

基于相关向量机的短期风速预测模型

李慧杰¹, 刘亚南², 卫志农², 李晓露¹, Kwok W Cheung³, 孙永辉², 孙国强²

(1. 阿尔斯通电网技术中心有限公司, 上海 201114; 2. 河海大学 可再生能源发电技术教育部工程研究中心, 江苏 南京 210098; 3. ALSTOM Grid Inc., Redmond, USA Washington 98052)

摘要: 通过对风速的时间序列进行分析, 表明该序列具有混沌特性。在此基础上, 利用相空间重构理论建立基于相关向量机(RVM)的短期风速预测模型, 并对不同的核函数进行分析, 选出最优的核函数。与现有的风速预测模型相比, 该模型具有高稀疏性、核函数选择灵活等优点。仿真结果表明, 与 BP 神经网络和支持向量机(SVM)模型相比, RVM 模型预测精度更高。

关键词: 神经网络; 支持向量机; 相关向量机; 相空间重构; 短期风速预测; 模型

中图分类号: TM 715; TM 614

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2013.10.005

0 引言

可再生能源的开发利用得到世界各国的高度重视, 风力发电因具有环保可再生、全球可行、成本低且规模效益显著等优点, 已经受到广泛的重视, 并且发展迅速^[1]。近年来, 风力发电机组容量的迅速增长, 对电力系统的影响也越来越明显。尽管风力发电已经成为一种较为成熟的技术, 但风电场风速的预测还未达到一定的满意程度。准确预测风电场的风速有利于调度部门调整计划, 从而有效减轻风电对整个电网的不利影响, 减少电力系统运行成本, 也有利于调度人员及时采取正确的调度措施^[2]。

由于风速受诸多因素的影响, 具有很强的随机性和不确定性, 所以预测难度较大, 尤其是进行短期风速预测^[3]。文献[4]将经典的 ARMA 模型用于短期风速预测, 取得了较好的结果, 但这种方法低阶模型不能完全反映样本的性能, 高阶模型的估计较为复杂, 在计算中消耗时间, 在气候变化很大的情况下预测结果不甚理想。文献[5-6]分别采用 BP 神经网络和径向基神经网络进行风速预测, 但其算法容易陷入局部最小问题, 得不到全局最优解, 收敛速度也较慢。文献[7]将支持向量机(SVM)应用到风速预测中, 同时采用微分进化算法进行参数优化, 相比神经网络, 该方法具有更高的精度和更强的鲁棒性。文献[8]采用空间相关性法进行短期风速预测, 该方法需要考虑所测地点以及与之相近几个地点的风速时间序列, 基于几个地点风速之间的空间相关性, 进行风速预测。由于该方法需要大量的原始数据, 在实际操作中存在一定的难度。

混沌理论最早用于气象学中, 通过对风速时间序列的 Lyapunov 指数计算, 可以证明其具有混沌特性,

而且混沌时间序列在短期内可以预测。因此, 利用混沌相空间重构理论可以还原风速时间序列的非线性动力特性, 使用一定的预测模型可以进行短期风速预测。文献[9-10]已经将相空间重构用于风力发电功率预测中。本文通过相空间重构的方法建立相关向量机(RVM)短期风速预测模型, 同时采用高斯核函数和多项式函数的组合作为 RVM 的核函数, 以此来提高预测精度。算例结果表明, RVM 模型较之现有的风速预测模型具有更高的精度。

1 相空间重构理论

根据 Takens 的嵌入定理^[11], 对于一个时间序列, 延迟坐标的维数 $m \geq 2d+1$ (d 是动力系统的维数), 在该嵌入维空间里可以把有规律的轨道(吸引子)恢复出来, 即重构的空间中的轨道与原吸引子的拓扑结构完全相同。对于一组时间序列 $\{x_i\}$, 则相空间重构为:

