充分逼近任意复杂的非线性关系, 但这种方法也存在一些问题, 如隐单元数目难以确定、容易陷入局部极小问题、算法收敛速度比较慢等。

最小二乘支持向量机克服了神经网络易陷入局部极小、训练时间长等缺点, 有更好的泛化性能。目前最小二乘支持向量机风速预测的研究对输入变量的确定还没有很好的选择标准。本文提出了考虑相关因素的最小二乘支持向量机风速预测方法, 通

过相关性分析,寻找对风速影响较大的因素,作为风速的信息特征,对历史样本进行搜索筛选,构成训练样本集,并定量确定预测模型的输入变量。本文结合具体实例,针对提前 10 min 给出风速预测值的要求,详细阐述这一方法在风速预测中的应用。

## 1 灰色关联分析理论

关联度是灰色系统理论提出的一种技术方法,是分析系统中各因素关联程度的方法,或者说是关联程度量化的一种方法。

关联度的基本思想,是根据曲线间相似程度来判断其关联程度,实质上是几种曲线间几何形状的分析比较,即认为几何形状越接近,则发展变化态势越接近,关联程度越大<sup>[9]</sup>。

灰色系统关联分析的具体计算步骤如下:

1) 确定反应系统行为特征的参考序列和影响系统行为的比较序列。参考序列(预测时刻信息特征)用  $X_0$  表示,  $X_0 = [X_0(1), X_0(2), \dots, X_0(m)]$ 。它们分别表示预测时刻的信息特征。数据库中的每日相同时刻的信息特征向量作为比较序列,用  $X_1, X_2, \dots, X_n$  表示。

$$(X_0, X_1, X_2, \dots, X_n) = \begin{bmatrix} x_0(1) & x_1(1) & \dots & x_n(1) \\ x_0(2) & x_1(2) & \dots & x_n(2) \\ \vdots & \vdots & & \vdots \\ x_0(m) & x_1(m) & \dots & x_n(m) \end{bmatrix} \quad (1)$$

2) 对参考序列和比较序列进行无量纲化处理。为了便于比较,在进行灰色关联度分析时,一般都要进行无量纲化的数据处理。采用公式对其进行无量纲化处理,得到

$$x'_i(k) = x_i(k) / x_i(1), i = 0, 1, 2, \dots, n; k = 1, 2, \dots, m \quad (2)$$

$$(X'_0, X'_1, X'_2, \dots, X'_n) = \begin{bmatrix} x'_0(1) & x'_1(1) & \dots & x'_n(1) \\ x'_0(2) & x'_1(2) & \dots & x'_n(2) \\ \vdots & \vdots & & \vdots \\ x'_0(m) & x'_1(m) & \dots & x'_n(m) \end{bmatrix} \quad (3)$$

3) 计算参考序列与比较序列的灰色关联系数。所谓关联程度,实质上是曲线间几何形状的差别程度。因此,曲线间差值大小,可作为关联程度的衡量尺度。

$$\xi_{0i}(k) = \frac{\min_i \min_k |x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|} \quad (4)$$

上式为曲线  $X_0$  与  $X_i$  在第  $K$  点的关联系数。其中,  $i = 0, 1, 2, \dots, n; k = 1, 2, \dots, m; \rho$  为分辨系数,通常  $\rho = 0.5$ , 得关联系数矩阵

$$\begin{bmatrix} \xi_{01}(1) & \xi_{02}(1) & \dots & \xi_{0n}(1) \\ \xi_{01}(2) & \xi_{02}(2) & \dots & \xi_{0n}(2) \\ \vdots & \vdots & & \vdots \\ \xi_{01}(m) & \xi_{02}(m) & \dots & \xi_{0n}(m) \end{bmatrix} \quad (5)$$

4) 求关联度。关联系数是比较序列与参考序列在曲线中各点的关联程度值,它的数不止一个,信息分散。因此有必要将各个时刻的关联系数集中为一个值,作为比较序列与参考序列间关联程度的数量表示,从而进行整体性比较。综合各点的关联系数,可得出整条曲线  $X_i$  与参考曲线  $X_0$  的关联度:

$$r_{0i} = \frac{1}{m} \sum_{k=1}^m \xi_{0i}(k), i = 1, 2, \dots, n \quad (6)$$

5) 排关联序。将  $n$  个比较序列对同一参考序列的关联度大小顺序排列,组成关联序,它反映了对于参考序列来说各比较序列的“优劣”关系。本文以预测时刻的历史风速指标向量为参考序列  $T_0$ , 以历史数据中每一日相同时刻的历史风速向量为比较序列  $T_i (i = 1, 2, \dots, n)$ , 计算它们与  $T_0$  之间的关联度。给定一特定值  $n'$ , 按关联度从大到小的顺序取前  $n'$  个样本数据作为预测最终的风速样本。

