

8-5-2020

GM(2,1) Model and Identification Algorithm Based Wind Power Generation Short-term Prediction

Ziyun Wang

Key Laboratory of Advanced Process Control for Light Industry (Ministry of Education), Jiangnan University College of Internet of Things, Jiangsu Province, Wuxi 214122, China;

Zhicheng Ji

Key Laboratory of Advanced Process Control for Light Industry (Ministry of Education), Jiangnan University College of Internet of Things, Jiangsu Province, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

GM(2,1) Model and Identification Algorithm Based Wind Power Generation Short-term Prediction

Abstract

Abstract: A method based on the gray theory and identification model was proposed to predict the short-term wind power generation. GM(2,1) model was applied for establishing a wind speed prediction model with an iterative step. After the wind speed prediction procedure, a finite impulse response moving average nonlinear Hammerstein model was used in the modeling between wind speed and wind power generation. By adopting the stochastic gradient searching theory, a wind power generation forecasting algorithm was proposed. The proposed simulation shows that the presented method can forecast the real time power generation of wind turbine and raise the accuracy of the wind power prediction, and the simulation that uses the actual data from real wind farm improves the practical applicability of proposed Grey-Identification model.

Keywords

wind speed prediction, GM(2, 1) model, FIR-MA identification model, stochastic gradient algorithm

Recommended Citation

Wang Ziyun, Ji Zhicheng. GM(2,1) Model and Identification Algorithm Based Wind Power Generation Short-term Prediction[J]. Journal of System Simulation, 2015, 27(11): 2762-2769.

基于 GM(2,1)和辨识算法的风电功率短期预测研究

王子贇, 纪志成

(江南大学物联网工程学院轻工过程先进控制教育部重点实验室, 无锡 214122)

摘要: 提出一种基于灰色理论和辨识模型的风电功率短期预测的方法。采用 GM(Grey Model)(2,1) 灰色方法建立具有迭代性质的 GM(2,1) 风速预测模型。将有限输入响应滑动平均非线性辨识模型引入到风电特性曲线的建模研究中, 通过随机梯度搜索, 提出了基于辨识模型的风电功率短期预测方法。针对实际风场采样数据的研究结果表明, 所提出的灰色模型和辨识算法准确拟合了风电功率特性曲线并精确预测了风电机组的输出功率, 该方法实现了对风电功率特性曲线的实时建模, 提高了风电功率短期预测的精确性。

关键词: 风电功率预测; GM(2,1)模型; FIR-MA 辨识模型; 随机梯度

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2015) 11-2762-08

GM(2,1) Model and Identification Algorithm Based Wind Power Generation Short-term Prediction

Wang Ziyun, Ji Zhicheng

(Key Laboratory of Advanced Process Control for Light Industry (Ministry of Education),
Jiangnan University College of Internet of Things, Jiangsu Province, Wuxi 214122, China)

Abstract: A method based on the gray theory and identification model was proposed to predict the short-term wind power generation. GM(2,1) model was applied for establishing a wind speed prediction model with an iterative step. After the wind speed prediction procedure, a finite impulse response moving average nonlinear Hammerstein model was used in the modeling between wind speed and wind power generation. By adopting the stochastic gradient searching theory, a wind power generation forecasting algorithm was proposed. The proposed simulation shows that the presented method can forecast the real time power generation of wind turbine and raise the accuracy of the wind power prediction, and the simulation that uses the actual data from real wind farm improves the practical applicability of proposed Grey-Identification model.

Keywords: wind speed prediction; GM(2,1) model; FIR-MA identification model; stochastic gradient algorithm

引言

风能是一类取之不尽、用之不竭的清洁能源,



收稿日期: 2015-02-10 修回日期: 2015-05-11;
基金项目: 国家自然科学基金(61174032); 高等学校
博士学科点优先发展领域科研基金(20110093130001);
作者简介: 王子贇(1989-), 男, 江西抚州, 博士, 研
究方向为非线性系统辨识理论及风电功率预测; 纪
志成(1959-), 男, 浙江杭州, 教授, 研究方向为复
杂系统控制理论和风力发电最优控制。

因此在当前的能源危机背景下, 合理开发风力资源和开展风能利用的研究受到各国政府和专家学者们的长期关注。然而, 风能的间歇性和随机性给风电的并网和风电系统的稳定性带来了极大的挑战。如何准确的预测风电功率, 对衡量风场的风能规模和缓解电力系统调峰调度都具有重要意义, 也是当前学界研究的热点问题。

目前, 国内外研究人员在风电功率的预测领域

<http://www.china-simulation.com>

• 2762 •

已经取得了一定的成果。从预测对象角度, 可以将风电功率的预测方法分为直接预测和间接预测。在直接预测类的预测方法中, 时间序列法是最常用的风电功率预测算法^[1-4], 通过编制和分析风电场过往的风电功率数列, 根据时间序列反映出的变化趋势进行类推和延伸, 从而得出下一段时间内的风电功率预测值。此外, 小波分析^[5-6]、卡尔曼滤波法^[7-8]和支持向量机^[9-10]等方法也被用于研究风电功率预测问题。