$$Y_m(i) = [x(i), x(i+\tau), x(i+2\tau), \dots, x(i+(m-1)\tau)] \quad (1)$$

其中, m 为嵌入维数, τ 为延迟时间, $Q = n - (m-1)\tau$ 为相空间中的相点个数, $i = 1, 2, \dots, Q$ 。

在重构过程中, 嵌入维数和延迟时间选取至关重要, 恰当选择 2 个参数将直接影响相空间重构的质量, 从而影响预测精度。

1.1 互信息求取延迟时间

利用计算互信息函数的第一极小值来确定最佳延迟时间 τ 的方法称为互信息法。

对于 2 组信号 $\{x(i), y(j)\} (i, j = 1, 2, \dots, Q)$ 给定 $x(i)$ 的一个测量值, 预测 $y(j)$ 的平均信息量为互信息函数:

$$I(x, y) = H(x) + H(y) - H(x, y) \quad (2)$$

$$H(x) = -\sum_i P_x[x(i)] \log \{P_x[x(i)]\} \quad (3)$$

$$H(x, y) = -\sum_{i,j} P_{xy}[x(i), y(j)] \log \{P_{xy}[x(i), y(j)]\} \quad (4)$$

收稿日期: 2012-01-30; 修回日期: 2013-09-05

基金项目: 国家自然科学基金资助项目(51277052, 51107032, 61104045)

Project supported by the National Natural Science Foundation of China(51277052, 51107032, 61104045)

其中, $P_x[x(i)]$ 为 $x(i)$ 的概率密度, $P_y[y(j)]$ 为 $y(j)$ 的概率密度, $P_{xy}[x(i), y(j)]$ 为联合概率; $H(x)$ 为信号 $\{x(i)\}$ 的熵, 表示对指定系统的 N 个 $x(i)$ 测量得到的平均信息量, $H(y)$ 的定义与 $H(x)$ 类似, $H(x, y)$ 为联合熵。本文采用等间距划分网格方法计算互信息。

针对本文选取的时间序列, 利用互信息法得到该序列互信息函数与延迟时间的关系如图 1 所示, 从图中看出, 延迟时间取 10。




图 1 互信息函数与延迟时间关系

Fig.1 Relationship between mutual information function and time delay

1.2 Cao 算法求嵌入维数

目前相空间重构嵌入维数的求取广泛采用 Cao 算法。对于混沌时间序列 $x_1, x_2, \dots, x_n$, 若嵌入维数为 m , 延迟时间为 τ , 则重构的相空间如式 (1) 所示。定义:

$$\alpha(i, m) = \frac{\|Y_{m+1}(i) - Y_{m+1}(n(i, m))\|}{\|Y_m(i) - Y_m(n(i, m))\|} \quad (5)$$

$$E(m) = \frac{1}{Q - m\tau} \sum_{i=1}^{Q - m\tau} \alpha(i, m) \quad (6)$$

$$E_1(m) = \frac{E(m+1)}{E(m)} \quad (7)$$

$$E^*(m) = \frac{1}{Q - m\tau} \sum_{i=1}^{Q - m\tau} |x(i + m\tau) - x[n(i, m) + m\tau]| \quad (8)$$

$i = 1, 2, \dots, Q - m\tau$

$$E_2(m) = \frac{E^*(m+1)}{E^*(m)} \quad (9)$$

其中, $E(m)$ 为所有 $\alpha(i, m)$ 的均值, $Y_{m+1}(n(i, m))$ 为 $Y_{m+1}(i)$ 的最邻近的点, $Y_m(n(i, m))$ 为 $Y_m(i)$ 的最邻近的点。

当嵌入维数 m 大于某个值时, $E_1(m)$ 不再变化, 这时 m 就是饱和嵌入维数。针对本文选取的时间序列, 利用 Cao 算法得到 $E_1(m)$ 、 $E_2(m)$ 与嵌入维数 m 的关系如图 2 所示。从图中可以看出, 嵌入维数 m 增




图 2 $E_1(m)$ 、 $E_2(m)$ 与嵌入维数 m 的关系

Fig.2 Relationship between $E_1(m)$ 、 $E_2(m)$ and embedding dimension m

加到 7 时, $E_1(m)$ 趋于稳定, 所以嵌入维数取 8。

1.3 时间序列的最大 Lyapunov 指数

对于一个混沌系统, 至少存在一个正的 Lyapunov 指数, 它反映了轨道从初始条件附件开始发散的速度。因此, 可以通过估计最大 Lyapunov 指数, 来判断系统的混沌属性。本文采用 Wolf 法^[12]估计最大 Lyapunov 指数。