## 2 LS-SVM 原理

最小二乘支持向量机用最小二乘线性系统作为损失函数取代支持向量机中的二次规划方法,将不等式约束条件变为等式约束,从而将二次规划问题转变为线性方程组的求解,提高了求解问题的速度和收敛精度<sup>[10-12]</sup>。

对于给定的训练数据集  $(x_i, y_i)$ ,  $i = 1, 2, \dots, l, x_i \in R^n, y_i \in R$ , 利用一非线性映射  $\phi(\cdot)$  将样本空间从原空间映射到特征空间  $\phi(x_i)$ , 在高维特征空间中构造最优决策函数:  $y(x) = \omega \cdot \phi(x) + b$

这样非线性估计函数转化为高维特征空间中的线性估计函数,利用结构风险最小化原则,回归问题表示成优化问题:

$$\min J(\omega, \xi) = \frac{1}{2} \omega^T \omega + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 \quad (7)$$

约束条件:

$$y_i = \phi(x_i) \cdot \omega + b + \xi_i, i = 1, 2, \dots, l$$

其中:  $\|\omega\|^2$  是控制模型的复杂度;  $C$  是边际系数;  $\xi_i$  是误差变量;  $b$  是偏差量。用拉格朗日法求解这

一优化问题:

$$L(\omega, b, \xi, a) = \frac{1}{2} \omega^T \omega + C \frac{1}{2} \sum_{i=1}^l \xi_i^2 - \sum_{i=1}^l a_i (\phi(x_i) \cdot \omega + b + \xi_i - y_i) \quad (8)$$

式中,  $a_i (i = 1, 2, \dots, l)$  为拉格朗日乘子, 由优化条件可得:

$$\begin{cases} \omega = \sum_{i=1}^l a_i \cdot \phi(x_i) \\ \sum_{i=1}^l a_i = 0 \end{cases} \quad (9)$$

定义核函数  $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ , 优化问题转化为求解如下线性方程组:

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + \frac{1}{C} & \dots & K(x_1, x_l) + \frac{1}{C} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & K(x_l, x_1) + \frac{1}{C} & \dots & K(x_l, x_l) + \frac{1}{C} \end{bmatrix} \times \begin{bmatrix} b \\ a_1 \\ \vdots \\ a_l \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \vdots \\ y_l \end{bmatrix} \quad (10)$$

用最小二乘法求出回归系数  $a_i$  和偏差  $b$ , 得非线性预测模型:

$$f(x) = \sum_{i=1}^l a_i K(x, x_i) + b \quad (11)$$

### 3 考虑相关因素的 LS-SVM 预测方法

风速虽然具有不稳定性和间歇性, 但是风本身还是具有一定变化规律的。我国大部门地区春秋风

速较大, 夏冬风速较小。白天气温高, 夜间气温低, 风速也随着气温的升降而不断变化。一般情况下, 在近地面层, 正常的风速日变化是午后最大, 之后逐渐减小, 清晨最小, 日出后风速又随着增强, 白天风速变化较夜间快得多。

这只是一般的变化规律, 对于具体某个地区风速和哪些因素相关性较强, 需要进行具体分析。本文选取了即刻温度、即刻压强、前 10 min 风速、前 20 min 风速、前 30 min 风速、前 1 h 风速和前 2 h 风速等参考因素, 与风速进行相关性分析, 在分析结果中选取相关性较大的因素作为风速的信息特征筛选训练样本, 并作为风速预测模型输入变量的重要参考量。

风速预测的重点在于预测模型输入变量的选取, 输入变量的选择恰当与否与风速预测精度直接相关。本文采用相关性分析方法, 选择对风速影响较大的因素作为输入变量。对于两个向量  $x$  和  $y$ , 它们的相关系数为

$$r_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (12)$$

其中:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ ;  $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ 。风速与各因素的相关性分析如表 1 所示。