然而, 直接法的预测过程往往忽略了对风电功率预测精度具有较大影响的物理因素, 例如风速、风向、温度等, 因此模型的稳定性不高。相比而言, 间接预测则考虑到直接预测过程的不足, 引入了更多的气象因素, 多角度的分析风电功率预测问题。通过预测风速, 随后针对风电功率特性曲线进行建模是一种常用的两步预测方式, 而提高预测精度的关键就在于提高风速的预测效果和对风电功率特性曲线的精确建模。风速预测领域的研究方法有很多^[11-13], 文献[14-15]采用空间相关法, 使用相关系数作为判据建立了分风向相关模型; 文献[16]采用多层神经网络方式构建了风速预测模型并对比了不同训练模式对建模的影响。灰色模型是一类重要的建模方式, 在风速预测领域也有广泛的应用。文献[17-19]采用灰色 GM(1,1) 模型针对风速序列进行建模, 并检验了预测误差情况。在获得风速预测值后, 通过针对风电功率特性曲线的精确拟合, 从而获得风电功率的预测值。由于风速预测的精度往往比功率预测精度高, 因此这种间接预测的效果要好于直接预测法。

本文基于上述研究, 采用经过残差修正的灰色 GM(2,1) 模型预测风速, 算法具有迭代特性, 做到采用最新的风速数据逐步代替旧的数据, 实现更精确的风速预测, 同时引入系统辨识的方法建立 FIR-MA (Finite Impulse Response Moving Average) 非线性模型, 对风速-风电功率特性曲线进行参数辨识, 通过随机梯度辨识算法得出恰当的曲线参数, 从而获得风电功率预测值, 最后本文依据实际

风场的采样结果并根据模型需要进行适当的数据处理, 筛选适用于风电功率特性曲线的建模数据, 验证了该方法及模型的可行性和有效性。

1 基于迭代灰色 GM(2,1) 的风速预测算法

1.1 GM(2,1) 风速预测模型

灰色 GM(2,1) 模型的输入向量为风场某时刻区间内的风速序列: $V^{(0)} = (v^{(0)}(1), v^{(0)}(2), \dots, v^{(0)}(n))$, 其中: $v^{(0)}(i)$ 是实测风速值; n 表示灰色 GM(2,1) 模型的维数。

该 GM(2,1) 模型对应的 1-AGO 序列 $V^{(1)}$ 和 1-IAGO 序列 $\alpha^{(1)}V^{(0)}$ 分别为:

$$V^{(1)} = (v^{(1)}(1), v^{(1)}(2), \dots, v^{(1)}(n)) \quad (1)$$

$$\alpha^{(1)}V^{(0)} = (\alpha^{(1)}v^{(0)}(2), \alpha^{(1)}v^{(0)}(3), \dots, \alpha^{(1)}v^{(0)}(n)) \quad (2)$$

其中: $\alpha^{(1)}v^{(0)}(k) = v^{(0)}(k) - v^{(0)}(k-1)$, $k = 2, 3, \dots, n$ 。

在 GM(2,1) 模型中, 风速序列的紧邻均值生成序列为 $Z^{(1)} = (z^{(1)}(2), z^{(1)}(3), \dots, z^{(1)}(n))$, 其中 $z^{(1)}(k) = \frac{1}{2}(v^{(1)}(k) + v^{(1)}(k-1))$, $k = 2, 3, \dots, n$

利用风速的 1-AGO 生成序列和 1-IAGO 序列, 构造 GM(2,1) 的风速预测模型, 具体如下:

$$\alpha^{(1)}v^{(0)}(k) + a_1v^{(0)}(k) + a_2z^{(1)}(k) = b \quad (3)$$

对应的 GM(2,1) 预测模型的白化方程为

$$\frac{d^2v^{(1)}}{dt^2} + a_1 \frac{dv^{(1)}}{dt} + a_2v^{(1)} = b \quad (4)$$

式中: a_1 和 a_2 表示 GM(2,1) 风速预测模型的发展系数; b 表示预测模型的灰色作用量。参数向量 $\theta = [a_1, a_2, b]^T$ 的最小二乘估计 $\hat{\theta}$ 可以由下式计算:

$$\hat{\theta} = [\hat{a}_1, \hat{a}_2, \hat{b}]^T = (B^T B)^{-1} B^T Y \quad (5)$$

$$\text{式中 } B = \begin{bmatrix} -v^{(0)}(2) & -z^{(1)}(2) & 1 \\ -v^{(0)}(3) & -z^{(1)}(3) & 1 \\ \vdots & \vdots & \vdots \\ -v^{(0)}(n) & -z^{(1)}(n) & 1 \end{bmatrix} \quad (6)$$

$$Y = \begin{bmatrix} \alpha^{(1)} v^{(0)}(2) \\ \alpha^{(1)} v^{(0)}(3) \\ \vdots \\ \alpha^{(1)} v^{(0)}(n) \end{bmatrix} = \begin{bmatrix} v^{(0)}(2) - v^{(0)}(1) \\ v^{(0)}(3) - v^{(0)}(2) \\ \vdots \\ v^{(0)}(n) - v^{(0)}(n-1) \end{bmatrix} \quad (7)$$

