

# 一种参数自调整风电功率预测模型

翟军昌<sup>1</sup>, 葛延峰<sup>2</sup>, 梁 鹏<sup>3</sup>, 高立群<sup>1</sup>

(1. 东北大学 信息科学与工程学院, 辽宁 沈阳 110819; 2. 辽宁省电力有限公司, 辽宁 沈阳 110006;  
3. 国网辽宁省电力有限公司 锦州供电公司, 辽宁 锦州 121000)

**摘 要:** 为了提高风电功率预测精度, 提出一种参数自调整风电功率预测模型. 通过加权递推最小二乘 (SWWRLS) 方法建立预测模型, 侧重当前数据对预测结果的影响, 排除了历史数据对预测结果的干扰. 模型通过加权递推的方法节省了存储空间, 并且提高了模型对外界环境数据变化的自适应性. 最后, 分别采用支持向量机 (SVM) 方法、卡尔曼滤波 (KF) 方法和本文 SWWRLS 方法, 以辽宁省某风电场的真实历史数据进行风电功率预测对比实验, 实验结果表明, 本文方法建立的模型具有较高的预测精度.

**关 键 词:** 风电功率预测; 最小二乘法; 滑动窗口; 支持向量机; 卡尔曼滤波

中图分类号: TP 301.6 文献标志码: A 文章编号: 1005-3026(2016)02-0153-04

## A Parameter Self-tuning Model for Wind Power Prediction

ZHAI Jun-chang<sup>1</sup>, GE Yan-feng<sup>2</sup>, LIANG Peng<sup>3</sup>, GAO Li-qun<sup>1</sup>

(1. School of Information Science & Engineering, Northeastern University, Shenyang 110819, China;  
2. Liaoning Electric Power Company Limited, Shenyang 110006, China; 3. Jinzhou City Power Supply Company, State Grid Liaoning Electric Power Company Limited, Jinzhou 121000, China. Corresponding author: ZHAI Jun-chang, E-mail: zhajunchang@163.com)

**Abstract:** To improve the prediction accuracy of wind power, a parameter self-tuning model is proposed. The sliding window weighted recursive least square (SWWRLS) method is used to establish the wind power prediction model, which emphasizes most recent data in the prediction, ruling out the interference of historical data. Less memory space is used in the weighted recursive model, and the adaptability of the prediction model to the external environment data is increased. Finally, the simulation is carried out on the real historical data of the wind farm in Liaoning with support vector machine, Kalman filter and SWWRLS methods, separately, and the simulation results show the superiority of the proposed method.

**Key words:** wind power prediction; least square method; sliding window; support vector machine; Kalman filter

风能是一种洁净的可再生能源, 已得到世界各国的高度重视. 迫于化石能源危机以及环境压力, 风力发电的开发和利用发展迅速. 随着风力发电规模的不断扩大, 风电场并网的需求也越来越大. 风速具有很大的随机性和间歇性, 直接影响风电场的出力大小, 削弱了电力系统中发电功率的可控性; 因此在风电并网后, 风电穿越功率超过一定值后的电网稳定和安全问题成为电力工作者急需解决的新课题. 预测风电场输出功率是解决该

问题的重要手段之一. 通常情况下, 风电场输出功率的预测周期越长, 预测误差越大; 而预测周期越短, 预测结果越好, 尤其是对风电场输出功率的超短期预测有助于预判风电功率变化趋势, 进而有助于降低风电功率不可控性对电力系统的影响, 从而保证电力系统的安全运行和有效调度<sup>[1-3]</sup>. 目前对风电场输出功率的短期预测主要包括基于数值天气预报的物理方法和基于风电场历史数据的信息统计方法.

收稿日期: 2014-12-12

基金项目: 国家自然科学基金资助项目 (61273155, 61104106).

作者简介: 翟军昌 (1978-), 男, 辽宁东港人, 东北大学博士研究生; 高立群 (1949-), 男, 辽宁沈阳人, 东北大学教授, 博士生导师.