步骤 1 设初始时刻为 t_0 , 当前时刻为 t_1 , 终点时刻为 t_M , $M = P - (m + 1)\tau$, P 为时间序列终点。

步骤 2 设初始点为 $Y(t_0)$, 其与最近邻点 $Y_0(t_0)$ 的距离为 L_0 , 经过一定时间的演化到达 2 个新的点 $Y(t_1)$ 和 $Y_0(t_1)$, 此时间距超过一个预先给定的阈值 ξ ($\xi > 0$), 即 $L'_0 = |Y(t_1) - Y_0(t_1)| > \xi$ 。

步骤 3 保留 $Y(t_1)$, 同时在 $Y(t_1)$ 邻近另找一个点 $Y_1(t_1)$, 使得 $L_1 = |Y(t_1) - Y_1(t_1)| < \xi$ 并且与之夹角尽可能小。

步骤 4 继续步骤 3, 直到到达时间序列的终点 M , 追踪演化过程的迭代次数为 $t_M - t_0$, 则最大 Lyapunov 指数 λ_1 为:

$$\lambda_1 = \frac{1}{t_M - t_0} \sum_{i=1}^M \ln \frac{L'_i}{L_i} \quad (10)$$

其中, $L'_i = |Y(t_i) - Y(t_{i-1})|$, $L_i = |Y(t_i) - Y_i(t_i)|$, $Y_i(t_i)$ 为 t_i 时刻在状态 $Y(t_i)$ 以 ε 为半径的邻域内的一点。

根据前述分析, 取 $m=8$ 、 $\tau=10$, 这时最大 Lyapunov 指数大于 0, 其值为 $\lambda_1=0.2851$ 。由此看出, 风速时间序列具有混沌特性。

2 RVM 原理

RVM^[13-14]是在 SVM 的基础上, 基于贝叶斯学习理论提出的算法模型。与 SVM 相比, RVM 有如下优点: 相关向量的数目远远小于支持向量, 具有高稀疏性; 仅有核参数的设置, 可以节约训练时间; 核函数无需满足 Mercer 条件, 增加了核函数选择的灵活性。

对于给定的训练样本输入集 $\{\mathbf{x}_n\}_{n=1}^N$ 和对应的输出集 $\{l_n\}_{n=1}^N$, RVM 回归模型^[15-17]可定义为:

$$l_i = \sum_{j=1}^N w_j K(\mathbf{x}, \mathbf{x}_j) + w_0 + \varepsilon \quad (11)$$

其中, ε 为服从 $N(0, \sigma^2)$ 分布的各独立样本误差, w_i 为权系数, $K(\mathbf{x}, \mathbf{x}_i)$ 为核函数, N 为样本数量。

对于相互独立的输出集, 整个样本的似然函数为:

$$p(l|\mathbf{w}, \sigma^2) = \prod_{i=1}^N N(t_i|y(\mathbf{x}_i; \mathbf{w}), \sigma^2) = (2\pi\sigma^2)^{-N/2} \times \exp[-\|\mathbf{l} - \Phi\mathbf{w}\|^2 / (2\sigma^2)] \quad (12)$$

其中, $\mathbf{l} = (l_1, l_2, \dots, l_N)$, $\mathbf{w} = [w_0, w_1, \dots, w_N]^T$, $\Phi = [\varphi(\mathbf{x}_1), \varphi(\mathbf{x}_2), \dots, \varphi(\mathbf{x}_N)]^T$, $\varphi(\mathbf{x}_N) = [1, K(\mathbf{x}_1, \mathbf{x}_N), K(\mathbf{x}_2, \mathbf{x}_N), \dots, K(\mathbf{x}_n, \mathbf{x}_N)]^T$, $y(\mathbf{x}_i; \mathbf{w})$ 为预测值。

