

8-25-2023

Modeling and Identification of Wind Power Generation System Based on Hammerstein Model

Feng Li

College of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou 213001, China, lifeng@jsut.edu.cn

Tian Zheng

College of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou 213001, China

Wei Song

College of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou 213001, 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.

Modeling and Identification of Wind Power Generation System Based on Hammerstein Model

Abstract

Abstract: A modeling and identification method of wind power generation system based on Hammerstein model is studied to establish high-precision model of wind power generation system. Firstly, 3σ criterion is used to propose the abnormal data, and the eliminated data is used to train the nominal model of the wind power generation system. Furthermore, *the Hammerstein model is used to establish the data-driven model of wind power generation system, and the combined signal composed of separable signal and actual wind speed is used as the input of the Hammerstein model.* The output of the separable signal through the nominal model and the actual power are used as the output of the Hammerstein model. Based on the input and output data of the combined signal, the parameters of static nonlinear subsystem and dynamic linear subsystem in the Hammerstein model are identified by correlation analysis and recursive extended stochastic gradient method. Simulation experiments with actual wind speed data show that the mean absolute percentage errors of the proposed method and the augmented stochastic gradient method are 4.99% and 14.73%, respectively. Compared with the extended stochastic gradient method, the average absolute percentage error of the proposed method is reduced by 9.74%. The simulation results show that the proposed method can effectively identify the Hammerstein model wind power generation system and has good prediction performance.

Keywords

wind power generation system, Hammerstein model, combined signal, two-stage identification

Recommended Citation

Li Feng, Zheng Tian, Song Wei. Modeling and Identification of Wind Power Generation System Based on Hammerstein Model[J]. Journal of System Simulation, 2023, 35(7): 1517-1525.

基于 Hammerstein 模型的风力发电系统建模与辨识

李峰, 郑天, 宋伟

(江苏理工学院 电气信息工程学院, 江苏 常州 213001)

摘要: 为建立风力发电系统的高精度模型, 研究了一种基于 Hammerstein 模型的风力发电系统的建模与辨识方法。使用 3σ 准则对异常数据进行剔除, 利用剔除后的数据训练风力发电系统的标称模型。利用 Hammerstein 模型建立风力发电系统的数据驱动模型, 并将可分离信号和实际风速构成的组合式信号作为 Hammerstein 模型输入, 可分离信号经过标称模型的输出和实际功率作为 Hammerstein 模型输出, 基于组合式信号的输入和输出数据, 利用相关分析法和带遗忘因子的递推增广随机梯度方法分别辨识 Hammerstein 模型中静态非线性子系统和动态线性子系统的参数。采用实际风速数据进行仿真实验, 提出的方法与增广随机梯度方法的平均绝对百分比误差分别为 4.99% 和 14.73%, 与增广随机梯度方法相比, 提出方法的平均绝对百分比误差减少了 9.74%。仿真结果表明, 提出的方法能够有效辨识 Hammerstein 模型风力发电系统, 具有较好的预测性能。

关键词: 风力发电系统; Hammerstein 模型; 组合式信号; 两阶段辨识

中图分类号: TP11; TP18; TP391.9 文献标志码: A 文章编号: 1004-731X(2023)07-1517-09

DOI: 10.16182/j.issn1004731x.joss.22-0246

引用格式: 李峰, 郑天, 宋伟. 基于 Hammerstein 模型的风力发电系统建模与辨识[J]. 系统仿真学报, 2023, 35(7): 1517-1525.

Reference format: Li Feng, Zheng Tian, Song Wei. Modeling and Identification of Wind Power Generation System Based on Hammerstein Model[J]. Journal of System Simulation, 2023, 35(7): 1517-1525.

Modeling and Identification of Wind Power Generation System Based on Hammerstein Model

Li Feng, Zheng Tian, Song Wei

(College of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou 213001, China)

Abstract: A modeling and identification method of wind power generation system based on Hammerstein model is studied to establish high-precision model of wind power generation system. Firstly, 3σ criterion is used to propose the abnormal data, and the eliminated data is used to train the nominal model of the wind power generation system. Furthermore, the Hammerstein model is used to establish the data-driven model of wind power generation system, and the combined signal composed of separable signal and actual wind speed is used as the input of the Hammerstein model. The output of the separable signal through the nominal model and the actual power are used as the output of the Hammerstein model. Based on the input and output data of the combined signal, the parameters of static nonlinear subsystem and dynamic linear subsystem in the Hammerstein model are identified by correlation analysis and recursive extended stochastic gradient method. Simulation experiments with actual wind speed data show that the mean absolute percentage errors of the proposed method and the augmented stochastic gradient method are 4.99% and 14.73%, respectively. Compared with the extended

收稿日期: 2022-03-22

修回日期: 2023-01-31

基金项目: 国家自然科学基金(62003151); 常州市科技计划(CJ20220065, CM20223015); 江苏高校“青蓝工程”

第一作者: 李峰(1987-), 男, 副教授, 博士, 研究方向为数据驱动的复杂非线性动态模型化。E-mail: lifeng@jsut.edu.cn

stochastic gradient method, the average absolute percentage error of the proposed method is reduced by 9.74%. The simulation results show that the proposed method can effectively identify the Hammerstein model wind power generation system and has good prediction performance.