一般情况下,在实际风电场中由于风速的波动性和偶然性较大,预测过程中不可能产生重根(或共轭复根),因此在实际数据处理过程中,白化方程(4)的解为

$$\hat{v}^{(1)} = v^{(1)*} + \bar{v}^{(1)} = c_1 e^{r_1 t} + c_2 e^{r_2 t} + \frac{\hat{b}}{\hat{a}_2} \quad (8)$$

其中: r_1, r_2 是特征方程 $r^2 + \hat{a}_1 r + \hat{a}_2 = 0$ 的不等实根。由此,可得到 GM(2,1)模型的时间响应式为

$$\hat{v}^{(1)}(k+1) = c_1 e^{r_1 k} + c_2 e^{r_2 k} + \frac{\hat{b}}{\hat{a}_2} \quad (9)$$

再作 1-IAGO 还原,得到风速的预测值

$$\hat{v}^{(0)}(k) = \hat{v}^{(1)}(k) - \hat{v}^{(1)}(k-1) \quad (10)$$

1.2 具有迭代性质的 GM(2,1) 风速预测算法

采用上述灰色 GM(2,1) 预测算法,将很好的利用一元二阶方程的高阶优势,在有限数据区间的条件下更好的拟合实测风速曲线。但是,随着测量时间 t 的增加(即测量点 k 的增加),数据量将明显增大,对应的信息向量矩阵 B 和 Y 的维数也将显著增加,但原先一些测量时间较为久远的数据并没有包含目前风场的风速信息,这些“较老”的数据不仅不能提供应有的信息量,相反会增大预测的误差。

本文提出解决这一问题的方法是:将风速序列中“最老的”数据剔除,引入最新测量的风速数据,采用这种迭代思想来不断更新信息向量矩阵 B 和 Y ,在保持维数不变的情况下,提高预测的精确性。同时,引入迭代算法,对每一次风速预测过程中产生的信息向量矩阵 B 和 Y 进行辨识,得出最优的风速预测值。

设矩阵 $B(i)$ 和 $Y(i)$ 在 i 时刻的维数为 k (k 为定常数),下面列出基于迭代的灰色 GM(2,1) 风速预测算法:

$$B = \begin{bmatrix} -v^{(0)}(i) & -z^{(0)}(i) & 1 \\ -v^{(0)}(i+1) & -z^{(0)}(i+1) & 1 \\ \vdots & \vdots & \vdots \\ -v^{(0)}(i+k-1) & -z^{(0)}(i+k-1) & 1 \end{bmatrix} \quad (11)$$

$$z^{(1)}(j) = \frac{1}{2}(v^{(1)}(j) + v^{(1)}(j-1)), \\ j = i, i+1, \dots, i+k-1 \quad (12)$$

$$Y = \begin{bmatrix} v^{(0)}(i) \\ v^{(0)}(i+1) \\ \vdots \\ v^{(0)}(i+k-1) \end{bmatrix} \quad (13)$$

$$\hat{\theta}(i) = [\hat{a}_1(i), \hat{a}_2(i), \hat{b}(i)]^T = \\ (B(i)^T B(i))^{-1} B(i)^T Y(i) \quad (14)$$

$$\hat{v}^{(1)}(i+k) = c_1(i) e^{r_1(i)(i+k-1)} + \\ c_2(i) e^{r_2(i)(i+k-1)} + \frac{\hat{b}(i)}{\hat{a}_2(i)} \quad (15)$$

$$r_1(i) = -\frac{\hat{a}_1(i)}{2} + \sqrt{\frac{\hat{a}_1(i)^2}{4} - \hat{a}_2(i)} \quad (16)$$

$$r_2(i) = -\frac{\hat{a}_1(i)}{2} - \sqrt{\frac{\hat{a}_1(i)^2}{4} - \hat{a}_2(i)} \quad (17)$$

$$c_1(i) = \frac{r_2(i)v^{(0)}(i+1) - v^{(0)}(i) - r_2(i)\frac{\hat{b}(i)}{\hat{a}_2(i)}}{r_2(i) - r_1(i)} \quad (18)$$

$$c_2(i) = \frac{r_1(i)v^{(0)}(i+1) - v^{(0)}(i) - r_1(i)\frac{\hat{b}(i)}{\hat{a}_2(i)}}{r_1(i) - r_2(i)} \quad (19)$$

$$\hat{v}^{(0)}(i+k) = \hat{v}^{(1)}(i+k) - \hat{v}^{(1)}(i+k-1) \quad (20)$$

$$\hat{V}(t) = \begin{bmatrix} \hat{v}^{(0)}(i+k) \\ \hat{v}^{(0)}(i+k+1) \\ \vdots \\ \hat{v}^{(0)}(n+1) \end{bmatrix} \quad (21)$$