本文首先介绍了几种常见的风电功率预测模型,然后针对现有预测模型的不足,提出了一种新的参数自调整风电功率预测模型,并且给出了迭代递推求解的方法.求解该模型时,对模型参数进行自适应调整可以提高预测速度和预测精度.通过对辽宁某风电场的历史发电数据和测风塔的测风数据进行仿真,验证了所提出方法的有效性.

## 1 风电功率预测模型

目前风电场输出功率预测模型主要包括基于物理方法的物理模型、基于自回归滑动平均和卡尔曼滤波等方法建立的时间序列预测模型,以及基于机器学习方法建立的智能模型.

### 1.1 物理模型

物理模型是根据风电场周围的地形、粗糙度、障碍物等物理信息来估计轮毂高度处的风速,然后利用功率曲线得到风机的发电量,其输入参数是数字天气预报(NWP)信息.由于气象预报每日更新的频率很低,因此该方法更适合中期风电场发电量的预测.

物理方法不需要长期大量的观测数据,但需要获得有效的气象预报数据;而风电场周围的物理信息对预测准确度也有很大影响.

### 1.2 时间序列模型

时间序列模型是根据历史数据(风速或功率),通过模式识别、参数估计和模型校验等步骤建立天气状况和输出功率的映射关系,如自回归滑动平均(ARMA)模型、卡尔曼滤波(KF)或者这两者的结合<sup>[4-7]</sup>.短期预测时,模型输入量是若干个历史功率数据和在线实时采集的数据集.

时间序列模型比较简单,短期预测性能很好;其所用数据比较单一,若对突变信息处理不好,模型随着预测时间的增加,准确性会快速下降.

### 1.3 智能模型

智能模型是在输入变量和输出功率间建立非线性映射关系,以大量历史数据作为训练样本,采用机器学习的方法建立风电功率预测模型,如神经网络和支持向量机等方法,以及这些方法的混合使用<sup>[8-10]</sup>.

智能模型预测准确度比较高,但模型复杂,计算量大,建模时需要大量历史数据;模型对环境变化的适应性较弱,需要通过大量的学习调整模型的参数.如果历史观测数据较少,该类方法的预测效果较差.

## 2 参数自调整风电功率预测模型

针对现有风电功率预测模型的不足,本文提出一种新的参数自调整风电功率预测模型.该模型形式上属于自回归滑动平均(ARMA)模型,但通过滑动窗口加权递推最小二乘(sliding window weighted recursive least squares, SWWRLS)方法建模,对模型参数进行动态调整,使模型具有自适应能力,可以提高模型对环境变化的适应性和预测精度.

在风电功率预测中,输出功率与各因素之间关系的 ARMA 模型可描述为

$$\mathbf{A}(z)y(k) = \mathbf{B}(z)u(k) + \varepsilon(k). \quad (1)$$

式中: $\mathbf{A}(z^{-1}) = 1 + a_1z^{-1} + a_2z^{-2} + \cdots + a_pz^{-p}$ ;  $\mathbf{B}(z^{-1}) = b_1z^{-1} + b_2z^{-2} + \cdots + b_qz^{-q}$ ,  $z^{-1}$  为延迟算子; $y(k)$  表示  $k$  时刻的输出量; $u(k)$  表示  $k$  时刻的输入量; $\varepsilon(k)$  为零均值噪声.

### 2.1 模型定阶

在模型(1)中,阶次( $p, q$ )可以利用阶次-残差曲线确定,也可以利用 AIC 准则确定. AIC 准则定阶虽然不受主观因素影响,但对定阶数据不满足一致性,且所定阶次往往偏高.

在模型(1)中,针对  $p, q$  的取值,组成多个组对  $\{(p, q); p = 1, 2, \cdots, q = 1, 2, \cdots\}$ , 计算相应组对所对应的 ARMA 模型的预报误差值总和:

$$J = \sum_{i=k+1}^{k+m} (y - \hat{y})^2 = \sum_{i=k+1}^{k+m} (y(i) - (-a_1\hat{y}(i-1) - \cdots - a_p\hat{y}(i-p) + b_1u(i-1) + \cdots + b_qu(i-q)))^2. \quad (2)$$

通过优化方法,选取对应最小预报误差值总和  $J^*$  对应的( $p, q$ ),即为模型的阶次.