表 1 2006 年 4 月 3 日~5 月 3 日风速与各因素之间的相关系数

Tab.1 The correlation coefficient of wind speed and other factors from 4,3,2006 to 5,3,2006

时刻	0: 00	4: 30	10: 00	14: 00	16: 30	20: 00
即刻温度	-0.412 7	-0.469 4	-0.456 1	-0.386 4	-0.353 2	-0.335 3
即刻压强	-0.370 8	-0.557 6	-0.511 7	-0.111 2	0.171 1	-0.216 9
前 10 min 风速	0.981 3	0.987 8	0.977 2	0.975 7	0.976 2	0.988 1
前 20 min 风速	0.977 2	0.967 4	0.963 6	0.953 3	0.954 5	0.967 7
前 30 min 风速	0.961 2	0.973 0	0.919 2	0.961 0	0.953 3	0.921 6
前 1 h 风速	0.921 8	0.915 5	0.917 4	0.936 2	0.929 9	0.944 8
前 2 h 风速	0.863 1	0.923 4	0.853 5	0.886 5	0.770 2	0.911 3

从表 1 中可以看出, 风速与即刻的温度、压强等因素相关性不高, 靠温度、压强等气象因素预测, 精度不会令人满意。而当前风速值与前 10 min、前 20 min、前 30 min 的风速值的相关性很高, 与前 1 h 的风速值也有较高的相关性。因为风速虽然随机性很强, 但是通常情况下, 短时间内变化不会太大。

对于超短期风速预测, 前一时刻的风速值, 表征了预测的起始, 可以作为风速预测的重要参考量。而 2 h 内风速可能发生比较大的变化, 提前 2 h 的风速值与即刻风速值相关性不是很高, 所以不考虑前 2 h 风速值作为参考值。因此, 选择预测时刻的前 1 h 风速值、前 30 min 风速值、前 20 min 风速值以及

前 10 min 风速值作为风速预测的信息特征参考量。

为了选择相似历史风速 (即相似信息特征) 样本, 设定参考序列  $T_0=[T_0(1), T_0(2), T_0(3), T_0(4)]$  (即  $m=4$ )。它们分别表示预测时刻的前 1 h 风速值、前 30 min 风速值、前 20 min 风速值以及前 10 min 风速值。数据库中的每日同一预测时刻的前 1 h 风速值、前 30 min 风速值、前 20 min 风速值、前 10 min 风速值作为比较序列, 用  $T_1, T_2, \dots, T_n$  表示。按照上述求关联度的步骤, 将  $n$  个比较序列对同一参考序列的关联度大小顺序排列。本文取  $n'=7$ , 即选 7 个相似信息特征风速样本。

对于训练样本, 通过本文采用的灰色关联分析方法提取出和预测点同一时刻且信息特征相似的风速值作为 LS-SVM 训练模型的输出量  $y$  值, 相应的样本输入量  $x$  值为:  $X=[A_1, B_1, C_1]$ 。其中  $A_1=[a_1, a_2, \dots, a_s]$ , 表示预测日之前  $s$  日内同一预测时段的风速数据。 $B_1=[b_1, b_2, \dots, b_s]$ , 表示预测日之前  $s$  日内同一预测时段的信息特征向量, 其中任何一个元素  $b_i$  包含  $m$  个风速信息 (即前 1 h、前 30 min、前 20 min、前 10 min 历史风速)。 $C_1=[c_1, c_2, \dots, c_m]$ , 表示预测日预测时刻的风速信息。

## 4 实例分析

### 4.1 样本选择

选取我国某风电场 40 天的风速观测数据作为样本数据, 该风速序列每 10 min 采样一点。用前 39 天的数据进行建模, 按每 10 min 预测一点的要求, 对第 40 天的风速进行预测。根据上述方法的建模过程, 首先根据灰色关联分析方法压缩精简样本, 之后对最小二乘支持向量机模型进行训练, 进而进行风速的预测。

### 4.2 LS-SVM 模型参数的优化

文中 LS-SVM 模型采用的核函数是径向基核函数:  $K(x, x_i) = \exp(-(x - x_i)^2 / 2\sigma^2)$ , 惩罚因子  $C$  和核函数参数  $\sigma^2$  的选取对模型性能有重要影响。

蚁群算法是一种模拟进化算法, 具有很强的全局搜索能力。它是一种应用于组合优化问题的启发式搜索算法<sup>[13]</sup>。

基于蚁群算法的参数优化步骤为:

(1) 根据问题性质估计一下最优解的范围, 即确定各变量的值域。

(2) 将变量区域网格化, 空间的一个网格点对应一个状态, 蚂蚁在各网格点之间移动, 并根据各网格点的目标函数值留下不同量的信息, 以影响下

一批蚂蚁的移动方向。

(3) 循环一段时间后, 相邻节点间的目标函数差值越小, 网格点信息量越大, 对信息量较大的网格点, 缩小变量范围, 在该点附近进行蚁群移动。

(4) 不断重复上述过程, 直到满足算法的停止条件。

通过以上算法确定最优的参数值对为 (2900, 810)。

### 4.3 预测结果及分析

对该风电场 5 月 13 日一天 144 个点进行预测, 预测风速值的分布如图 1 所示。从图中可以看出, 预测曲线与实测曲线变化规律一致。

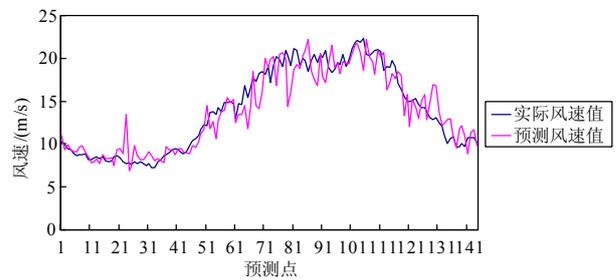


图 1 考虑相关因素的 LS-SVM 风速预测结果

Fig.1 Forecasting results of wind speed with LS-SVM considering the factors related

本文选取绝对百分比误差  $E_{APE}$  和平均绝对百分比误差  $E_{MAPE}$  作为各种方法预测效果判断的依据:

$$E_{APE} = \left| \frac{A(i) - F(i)}{A(i)} \right| \times 100\% \quad (13)$$

$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{A(i) - F(i)}{A(i)} \right| \times 100\% \quad (14)$$

式中:  $A(i)$  和  $F(i)$  分别为实际风速值和预测风速;  $n$  为预测值的个数。采用本文方法预测各点的风速结果如表 2 所示。

通过上述提出的考虑相关因素的 LS-SVM 模型进行预测, 平均绝对百分比误差为 10.00%。144 个点中有个别值偏离较大, 如果不考虑个别异常值, 误差能达到 6.81%。在个别预测点的预测误差较大, 尤其是在风速序列的转折点处预测结果与实际风速值有较大偏差, 这是因为风速的随机性很强, 所用方法很难对风速波动较大的时刻做出准确预测。但是总体来看, 本文采用的方法在绝大部分预测点给出了比较准确的结果。

表 2 考虑相关因素的 LS-SVM 模型预测结果

Tab.2 Forecasting results of LS-SVM model considering the factors related

预测时刻	实际风速/ (m/s)	预测风速/ (m/s)	$E_{APE}/\%$
0:00	10.3	10.926 1	6.08
0:10	9.9	9.288 3	6.18
0:20	9.5	9.923 3	4.46
0:30	9.4	9.289 3	1.18
0:40	8.9	9.132 2	2.61
0:50	8.7	9.082 5	4.40
1:00	8.8	9.549 5	8.52
1:10	8.8	9.785 6	11.20
1:20	8.9	9.148 4	2.79
1:30	8.2	8.546 5	4.23
1:40	8.2	7.858 9	4.16
1:50	8.4	7.976 5	5.04
2:00	8.5	8.335 6	1.93
2:10	8.3	7.676 9	7.51
2:20	8.5	8.805 9	3.60
2:30	8.1	8.274 7	2.16
2:40	8	8.329 9	4.12
2:50	8.1	8.468 0	4.54
⋮	⋮	⋮	⋮
11:00	10.1	12.092 3	19.73
11:10	9.7	10.932 9	12.71
11:20	10.8	8.886 2	17.72
11:30	10.7	11.339 2	5.97
11:40	10.8	11.698 1	8.32
11:50	10.2	9.801 3	3.91