以下是基于迭代的灰色 GM(2,1) 风速预测算法的具体步骤:

首先,收集采样风速序列 $\{v(i): i=1, 2, \dots, n\}$, 同时设定迭代初始值 $i=1$;

由(12)计算风速的 1-AGO 序列, 并分别由(11)和(13)组成向量 B 和 Y ;

用(14)更新参数 $\hat{\theta}(i)$;

由(16)和(17)分别计算 $r_1(i), r_2(i)$, 由(18)和(19)分别计算 $c_1(i), c_2(i)$;

根据(15)计算 $i+k$ 时刻风速 1-AGO 序列的预测值 $\hat{v}^{(1)}(i+k)$;

根据(20)计算 $i+k$ 时刻风速预测值 $\hat{v}^{(0)}(i+k)$;

如果 $i+k-1 < n$, 那么 i 增加 1, 同时返回步骤 2);

由(21)获取风速时间序列的预测值 $\hat{v}(t)$ 。

2 风速-风电功率曲线的迭代辨识模型

2.1 风电功率特性曲线分析

风电机组的实时出力情况与多种因素有关, 其中包含当地的空气密度 ρ 、风机的风轮半径 R , 实时风速 v , 以及风机的风能捕获效率 $C_p(\lambda)$ 。具体的有功功率计算公式如下:

$$P_{wt} = \frac{1}{2} \rho \pi R^2 v^3 C_p(\lambda) \quad (22)$$

其中: λ 表示叶尖速比, 其大小与风轮的半径 R 、风机转子的转速 Ω_t , 以及实时风速 v 。叶尖速比 λ 的计算式为: $\lambda = \frac{R\Omega_t}{v}$

同时, 根据风机在运转过程中呈现出的不同动态特征, 按照风速区间把风机运行过程分为 4 个阶段: 切入风速以下、切入风速至额定风速之间、额定风速至切出风速之间、切出风速以上等 4 个阶段。风速-风电功率曲线的理论图如图 1 所示。




图 1 风速-风电功率曲线理论图

从图 1 可以明显看出, 风电功率特性曲线在不同的风速区间上的函数特征是不一样的, 依据风速的三个临界点: 切入风速、额定风速、切出风速, 本文从分段函数的角度, 在理论上对风电功率特性曲线进行分段建模, 具体如下:

$$P(v) = \begin{cases} 0, & 0 \leq v \leq V_{\text{切入风速}} \\ f(v), & V_{\text{切入风速}} \leq v \leq V_{\text{额定风速}} \\ P_r, & V_{\text{额定风速}} \leq v \leq V_{\text{切出风速}} \\ 0, & v \geq V_{\text{切出风速}} \end{cases}$$

然而, 上述的理论建模过程只考虑到风电功率与风速、风轮半径等常见因素有关, 没有考虑当地气象实时变化, 以及因长时间机械磨损带来的物理影响等客观因素, 因此理论建模在风电功率预测过程中往往存在较大的偏差。通过对实际风场的长时间观测, 取得大量风速、风电功率的实测数据后分析得出, 风电机组输出有功功率和风速存在非线性的函数关系(如图 2 所示)。该函数关系可以用 FIR-MA(Finite impulse response moving average, 有限输入响应滑动平均)模型的函数表达式来表述^[19], FIR-MA 模型是辨识领域中重要的一类非线性模型, 本文将风速数据作为模型的输入量, 将风电功率数据作为模型的输出量, 误差作为信号的噪声变量, 将模型中涉及到的风速向量的非线性参数和噪声变量的参数作为辨识目标, 通过负梯度搜索的方式, 达到辨识未知参数和拟合风电功率特性曲线的目的。