根据概率预测公式, 所求的条件概率为:

$$p(\mathbf{l}_*|\mathbf{l}) = \int p(\mathbf{l}_*, \mathbf{w}, \sigma^2) p(\mathbf{w}, \sigma^2|\mathbf{l}) d\mathbf{w} d\sigma^2 \quad (13)$$

其中, $\mathbf{l}_*$ 为目标值。

为了避免直接使用最大似然方法求解 $\mathbf{w}$ 和 σ^2 而带来的过适应现象, 对 $\mathbf{w}$ 加上先决条件。根据贝叶斯理论, $\mathbf{w}$ 为分布为零的标准正态分布, 同时引入超参数 $\boldsymbol{\alpha} = [\alpha_0, \alpha_1, \dots, \alpha_N]^T$, 可得:

$$p(\mathbf{w}|\boldsymbol{\alpha}) = \prod_{i=0}^N N(w_i|0, \alpha_i^{-1}) \quad (14)$$

因此, 概率预测式改为:

$$p(\mathbf{l}_*|\mathbf{l}) = \int p(\mathbf{l}_*|\mathbf{w}, \sigma^2) p(\mathbf{w}, \boldsymbol{\alpha}, \sigma^2|\mathbf{l}) d\mathbf{w} d\boldsymbol{\alpha} d\sigma^2 \quad (15)$$

RVM 的一个重要特征就是对每个权值限定先决条件。 $\boldsymbol{\alpha}$ 为权值 $\mathbf{w}$ 对应的超参数, 符合伽马分布。经过足够的更新次数后, 大部分 α_i 会趋近无限大, 其对应的权值趋于 0, 而其他的 α_i 会稳定地趋近有限值。而与之对应的 $\mathbf{x}_i$ 称之为相关向量, 实现 RVM 稀疏特性。

在定义了先验概率分布及似然分布以后, 根据贝叶斯原理, 就可以求得所有未知参数的后验概率分布为:

$$p(\mathbf{w}|\mathbf{l}, \boldsymbol{\alpha}, \sigma^2) = (2\pi)^{-(N+1)/2} |\boldsymbol{\Psi}|^{-1/2} \times \exp\left[-\frac{1}{2}(\mathbf{w}-\boldsymbol{\mu})^T \boldsymbol{\Psi}^{-1}(\mathbf{w}-\boldsymbol{\mu})\right] \quad (16)$$

其中, $\boldsymbol{\Psi} = (\sigma^{-2} \boldsymbol{\Phi}^T \boldsymbol{\Phi} + \mathbf{A})^{-1}$, $\boldsymbol{\mu} = \sigma^{-2} \boldsymbol{\Psi} \boldsymbol{\Phi}^T \mathbf{l}$, $\mathbf{A} = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$ 。

最后使用最大似然方法可以得到估计的超参数 $\boldsymbol{\alpha}$ 和方差 σ^2 。

若给定新的输入值 $\mathbf{x}^*$, 则相应的输出概率分布服从高斯分布, 其相应的预测值为 $\mathbf{y}^* = \boldsymbol{\mu}^T \boldsymbol{\varphi}(\mathbf{x}^*)$ 。

3 风速预测的 RVM 预测模型

3.1 样本数据的预处理

为了加快样本的训练速度和收敛速度, 需要对原始样本进行预处理, 从而提高模型的预测精度。本文主要采用归一化方法对样本数据进行处理:

$$\hat{x}(i) = \frac{x(i) - x_{\min}}{x_{\max} - x_{\min}} \quad (17)$$

其中, $\hat{x}(i)$ 为归一化后的数据值, $x_{\max}$ 、 $x_{\min}$ 分别为风速样本的最大值和最小值。

3.2 RVM 模型参数的选取

RVM 是基于核函数模式的模式识别技术, 本质上讲, 核方法实现了数据空间、特征空间和类别空间之间的非线性变换。混合核函数的基本思想^[18]是将多个不同的核函数结合起来, 使得组合后的核函数具有更好的特性。