用本文提出的方法和不考虑相关因素的 LS-SVM 模型进行对比, 比较两者的预测精度, 结果如图 2 所示。

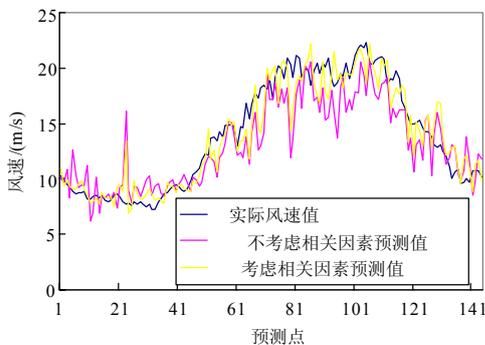


图 2 采用不同预测方法的风速预测结果比较

Fig.2 The comparison of wind speeds forecasting results with different methods

不考虑相关因素的 LS-SVM 模型预测平均绝对百分比误差为 14.13%。较本文采用的方法预测误差大。从图 2 可以看出, 本文方法对提高风速预测精度有一定的贡献。

### 5 结束语

对考虑相关因素的最小二乘支持向量机风速预测方法研究得出以下结论:

(1) 最小二乘支持向量机具有较强的小样本学习和泛化能力。LS-SVM 模型参数会直接影响模型的预测效果。蚁群算法在解决参数优化问题方面有一定的优越性, 具有很好的通用性和鲁棒性, 是基于总体的优化方法。

(2) 考虑了对风速影响较大的相关因素, 作为风速的信息特征, 对历史样本进行搜索筛选, 筛选出某些与预测日特征相似的历史样本作为最小二乘支持向量机模型的训练样本, 构成训练样本集, 有利于提高预测模型的外推效果, 并对预测模型的输入变量做了定量分析。该方法有效地提高了风速预测的精度, 取得了比较满意的预测效果。

### 参考文献

- [1] 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 Xiu-yuan, XIAO Yang, CHEN Shu-yong. Wind speed and generated power forecasting in wind farm[J]. Proceedings of the CSEE, 2005, 25 (11): 1-5.
- [2] 谷兴凯, 范高峰, 王晓蓉, 等. 风电功率预测技术综述[J]. 电网技术, 2007, 31 (2): 335-338. GU Xing-kai, FAN Gao-feng, WANG Xiao-rong, et al. Summarization of wind power prediction technology[J]. Power System Technology, 2007, 31 (2): 335-338.
- [3] Bossanyi E A. Short-term wind prediction using Kalman filters[J]. Wind Engineering, 1985, 9 (1): 1-8.
- [4] 吴兴华, 周晖, 黄梅. 基于模式识别的风电场风速和发电功率预测[J]. 继电器, 2008, 36 (1): 27-32. WU Xing-hua, ZHOU Hui, HUANG Mei. Wind speed and generated power forecasting based on pattern recognition in wind farm[J]. Relay, 2008, 36 (1): 27-32.
- [5] Damousis I G, Alexiadis M C, Theocharis J B, et al. A fuzzy expert system for the forecasting of wind speed and power generation in wind farms using spatial correlation[J]. IEEE Trans on Energy Conversion, 2004, 19 (6): 352-361.
- [6] Kamal L, Jafri Y Z. Time series models to simulate and forecast hourly averaged wind speed in Wuetta, Pakistan[J]. Solar Energy, 2001, 61 (1): 23-32.
- [7] 范高峰, 王伟胜, 刘纯. 基于人工神经网络的风电功率短期预测系统[J]. 电网技术, 2008, 32 (22): 72-76. FAN Gao-feng, WANG Wei-sheng, LIU Chun. Artificial neural network based wind power short term prediction