图 2 风电机组输出有功功率和风速的实测关系图

2.2 基于 FIR-MA 随机梯度算法的风电功率特性曲线拟合

在图 1 所示的风速-风电功率关系图中, 可以清晰看出: 风速处于切入风速至额定风速区间时, 风电功率特性曲线呈现多次函数曲线的增长趋势。用于风电功率特性曲线拟合的 FIR-MA 模型, 其函数形式如下:

$$P(t) = B(z)\bar{v}(t) + D(z)\varepsilon(t) \quad (23)$$

$$\bar{v}(t) = g(v(t)) \quad (24)$$

其中, 多项式 $B(z)$ 和 $D(z)$ 的具体表述如下:

$$B(z) = b_1 z^{-1} + b_2 z^{-2} + \dots + b_{n_b} z^{-n_b} \quad (25)$$

$$D(z) = 1 + d_1 z^{-1} + d_2 z^{-2} + \dots + d_{n_d} z^{-n_d} \quad (26)$$

多项式 $B(z)$ 和 $D(z)$ 在 FIR-MA 模型中会带来时延的效果。由于风速的变化是连续的, 因此采用历史风速数据和误差作为拟合曲线的数据来源, 更有利于拟合风电功率特性曲线。 $\bar{v}(t)$ 是关于当前时刻风速 $v(t)$ 的多次非线性函数, 具体表达式如下:

$$g(v(t)) = c_0 + c_1 g_1(v(t)) + c_2 g_2(v(t)) + c_3 g_3(v(t)) + \dots + c_{n_c} g_{n_c}(v(t)) \quad (27)$$

$$\text{令 } w(t) = D(z)\varepsilon(t) \quad (28)$$

由式(23)~(28), 可得如下风电功率特性曲线拟合模型:

$$\begin{aligned} P(t) &= b_1 \bar{v}(t-1) + b_2 \bar{v}(t-2) + \dots + \\ & b_{n_b} \bar{v}(t-n_b) + w(t) = \\ & \sum_{i=1}^{n_b} b_i \sum_{j=1}^{n_c} c_j g_j(v(t-i)) + w(t) = \\ & \sum_{i=1}^{n_b} b_i [c_1 g_1(v(t-i)) + c_2 g_2(v(t-i)) + \dots + \\ & c_{n_c} g_{n_c}(v(t-i))] + w(t) \\ & \sum_{i=1}^{n_b} c_1 b_i g_1(v(t-i)) + \sum_{i=1}^{n_b} c_2 b_i g_2(v(t-i)) + \dots + \\ & \sum_{i=1}^{n_b} c_{n_c} b_i g_{n_c}(v(t-i)) + w(t) \end{aligned}$$

分别定义该模型的参数向量和信息向量。参数

$$\text{向量 } \theta = \begin{bmatrix} \theta_s \\ \theta_n \end{bmatrix} \in \mathbb{R}^{n_b n_c + n_d}, \text{ 其中}$$

$$\theta_s = [c_1 \mathbf{b}^T, c_2 \mathbf{b}^T, \dots, c_{n_c} \mathbf{b}^T]^T \in \mathbb{R}^{n_b n_c}$$

$$\mathbf{b} = [b_1, b_2, \dots, b_{n_b}]^T \in \mathbb{R}^{n_b}$$

$$\theta_n = [d_1, d_2, \dots, d_{n_d}]^T \in \mathbb{R}^{n_d}$$

$$\text{信息向量 } \phi(t) = \begin{bmatrix} \phi_s(t) \\ \phi_n(t) \end{bmatrix} \in \mathbb{R}^{n_b n_c + n_d},$$

$$\phi_s(t) = [\psi_1^T(t), \psi_2^T(t), \dots, \psi_{n_c}^T(t)]^T \in \mathbb{R}^{n_b n_c},$$

$$\psi_i(t) = [g_i(v(t-1)), g_i(v(t-2)), \dots, g_i(v(t-n_b))]^T \in \mathbb{R}^{n_b}, i = 1, 2, \dots, n_c$$

$$\phi_n(t) = [\varepsilon(t-1), \varepsilon(t-2), \dots, \varepsilon(t-n_d)]^T \in \mathbb{R}^{n_d}$$

由此, 风电功率特性曲线模型可以表述为如下形式:

$$\begin{aligned} P(t) &= \phi_s^T(t) \theta_s + w(t) = \phi_s^T(t) \theta_s + \\ & \phi_n^T(t) \theta_n + \varepsilon(t) = \phi^T(t) \theta + \varepsilon(t) \quad (29) \end{aligned}$$

在辨识风电功率特性曲线模型参数过程中, 往往采用最小二乘辨识的方法, 将参数估计按照(29)式进行最小二乘估计。然而, 在信息向量 $\phi(t)$ 中存在噪声信号, 因此无法直接采用最小二乘算法进行辨识曲线参数。考虑到算法的可行性和高精度性, 本文采用随机梯度算法, 增加梯度算子(增益向量) $L(t)$, 使 $\theta(t)$ 收敛于真值 θ 。相比其他算法而言, 随机梯度算法不需要计算协方差矩阵, 算法的计算量将大大减小。由随机逼近原理(即负梯度搜索原理), 增益向量 $L(t)$ 的表述形式如下:

$$L(t) = u_t \phi(t) \quad (30)$$

其中: u_t 被称为收敛因子(或步长), 一般情况下, 收敛因子取 $u_t = \frac{1}{r(t)}$ 较为合适, 则随机梯度算法的一般形式如下:

$$\begin{aligned} \hat{\theta}(t) &= \hat{\theta}(t-1) + \frac{\hat{\phi}(t)}{r(t)} [y(t) - \hat{\phi}^T(t) \hat{\theta}(t-1)], \\ r(t) &= r(t-1) + \|\hat{\phi}(t)\|^2, \quad r(0) = 1 \end{aligned}$$