高斯核函数在众多核函数中表现出了优异的特性, 本文选择多项式核函数进行线性组合得到的函

数作为 RVM 模型的核函数。为了方便起见, 选择如下二项式函数:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \lambda G(\mathbf{x}_i, \mathbf{x}_j) + (1-\lambda) P(\mathbf{x}_i, \mathbf{x}_j) \quad (18)$$

$$G(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / \sigma^2) \quad (19)$$

$$P(\mathbf{x}_i, \mathbf{x}_j) = [(\mathbf{x}_i \cdot \mathbf{x}_j) + 1]^2 \quad (20)$$

其中, $G(\mathbf{x}_i, \mathbf{x}_j)$ 为高斯核函数; $P(\mathbf{x}_i, \mathbf{x}_j)$ 为二项式核; λ 为核函数权重, $0 \leq \lambda \leq 1$, $\lambda = 0$ 或 $\lambda = 1$ 时分别为单一核函数。

在基于核函数的模式识别技术中, 核参数的选择对结果起着至关重要的作用。RVM 预测模型中超参数 $\boldsymbol{\alpha}$ 可以通过训练自适应得到最优值, 核函数宽度 σ 和权重 λ 的选取采用网格搜索法来获得。

3.3 预测模型的评价标准

预测模型的预测效果采用平均绝对百分比误差评价, 其表达式为:

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{|Y_i|} \times 100\% \quad (21)$$

其中, Y_i 、 $\hat{Y}_i$ 分别为第 i 个实际风速值与预测风速值, n 取 96。

3.4 风速预测模型流程图

风速预测流程如图 3 所示。




图 3 风速预测流程图

Fig.3 Flowchart of wind speed forecasting

4 算例分析

本文采用某风电场前 15 天的 1440 个实测风速值作为训练样本, 数据采样间隔为 15 min, 建立 RVM 风速预测模型, 对第 16 天的 96 个采样点的风速值做提前 1 点 (即 15 min) 的预测。建立模型前对数据进行预处理, 选取合理的参数。本文嵌入维数取 8, 延迟时间取 10。

本文分别选择了 Sigmoid 函数、线性函数、二次项函数、RBF 函数及其组合函数作为核函数, 比较预测结果如表 1 所示。

表 1 不同核函数的预测结果
Tab.1 Forecasts by different kernel functions

核函数	$e_{MAPE}/\%$	核函数	$e_{MAPE}/\%$
Sigmoid 函数	10.38	RBF+Sigmoid 函数	8.75
线性函数	8.81	RBF+线性函数	8.09
二项式函数	2.62	RBF+二项式函数	2.58
RBF 函数	2.65		

由表 1 可以看出,不同的核函数对应的 e_{MAPE} 的差别很大,对于单一核函数,二项式函数的 $e_{MAPE}=2.62\%$,RBF 核函数的 $e_{MAPE}=2.65\%$,这 2 种核函数的误差远小于其余的单一核函数。本文所采用的 RBF 核函数与二项式函数的组合核函数的 $e_{MAPE}=2.58\%$,预测效果优于 RBF 核函数和其他的组合核函数。

将 RVM 模型与时间序列模型、BP 神经网络模型、SVM 模型的预测结果分别进行比较,这些模型在数据处理上基本相同,得到的提前 15 min 的预测结果如表 2 所示(由于篇幅有限,只列出部分数据)。

表 2 不同预测模型的预测结果
Tab.2 Forecasts by different forecasting models

采样点	真实值/ ($m\cdot s^{-1}$)	预测值/($m\cdot s^{-1}$)			
		时间序列	BP 神经网络	SVM	RVM
1	6.13	6.0368	6.1400	6.1454	6.1173
2	6.18	6.1147	6.2281	6.2381	6.1849
3	6.17	6.1378	6.2666	6.2919	6.2099
4	6.16	6.1153	6.2464	6.2996	6.2837
5	6.15	6.0958	6.2254	6.2986	6.2466
6	6.16	6.0687	6.2098	6.2924	6.1796
7	6.17	6.0574	6.2211	6.2973	6.1489
8	6.19	6.0782	6.2323	6.3044	6.1612
9	6.63	5.3980	6.2533	6.3187	6.1858
10	6.56	6.7115	6.6643	6.5618	6.5905
11	6.46	6.5784	6.5997	6.5421	6.5979
12	6.37	6.4081	6.5064	6.4922	6.5869
85	3.48	3.6181	3.3659	3.5160	3.5169
86	3.44	3.5354	3.2899	3.4397	3.4338
87	3.42	3.4821	3.2488	3.3951	3.3787
88	3.39	3.4844	3.2325	3.3833	3.3626
89	3.37	3.4472	3.2037	3.3583	3.3382
90	3.38	3.4229	3.1846	3.3441	3.3259
91	3.43	3.4246	3.1998	3.3632	3.3418
92	3.48	3.5038	3.2657	3.4263	3.3941
93	3.53	3.5529	3.3305	3.4878	3.4533
94	3.58	3.5900	3.3916	3.5450	3.6148
95	3.64	3.6279	3.4475	3.5984	3.6737
96	3.70	3.6882	3.5164	3.6593	3.6319