### 2.2 模型系数的辨识

当预测模型类型确定之后,根据系统输入和输出来辨识模型的系数是系统建模的关键.记  $y(k)$  和  $u(k)$  分别为  $k$  时刻系统的输出功率和风速,将 ARMA 预测模型改写成预报误差模型形式:

$$y(k) = -a_1y(k-1) - \cdots - a_py(k-p) + b_1u(k-1) + \cdots + b_qu(k-q) + \varepsilon(k). \quad (3)$$

式中  $a_i, b_j$  为待估计系数.

如果利用历史观测数据直接通过最小二乘法来估计模型(3)中的参数  $a_i$  和  $b_j$ ,则意味着在建模中对所有历史数据等同看待,这显然不太合理.一方面过早的历史数据会对当前的短期预测产生

干扰,另一方面计算机需要存储大量的历史数据.如果利用加权最小二乘法建模,虽然淡化了以前历史观测数据的影响,但并没有完全排除其影响,仍然不可避免地需要存储大量的历史数据.本文利用滑动窗口加权递推最小二乘(SWWRLS)建模的方法来解决这个问题.记

$$\mathbf{x}(k) = [y(k-1), \dots, y(k-p), u(k-1), \dots, u(k-q)]^T,$$

其中,  $k = m, m+1, \dots$ .

$$\text{利用 } i \text{ 到 } k \text{ 时刻数据所得到的模型参数记为 } \boldsymbol{\theta}_{k,i} = [\hat{a}_1(k,i), \dots, \hat{a}_p(k,i), \hat{b}_1(k,i), \dots, \hat{b}_q(k,i)]^T,$$

其中,  $i = 1, 2, \dots; k \geq m + \max\{p, q\}$ .

当对系统进行  $m$  次观测时,会得到  $m$  组观测数据,记

$$\mathbf{Y}(k) = \begin{bmatrix} \sqrt{\lambda^{m-1}} y(k-m+1) \\ \sqrt{\lambda^{m-2}} y(k-m+2) \\ \sqrt{\lambda^{m-3}} y(k-m+3) \\ \vdots \\ y(k) \end{bmatrix},$$

$$\mathbf{X}(k) = \begin{bmatrix} \sqrt{\lambda^{m-1}} \mathbf{x}(k-m+1) \\ \sqrt{\lambda^{m-2}} \mathbf{x}(k-m+2) \\ \sqrt{\lambda^{m-3}} \mathbf{x}(k-m+3) \\ \vdots \\ \mathbf{x}(k) \end{bmatrix} =$$

$$\begin{bmatrix} \sqrt{\lambda^{m-1}} y(k-m) & \dots & \sqrt{\lambda^{m-1}} y(k-m-p) \\ \sqrt{\lambda^{m-2}} y(k-m+1) & \dots & \sqrt{\lambda^{m-2}} y(k-m-p+1) \\ \sqrt{\lambda^{m-3}} y(k-m+2) & \dots & \sqrt{\lambda^{m-3}} y(k-m-p+2) \\ \vdots & & \vdots \\ y(k-1) & \dots & y(k-p) \\ \sqrt{\lambda^{m-1}} u(k-m) & \dots & \sqrt{\lambda^{m-1}} u(k-m-q) \\ \sqrt{\lambda^{m-2}} u(k-m+1) & \dots & \sqrt{\lambda^{m-2}} u(k-m-q+1) \\ \sqrt{\lambda^{m-3}} u(k-m+2) & \dots & \sqrt{\lambda^{m-3}} u(k-m-q+2) \\ \vdots & & \vdots \\ u(k-1) & \dots & u(k-q) \end{bmatrix},$$

其中  $\lambda$  称为衰减因子,通过对观测数据的加权,可以消除历史数据对当前预测模型的影响.