根据上文推导出的 FIR-MA 模型(23), (24), 结合随机梯度算法, 在采集风速、风电功率的实时数据后, 通过不断引入新的数据组, 从负梯度方向搜索, 缩小辨识误差, 最终得出模型参数准确的辨识

解。基于随机梯度辨识的风电功率特性曲线拟合的算法和步骤具体如下:

$$\hat{\theta}(t) = \begin{bmatrix} \hat{\theta}_s(t) \\ \hat{\theta}_n(t) \end{bmatrix} \quad (31)$$

$$\hat{\theta}_s(t) = [\hat{c}_1(t)\hat{b}(t)^T, \hat{c}_2(t)\hat{b}(t)^T, \dots, \hat{c}_{n_c}(t)\hat{b}(t)^T]^T \quad (32)$$

$$\hat{b}(t) = [\hat{b}_1(t), \hat{b}_2(t), \dots, \hat{b}_{n_b}(t)]^T \quad (33)$$

$$\hat{\theta}_n(t) = [\hat{d}_1(t), \hat{d}_2(t), \dots, \hat{d}_{n_d}(t)]^T \quad (34)$$

$$\hat{\phi}(t) = \begin{bmatrix} \hat{\phi}_s(t) \\ \hat{\phi}_n(t) \end{bmatrix} \quad (35)$$

$$\hat{\phi}_s(t) = [\psi_1^T(t), \psi_2^T(t), \dots, \psi_{n_c}^T(t)]^T \quad (36)$$

$$\psi_i(t) = [g_i(v(t-1)), g_i(v(t-2)), \dots, g_i(v(t-n_b))]^T \quad (37)$$

$$\hat{\phi}_n(t) = [\hat{\varepsilon}(t-1), \hat{\varepsilon}(t-2), \dots, \hat{\varepsilon}(t-n_d)]^T \quad (38)$$

$$\hat{\theta}(t) = \hat{\theta}(t-1) + \frac{\hat{\phi}(t)}{r(t)} [p(t) - \hat{\phi}^T(t)\hat{\theta}(t-1)] \quad (39)$$

$$r(t) = r(t-1) + \|\hat{\phi}(t)\|^2, \quad r(0) = 1 \quad (40)$$

$$\hat{\varepsilon}(t) = p(t) - \hat{\phi}^T(t)\hat{\theta}(t) \quad (41)$$

1. 设定初始值。令 $t=1$, 同时设置当 $t \leq 0$ 时, $\hat{\theta}(t) = 1/p_0$, $\hat{\phi}(t) = 1/p_0$, 其中, $p_0 = 10^{-6}$;

2. 收集风速和风电功率的实时数据 $\{v(t), P(t)\}$, 根据式(35)~(38)构造 $\hat{\phi}(t)$, 根据式(31)~(34)构造 $\hat{\theta}(t)$;

3. 由式(40)计算 $r(t)$, 代入式(39)计算 t 时刻的参数估计值 $\hat{\theta}(t)$;

4. 根据式(41)计算 $\hat{\varepsilon}(t)$;

5. 时间 t 自增 1, 返回步骤 2 继续辨识。

3 仿真研究

3.1 仿真效果评价指标

确定 FIR-MA 模型的阶次和具体的含参表达式后, 将灰色预测后的风速序列 $\{\hat{v}(t): t=1, 2, 3, \dots\}$ 代入经随机梯度辨识算法拟合风速-风电功率曲线。本文采用 Matlab 7.1 进行仿真, 取 5 次风速曲线为拟合模型, 误差部分取两阶, 具体的功率辨识模型表达式为

$$\hat{P}(t) = \hat{c}_0 + \hat{c}_1\hat{v}(t) + \hat{c}_2\hat{v}^2(t) + \hat{c}_3\hat{v}^3(t) + \hat{c}_4\hat{v}^4(t) + \hat{c}_5\hat{v}^5(t) + \varepsilon(t) + \hat{d}_1\varepsilon(t-1) + \hat{d}_2\varepsilon(t-2),$$

预测得出对应的风电功率预测序列 $\{\hat{P}(t): t=1, 2, 3, \dots\}$, 随后与真实的风电功率序列 $\{P(t): t=1, 2, 3, \dots\}$ 进行比较, 通过仿真得出风电功率预测效果。本文采用的评价指标具体如下:

1. 平均绝对误差 (MAPE, Mean Absolute Percentage Error)

$$MAPE_v = \frac{1}{N} \sum_{t=1}^N \frac{|v(t) - \hat{v}(t)|}{v(t)} \times 100\% \quad (42)$$

$$MAPE_p = \frac{1}{N} \sum_{t=1}^N \frac{|P(t) - \hat{P}(t)|}{P(t)} \times 100\% \quad (43)$$

其中: $v(t)$ 和 $\hat{v}(t)$ 分别表示在 t 时刻测量的实际风速和对应的预测风速值; $p(t)$ 和 $\hat{p}(t)$ 分别表示 t 时刻实测风电机组的有功功率输出值和对应的功率预测值; N 表示样本采样点的数目。

2. 均方根误差 (RMSE, Root Mean Square Error)

$$RMSE_v = \left[\frac{1}{N} \sum_{t=1}^N (v(t) - \hat{v}(t))^2 \right]^{\frac{1}{2}} \quad (44)$$

$$RMSE_p = \left[\frac{1}{N} \sum_{t=1}^N (p(t) - \hat{p}(t))^2 \right]^{\frac{1}{2}} \quad (45)$$

其中, $v(t), \hat{v}(t), p(t), \hat{p}(t), N$ 的定义和式(24), (25)中的定义相同。同样的, 均方根误差越小, 表示预测效果越好。

3. 相对误差 δ (Relative Error)

$$\delta_v(t) = \frac{|v(t) - \hat{v}(t)|}{v(t)} \times 100\% \quad (46)$$

$$\delta_p(t) = \frac{|p(t) - \hat{p}(t)|}{p(t)} \times 100\% \quad (47)$$

其中: $v(t), \hat{v}(t), p(t), \hat{p}(t)$ 的定义和式(24), (25)中的定义相同。误差 δ 越小, 预测效果越佳。

3.2 风速仿真

文章采用 Matlab 7.1 为仿真平台, 通过采集我国某风电场风电机组的实时风速、风电功率数据, 对上述风速预测算法和功率曲线辨识模型进行仿

真。该风场装机容量为 33.75 MW，共有 27 台额定功率为 1.25 MW 的风机，额定风速为 12.5 m/s，切入风速为 2.5 m/s，切出风速为 25 m/s。采样以 15 分钟为间隔，通过对该风场 2014-12-01T0:00:00~2014-12-02T23:45:00 时间段进行风速采样，48 h 内取得测量点 192 个，绘制风速图如图 3。




图3 48 h内风速-功率实测图

由如图 3 所示的风速-功率实测图，可以发现 192 组采样中，当风速 < 2.5 m/s 时(红线以下区域)，功率测量值往往在 0 附近，甚至小于 0，这是由于当风速 < 2.5 m/s 的切入风速时，风机处于宕机状态，不产出电量的同时也在消耗能量，因此必须针对测量的数据进行适当的预处理。经过排除切入风速以下的数据组，可以整理得出如图 4 所示的风速-功率实测曲线。图 4 中，97 组风速-功率数据均在切入风速以上，满足 Hammerstein FIR-MA 模型建模需求。




图4 风速和风电功率建模曲线

随后引入迭代思想，采用基于 GM(2,1)灰色模型的方法，利用前 6 组数据为初始数据，采用一步迭代预测的方式，对实测风速进行迭代运算，虽然二阶灰色模型相比一阶而言运算量较大，但 GM(2,1)模型能够更好的短期预测风速数据。与 GM(1,1)算法对比，经过 GM(2,1)模型预测的风速预测曲线如图 5 所示。

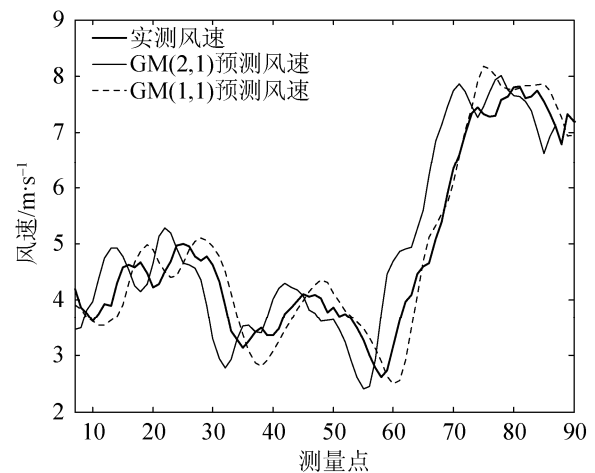


图5 基于 GM(2,1)和 GM(1,1)灰色预测后的风速变化曲线

同时，从表 1 可以看出，与基于残差的 GM(1,1)灰色预测算法相比，基于残差的 GM(2,1)灰色预测算法在风速预测上的精度更高，其平均绝对误差只有 5.088 31%，风速预测均方根误差为 0.274 25 m/s。