时间序列模型预测结果的 $e_{MAPE}=5.21\%$,BP 神经网络模型预测结果的 $e_{MAPE}=5.18\%$,SVM 模型预测结果的 $e_{MAPE}=3.22\%$,RVM 模型预测结果的 $e_{MAPE}=2.58\%$ 。由不同模型得到的 e_{MAPE} 可以看出,RVM 模型在风速预测中精度比其他模型高。RVM 模型计算的结果比较稳定,比 BP 神经网络模型性能优越,BP神经网络方法不能得到全局最优解,因为其采用梯度下降法优化权值,而这一优化过程只能保证收敛到其中一个点。SVM 模型性能也很好,也可以得到全局最优解,

其收敛时间为 550.98 s,但是 RVM 模型具有更高的稀疏性,能较快收敛,其收敛时间为 345.53 s,从而验证了 RVM 理论在风速预测中的可行性,具有一定的使用价值。

5 结论

本文对风速时间序列建立了非线性动力学系统模型,通过估计嵌入维数、延迟时间以及最大 Lyapunov 指数检验了该系统的混沌特性。在此基础上,借助 RVM 方法,对风速进行了短期预测。该方法克服了神经网络训练时间长、泛化能力差、易陷入局部极小等缺点,具有较强的小样本学习和泛化能力。同时通过对不同的核函数进行分析组合,选择出了 RBF 核函数与二项式函数的组合核函数作为 RVM 模型的核函数。与 SVM 相比,该方法稀疏性更高,核函数选择更加灵活,同时组合核函数的使用提高了预测的精度。作为一种新型的稀疏性学习方法,RVM 可以同时输出预测值和预测值方差,非常适用于有实时性要求的工程预测估计。

参考文献:

[1] 雷亚洲,王伟胜,戴慧珠,等. 风电对电力系统运行的价值分析[J]. 电网技术,2002,26(5):10-14.
LEI Yazhou,WANG Weisheng,DAI Huizhu,et al. Analysis of wind power value to power system operation[J]. Power System Technology,2002,26(5):10-14.

[2] 李晶,宋家骅,王伟胜. 大型变速恒频风力发电机组建模与仿真[J]. 中国电机工程学报,2004,24(6):100-105.
LI Jing,SONG Jiahua,WANG Weisheng. Modeling and dynamic simulation of variable speed wind turbine with large capacity[J]. Proceedings of the CSEE,2004,24(6):100-105.

[3] 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.

[4] 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.

[5] 蔡凯,谭伦农,李春林,等. 时间序列与神经网络法相结合的短期风速预测[J]. 电网技术,2008,32(8):82-86.
CAI Kai,TAN Lunnong,LI Chunlin,et al. Short-term wind speed forecasting combining time series and neural network method[J]. Power System Technology,2008,32(8):82-86.