为了使预测模型误差最小,令目标函数

$$J = E\{(\mathbf{Y}^T(k) - \mathbf{Y}^T(k))(\mathbf{Y}(k) - \mathbf{Y}(k))\}, \quad (4)$$

则

$$\boldsymbol{\theta}_m(k) = [a_1(k), \dots, a_p(k), b_1(k), \dots, b_q(k)]^T =$$

$$(\mathbf{X}^T(k)\mathbf{X}(k))^{-1}\mathbf{X}^T(k)\mathbf{Y}(k). \quad (5)$$

其中,  $\boldsymbol{\theta}_m(k)$  表示  $m$  次观测数据的参数估计值.

### 2.3 SWWRLS 建模算法

模型参数估计利用滑动窗口加权递推最小二乘(SWWRLS)方法,建模步骤如下:

①对于  $m$  次观测数据,在第  $i$  时刻利用  $i+m+1$  组数据对  $\boldsymbol{\theta}_{i+m-1,i}$  修正,递推求出

$$\boldsymbol{\theta}_{i+m,i} = \boldsymbol{\theta}_{i+m-1,i} + \frac{\mathbf{P}_{i+m-1,i} \mathbf{x}_{i+m}}{\lambda + \mathbf{x}_{i+m}^T \mathbf{x}_{i+m}} (y(i+m) - \mathbf{x}_{i+m}^T \boldsymbol{\theta}_{i+m-1,i}), \quad (6)$$

然后对矩阵  $\mathbf{P}_{i+m-1,i}$  递推修正,得到

$$\mathbf{P}_{i+m,i} = \frac{1}{\lambda} (\mathbf{P}_{i+m-1,i} - \frac{\mathbf{P}_{i+m-1,i} \mathbf{x}_{i+m-1} \mathbf{x}_{i+m-1}^T \mathbf{P}_{i+m-1,i}}{\lambda + \mathbf{x}_{i+m-1}^T \mathbf{x}_{i+m-1}}), \quad (7)$$

为步骤②递推做准备.

②将  $i+m+1$  组数据中最早的一组数据剔除,利用递推求出

$$\boldsymbol{\theta}_{i+m,i+1} = \boldsymbol{\theta}_{i+m,i} + \frac{\mathbf{P}_{i+m,i} \mathbf{x}_{i+m}}{\lambda + \mathbf{x}_{i+m}^T \mathbf{x}_{i+m}} (y(i) - \mathbf{x}_{i+m}^T \boldsymbol{\theta}_{i+m,i}), \quad (8)$$

然后对矩阵  $\mathbf{P}_{i+m-1,i}$  递推修正,得到

$$\mathbf{P}_{i+m,i+1} = \frac{1}{\lambda} (\mathbf{P}_{i+m,i} - \frac{\mathbf{P}_{i+m,i} \mathbf{x}_i \mathbf{x}_i^T \mathbf{P}_{i+m,i}}{\lambda + \mathbf{x}_i^T \mathbf{x}_i}), \quad (9)$$

为后面递推做准备.

式(6)~式(9)组成的滑动窗口加权递推最小二乘(SWWRLS)建模的递推算法有以下三个特点:

①排除了一定时间前的数据的影响;

②通过加权,在所利用的  $m$  组数据中更侧重于当前数据,可以为短期功率预测提供更加有效和实时的信息;

③采用滑动窗口建模,使得模型对环境的变化具有自适应性.

### 2.4 参数设置

衰减因子  $\lambda$  在  $0 \sim 1$  间取值,取值越小,表明模型中越注重当前数据;取  $\lambda = 1$ ,则表明对窗口内数据平等对待.

由于短期预报具有一定的周期性,一个周期内数据变化较大,因此滑动窗口不宜太大,但同时也要考虑最小二乘法对数据组数的要求,可以通过优化的方式选择确定  $m$  的大小.

## 3 仿真实验

选取辽宁省大唐中三家子风电场 2014 年观

测数据进行建模仿真. 为了验证本文 SWWRLS 方法的有效性, 将其与支持向量机(SVM)和卡尔曼滤波(KF)方法建立的预测模型进行对比实验. 在原始数据中每 15 min 测量一次数据, 每天测量 96 次.