对风场实测风速进行灰色预测，通过对风速、风电功率数据组的实时采样，将实际测量的风速 $v(t)$ 带入随机梯度辨识算法(31)~(40)，采用 5 次函数进行随机梯度拟合，将功率单位转变为 KW，可以大幅减少运算量。拟合风速-风电功率曲线的参数辨识后，得出曲线拟合方程如下：

$$P(t) = -1431.58479 + 1619.49984v(t) - 711.78672v^2(t) + 151.86706v^3(t) - 15.54013v^4(t) + 0.61293v^5(t) + \varepsilon(t) + 0.99847\varepsilon(t-1) + 0.66596\varepsilon(t-2)$$

表1 两种预测模型预测精度对比

预测模型	MAPE/%	RMSE/m·s ⁻¹
基于残差 GM(1,1)型	7.290 31	0.394 13
基于残差 GM(2,1)型	5.088 31	0.274 25

通过辨识得到风电功率特性曲线后, 带入预测的风速数据 $\hat{v}(t)$ 到上述方程, 得出预测的输出功率曲线, 并与实测风机的输出功率曲线对比, 如图 6 所示。




图 6 功率预测曲线与功率实测曲线的比较

由图 6 可以清楚的看出, 本文提出的功率预测方法可以精确的预测风电机组的输出功率。该方法通过对风场中风速数据的实时采样, 而非采用过往的风速数据作为参考依据, 通过对风电功率特性曲线的精确拟合, 达到满意的功率预测效果。从仿真图 6 可以看出, 尤其在一些风速波动点, 风速的变化引起风机有功功率有剧烈变化, 该方法依然能够对风机的输出功率保持不错的预测精度。

4 结论

(1) 结合 GM(2,1)模型和 FIR-MA 辨识模型的优点, 在灰色预测风速的基础上, 引入高阶非线性辨识模型, 提出了随机梯度辨识的方法, 较好的拟合了风电机组的风电功率特性曲线。曲线参数辨识过程中采用的风速均为实时风速, 消减了过往风速对曲线拟合过程的影响, 同时针对风速和功率数据进行适当预处理, 筛选出切入风速以上的数据建模, 符合模型需求。

(2) 经过对实际风场风速、风电功率数据的采样和仿真分析, 基于 GM(2,1)灰色模型和辨识模型的预测方法是可行、有效的。

(3) 由本文的仿真可以看出, 灰色模型对风速的变化趋势具有较好的拟合性, 能够体现风速变化的规律, 然而在短期预测方面, 灰色模型也具有一定的迟滞性, 如何减弱这种迟滞性带来的影响是今后需要研究的方向。

参考文献:

- [1] Croonenbroeck C, Ambach D. A Selection of Time Series Models for Short- to Medium-term Wind Power Forecasting [J]. Journal of Wind Engineering and Industrial Aerodynamics (S0167-6105), 2015, 136: 201-210.
- [2] Lee W J, Hong J. A Hybrid Dynamic and Fuzzy Time Series Model for Mid-term Power Load Forecasting [J]. International Journal of Electrical Power & Energy Systems (S0142-0615), 2015, 64: 1057-1062.
- [3] Liu H P, Shi J, Erdem E. Prediction of Wind Speed Time Series Using Modified Taylor Kriging Method [J]. Energy (S0360-5442), 2010, 35(12): 4870-4879.
- [4] 常康, 丁茂生, 薛峰, 等. 超短期风电功率预测及其在安全稳定预警系统中的应用 [J]. 电力系统保护与控制 (S1674-3415), 2012, 40(12): 19-24.
- [5] 师洪涛, 杨静玲, 丁茂生, 等. 基于小波-BP 神经网络的短期风电功率预测方法 [J]. 电力系统自动化 (S1000-1026), 2011, 35(16): 44-48.
- [6] 肖迁, 李文华, 李志刚, 等. 基于改进的小波-BP 神经网络的风速和风电功率预测 [J]. 电力系统保护与控制 (S1674-3415), 2014, 42(15): 80-86.
- [7] 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 (S0258-2724), 2011, 45(5): 47-51.
- [8] Chen K L, Yu J. Short-term Wind Speed Prediction Using an Unscented Kalman Filter based State-space Support Vector Regression Approach [J]. Applied Energy (S0306-2619), 2014, 113: 690-705.
- [9] 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 (S0258-8013), 2011, 31(31): 102-108.
- [10] 凌武能, 杭乃善, 李如琦. 基于云支持向量机模型的短期风电功率预测 [J]. 电力自动化设备 (S1006-6047), 2013, 33(7): 34-38.
- [11] 王秋瑾, 张新房. 基于 WLS-SVM 的变速风力机有效风速估计 [J]. 系统仿真学报 (S1004-731X), 2005, 17(7): 1590-1593.
- [12] 周松林, 茆美琴, 苏建徽. 基于预测误差校正的支持向量机短期风速预测 [J]. 系统仿真学报 (S1004-731X), 2012, 24(4): 769-773.

(下转第 2777 页)