- system[J]. Power System Technology, 2008, 32 (22): 72-76.
- [8] 杜颖, 卢继平, 李青, 等. 基于最小二乘支持向量机的风电场短期风速预测[J]. 电网技术, 2008, 32 (15): 62-66.  
DU Ying, LU Ji-ping, LI Qing, et al. Short-term wind speed forecasting of wind farm based on least square-support vector machine[J]. Power System Technology, 2008, 32 (15): 62-66.
- [9] 牛东晓, 谷志红, 刑棉, 等. 基于数据挖掘的 SVM 短期负荷预测方法研究[J]. 中国电机工程学报, 2006, 26 (18): 6-12.  
NIU Dong-xiao, GU Zhi-hong, XING Mian, et al. Study on forecasting approach to short-term load of SVM based on data mining[J]. Proceedings of the CSEE, 2006, 26 (18): 6-12.
- [10] 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 Shuang-bin, WANG Wei-qing, ZHANG Xin-yan. Wind speed and wind power prediction based on SVM[J]. East China Electric Power, 2009, 37 (9): 1600-1603.
- [11] 曾杰, 张华. 基于最小二乘支持向量机的风速预测模型[J]. 电网技术, 2009, 33 (18): 144-147.  
ZENG Jie, ZHANG Hua. A wind speed forecasting model based on least squares support vector machine[J]. Power System Technology, 2009, 33 (18): 144-147.
- [12] 李元诚, 方廷建, 于尔铿. 短期负荷预测的支持向量机方法研究[J]. 中国电机工程学报, 2003, 23 (6): 55-59.  
LI Yuan-cheng, FANG Ting-jian, YU Er-keng. Study of support vector machines for short-term load forecasting[J]. Proceedings of the CSEE, 2003, 23 (6): 55-59.
- [13] 张培林, 钱林方, 曹建军, 等. 基于蚁群算法的支持向量机参数优化[J]. 南京理工大学学报, 2009, 33 (4): 464-468.  
ZHANG Pei-lin, QIAN Lin-fang, CAO Jian-jun, et al. Parameter optimization of support vector machine based on ant colony optimization algorithm[J]. Journal of Nanjing University of Science and Technology, 2009, 33 (4): 464-468.

收稿日期: 2010-06-18

作者简介:

栗然 (1965-), 女, 教授, 博士, 研究方向为人工智能在电力系统中的应用、电网调度自动化、电网调度运营管理、数据仓库和数据挖掘技术在电力系统中的应用等;

陈倩 (1984-), 女, 硕士研究生, 研究方向为电力系统分析、运行与控制;

徐宏锐 (1984-), 男, 硕士, 研究方向为电力系统分析、运行与控制。

(上接第 145 页 continued from page 145)

- [4] Diyar Akay, Mehmet Atak. Grey prediction with rolling mechanism for electricity demand forecasting of Turkey[J]. Energy, 2007 (32): 1670-1675.
- [5] 刘思峰, 邓聚龙. GM (1,1) 模型的适用范围[J]. 系统工程理论与实践, 2000, 20 (5): 121-124.  
LIU Si-feng, DENG Ju-long. The range suitable for GM (1,1) [J]. Systems Engineering-Theory & Practice, 2000, 20 (5): 121-124.
- [6] 罗党, 刘思峰, 党耀国. 灰色模型 GM (1,1) 优化[J]. 中国工程科学, 2003, 5 (8): 50-53.  
LUO Dang, LIU Si-feng, DANG Yao-guo. The optimization of grey model GM (1,1) [J]. Engineering Science, 2003, 5 (8): 50-53.
- [7] 唐万梅, 向长合. 基于二次插值的 GM (1,1) 模型预测方法的改进[J]. 中国管理科学, 2006, 14 (6): 109-112.  
TANG Wan-mei, XIANG Chang-he. The improvements of forecasting method in GM (1,1) model based on quadratic interpolation[J]. Chinese Journal of Management Science, 2006, 14 (6): 109-112.
- [8] 李俊峰, 戴文战. 基于插值和 Newton-Cores 公式的 GM (1,1) 模型的背景值构造新方法[J]. 系统工程理论与实践, 2004, 24 (10): 122-126.  
LI Jun-feng, DAI Wen-zhan. A new approach of background value-building and its application based on data interpolation and Newton-Cores formula[J]. Systems Engineering-Theory & Practice, 2004, 24 (10): 122-126.
- [9] 关治, 陈景良. 数值计算方法[M]. 北京: 清华大学出版社, 1990.  
GUAN Ye, CHEN Jing-liang. Numerical methods[M]. Beijing: Tsinghua University Press, 1990.
- [10] 敖培, 牟龙华. 基于空穴序列的灰色预测模型及其应用[J]. 电力系统保护与控制, 2009, 37 (24): 90-93.  
AO Pei, MU Long-hua. Grey forecasting model based on vacant data series and application[J]. Power System Protection and Control, 2009, 37 (24): 90-93.

收稿日期: 2010-04-20

作者简介:

王晓佳 (1983-), 男, 博士, 讲师, 研究方向为电力系统保护与控制, 预测、决策科学与技术; E-mail: hfut211@163.com

沈建新 (1967-), 男, 博士, 研究方向为电力系统营销与控制, 预测、决策科学与技术;

杨善林 (1948-), 男, 教授, 博导, 研究方向为决策科学与技术, 人工智能, 计算机网络。