实验中, 在利用 SWWRLS 方法建模时, 分别取  $p = q = 3, m = 30$ , 取  $\lambda = 0.96$ ; 在利用 SVM 建模时, 将  $t - 1$  时刻的风速和功率作为自变量,  $t$  时刻的输出功率作为因变量; 在利用 KF 建模时, 采用式(1)的 ARMA 模型形式, 系统的阶数选择为二阶, 将风速作为控制输入量, 输出功率作为输出量.

选择风电场在 2014 - 03 - 01 00:00—2014 - 03 - 02 23:00 期间的历史数据对系统建模, 每 15 min 作为一个步长预测一次, 对 2014 - 03 - 03 00:00—2014 - 03 - 03 23:00 期间的输出功率进行预测. 三种方法得到的预测输出功率平均绝对值误差(MAE)和均方根误差(RMSE)见表 1.

表 1 预测误差		
模型	MAE	RMSE
SVM	9.49	16.565
KF	8.66	10.790
SWWRLS	<b>2.39</b>	<b>3.310</b>

注: 表 1 中粗体字代表最好值.

由表 1 可以看出, SVM 方法的预测误差最大, SWWRLS 方法的预测误差最小.

三种方法得到的输出功率预测曲线见图 1.




图 1 预测输出功率曲线  
Fig. 1 Predicted curve of output power

由图 1 可以看出, 采用本文方法得到的预测曲线更接近风电场的实际输出功率, 预测精度较高; 而采用支持向量机和卡尔曼滤波方法得到的预测结果误差相对较大.

4 结 语

本文针对传统风电功率预测模型的不足, 提出了基于滑动窗口加权递推最小二乘方法的风电功率预测模型. 此方法不需要存储大量的历史数据, 通过窗口滑动和数据加权, 侧重于近期数据对风电场输出功率的影响, 使模型具有较好的自适应性, 可以应对环境数据的变化. 仿真实验结果表明, 本文建立的风电功率预测模型在短期风电功率预测中具有更高的预测精度.

参考文献:

[ 1 ] Ghadi M J, Gilani S H, Afrakhte H, et al. A novel heuristic method for wind farm power prediction: a case study [ J ]. *International Journal of Electrical Power & Energy Systems*, 2014, 63: 962 - 970.

[ 2 ] Yan G G, Liu Y, Mu G, et al. The ultra-short term prediction of wind power based on chaotic time series [ J ]. *Energy Procedia*, 2012, 17: 1490 - 1496.

[ 3 ] Costa A, Crespo A, Navarro J, et al. A review on the young history of the wind power short-term prediction [ J ]. *Renewable & Sustainable Energy Reviews*, 2008, 12 ( 6 ) : 1725 - 1744.

[ 4 ] Brown B G, Katz R W, Murphy A H. Time series models to simulate and forecast wind speed and wind power [ J ]. *Journal of Climate and Applied Meteorology*, 1984, 23 ( 8 ) : 1184 - 1195.

[ 5 ] Louka P, Galanis G, Siebert N, et al. Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering [ J ]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2008, 96 ( 12 ) : 2348 - 2362.

[ 6 ] Taylor J W, McSharry P E, Buizza R. Wind power density forecasting using ensemble predictions and time series models [ J ]. *IEEE Transactions on Energy Conversion*, 2009, 24 ( 3 ) : 775 - 782.

[ 7 ] Ding M, Zhang L J, Wu Y C. Wind speed forecast model for wind farms based on time series analysis [ J ]. *Electric Power Automation Equipment*, 2005, 25 ( 8 ) : 32 - 34.

[ 8 ] Li S, Wunsch D C, O'Hair E A, et al. Using neural networks to estimate wind turbine power generation [ J ]. *IEEE Transactions on Energy Conversion*, 2001, 16 ( 3 ) : 276 - 282.

[ 9 ] Miranda M S, Dunn R W. One-hour-ahead wind speed prediction using a Bayesian methodology [ C ] // IEEE Power Engineering Society General Meeting. Montreal, 2006 : 1 - 6.

[ 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. )