[6] 李文良,卫志农,孙国强,等. 基于改进空间相关性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.
- [7] 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.
- [8] DAMOUSIS I G,DOKOPOULOS P. A fuzzy expert system for the forecasting of wind speed and power generation in wind farms[C]//IEEE Power Industry Computer Applications Conference. Sydney,NSW,Australia:[s.n.],2001:63-69.
- [9] 冬雷,王丽婕,高爽,等. 基于混沌时间序列的大型风电场发电功率预测建模与研究[J]. 电工技术学报,2008,23(12):125-129.
DONG Lei,WANG Lijie,GAO Shuang,et al. Modeling and analysis of prediction of wind power generation in the large wind farm based on chaotic time series[J]. Transactions of China Electro-technical Society,2008,23(12):125-129.
- [10] 吕涛,唐巍,所丽. 基于混沌相空间重构理论的风电场短期风速预测[J]. 电力系统保护与控制,2010,38(21):113-117.
Lǚ Tao,TANG Wei,SUO Li. Prediction of short-term wind speed in wind farm based on chaotic phase space reconstruction theory[J]. Power System Protection and Control,2010,38(21):113-117.
- [11] 韩敏. 混沌时间序列预测理论与方法[M]. 北京:中国水利水电出版社,2007:79-92.
- [12] WOLF A,SWIFT J B,SWINNEY H L,et al. Determining Lyapunov exponents from time series[J]. Physica D,1985,16(2):285.
- [13] TIPPING M E. Sparse bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research,2001,1(3):211-244.
- [14] CHEN S,GUNN S R,HARRIS C J. The relevance vector machine technique for channel equalization application[J]. IEEE Transactions on Neural Networks,2002,12(6):1529-1532.
- [15] 段青,赵建国,马艳. 相关向量机与支持向量机在负荷预测中的比较[C]//全国电气工程博士论坛. 成都:西南交通大学,2008:314-319.
- [16] 孙志刚,翟玮星,李伟伦,等. 基于 EMD 和相关向量机的短期负荷预测[J]. 电力系统及其自动化学报,2011,23(1):92-97.
SUN Zhigang,ZHAI Weixing,LI Weilun,et al. Short-term load forecasting based on EMD and RVM[J]. Proceedings of the CSU-EPSA,2011,23(1):92-97.
- [17] 黄帅栋,卫志农,高宗和,等. 基于非负矩阵分解的相关向量机短期负荷预测模型[J]. 电力系统自动化,2012,36(11):62-66.
HUANG Shuaidong,WEI Zhinong,GAO Zonghe,et al. A short-term load forecasting model based on relevance vector machine with nonnegative matrix factorization[J]. Automation of Electric Power Systems,2012,36(11):62-66.
- [18] 段青,赵建国,马艳. 优化组合核函数相关向量机电力负荷预测模型[J]. 电机与控制学报,2010,14(6):33-38.
DUAN Qing,ZHAO Jianguo,MA Yan. Relevance vector machine based on particle swarm optimization of compounding kernels in electricity load forecasting[J]. Electric Machines and Control,2010,14(6):33-38.

作者简介:

李慧杰(1969-),女,河南许昌人,工程师,硕士,主要研究方向为高压直流输电控制保护技术及新能源技术;

刘亚南(1988-),男,江苏徐州人,硕士研究生,研究方向为负荷预测(E-mail:lynwyx@163.com);

卫志农(1962-),男,江苏江阴人,教授,博士研究生导师,研究方向为电力系统运行分析与控制、输配电系统自动化等(E-mail:wzn_nj@263.net)。

Short-term wind speed forecasting model based on relevance vector machine

LI Huijie¹,LIU Yanan²,WEI Zhinong²,LI Xiaolu¹,Kwok W Cheung³,SUN Yonghui²,SUN Guoqiang²

(1. ALSTOM Grid Technology Center Co.,Ltd.,Shanghai 201114,China;

2. Research Center for Renewable Energy Generation Engineering,Ministry of Education,

Hohai University,Nanjing 210098,China;3. ALSTOM Grid Inc.,Redmond,Washington 98052,USA)

Abstract: Analysis of chronological wind speed series shows its chaos,according to which,a short-term wind speed forecasting model based on RVM(Relevance Vector Machine) is built by phase space reconstruction and its optimal kernel function is chosen by kernel function analysis. Compared to existing wind speed forecasting models,it has higher sparseness,as well as higher flexibility in kernel function selection. Simulative results show that,its forecast accuracy is higher than those of BP neural network and SVM(Support Vector Machine)-based model.

Key words: neural networks; support vector machines; relevance vector machine; phase-space reconstruction; short-term wind speed forecasting; models