Keywords: wind power generation system; Hammerstein model; combined signal; two-stage identification

0 引言

可再生能源可以有效地为人类社会提供能源需求, 风能作为最具代表性可再生能源之一, 可以有效改善石油资源短缺的现状以及发电过程中造成的环境污染, 因此得到了广泛的关注和快速发展^[1]。测量风速和发电机输出功率可以得到相应的风速-功率曲线。风速-功率曲线是评价风力发电机组的性能和判断风力发电机组是否发生故障的重要依据。因此, 对功率数据的研究成为研究风力发电预测和评估风力发电对电网影响的基础^[2]。

经过近年来对风力发电系统建模问题的研究, 其建模方法大致可分为物理机制建模、经典统计建模和人工智能建模^[3]。物理机制建模的原理是基于物理学模拟大气状态, 但由于大气状态不可控, 这类模型迭代时间长, 并且模型精度不高^[4]。经典统计建模主要利用自回归模型^[5]、自回归滑动平均数模型^[6]等模型建模。经典统计建模方法的优点是能挖掘隐藏在历史数据中的信息, 并有效建立风力发电系统, 缺点是这类模型的辨识过程会受到复杂非线性的影响。人工智能建模方法能够有效解决复杂非线性问题^[7], 但是根据风力发电系统的特点和风力发电曲线的描述, 风力发电系统的变化规律包括了动态线性特征和静态非线性特征, 而人工智能模型往往不能充分挖掘风电系统的线性和非线性关系。

Hammerstein 模型作为典型非线性模型, 既能描述风力发电系统的非线性特性, 也能充分挖掘风力发电系统内部的线性和非线性关系^[8]。其辨识方法可分为两大类: 同步辨识和分步辨识, 其中同步辨识主要有直接辨识法^[9]、子空间法^[10-12]、过

参数法^[13]等; 分步辨识主要有可分离最小二乘法^[14]、频域法^[15]、特殊信号法^[16-17]等。两类辨识方法的主要区别在于是否需要估计模型的中间不可测变量。同步辨识法的原理是辨识静态非线性子系统和动态线性子系统的混合参数模型, 进一步采用参数分离方法得到各子系统的参数。分步辨识法是通过特殊方法处理中间不可测变量, 实现静态非线性子系统和动态线性子系统的分离, 能够简化辨识过程, 提高辨识精度。

风力发电数据中存在大量异常数据, 其根本原因是由于风力发电本身存在设备故障、通信噪声、机组停机等不可控因素。但是由于风力发电机运行数据的采集、管理等方面上还存在很大的不足, 无法保证数据质量。因此, 数据分析和挖掘前需要对数据进行预处理, 即数据清洗环节。目前, 国内外专家学者提出了各种方法应用于风速-功率数据清洗。文献[18]采用 Thompson tau-四分位数算法来分段识别风电机组功率曲线的异常值, 但当异常值的占比较大时, 该算法的效果并不明显。文献[19]提出了一种基于变化点分组算法的异常数据清洗方法, 该方法对去除底部和中部的异常数据效果较好, 但对上部 and 周围分散的异常数据清洗效果较弱。针对上述问题, 本文提出了一种基于 Hammerstein 模型的风力发电系统 9 的建模与辨识方法。

1 风力发电数据预处理

原始风力发电数据风速功率分布曲线如图 1 所示。能够看出原始数据下风力发电机的风速-功率特性曲线呈现 S 形变化规律, 能够展示风速与发电机组功率之间的关系。风速-功率曲线可以用来设计风力发电机组控制系统, 也可以用来评估风力发电机组发电性能。风力发电机的原始功率

状态可以分为三大类: 停机状态、异常工作状态、正常工作状态。风力发电数据预处理就是保留正常工作状态, 去掉其他两类工作状态。直接删除功率为0但风速不为0的点即可筛选掉停机状态的异常数据点。




图1 风电机组风速功率曲线
Fig. 1 Wind turbine wind power curve

数据预处理的重点在于异常工作状态的风电数据清洗。本文利用 3σ 准则剔除异常数据, 首先定义一个风速步长, 将原始风电数据划分成若干区间, 每一个区间功率的均值与标准差公式为

$$P_{\text{average}} = \frac{1}{k} \sum_{i=1}^k P_i \quad (1)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^k (P_i - P_{\text{average}})^2} \quad (2)$$

式中: P_i 为采样发电功率, i 为采样个数。功率值的剩余误差公式为

$$P_{\text{error}} = |P_i - P_{\text{average}}| \quad (3)$$

当 P_{error} 超过 3σ , 即可剔除。将时间序列下的风速以及功率信号作为样本, 依次剔除异常点数据。剔除异常点后造成数据样本量不足, 用拉格朗日插值法填充缺失数据。

已知平面上有 n 个点, 且没有任意两点在一条直线上, 设 y 为 $n-1$ 次多项式, 则有

$$y = L_0 + L_1 x + L_2 x^2 + \dots + L_{n-1} x^{n-1} \quad (4)$$

将点的坐标代入式(4), 拉格朗日多项式为

$$L(X) = \sum_{i=0}^k y_i \prod_{j=0, j \neq i}^k \frac{x - x_j}{x_i - x_j} \quad (5)$$

通过上述清洗方法, 剔除数据集中的异常值, 有助于提高建立模型的精度。

2 基于 Hammerstein 模型的风力发电系统建模与辨识

2.1 基于 Hammerstein 模型风力发电系统建模

Hammerstein模型由静态非线性子系统 $f(\cdot)$ 和动态线性子系统 $L(\cdot)$ 串联成非线性动态模型, 如图2所示。根据风电-功率曲线特征分析, Hammerstein模型能够以风速为输入、以功率为输出来表示和逼近实际风力发电系统。然而, Hammerstein模型风力发电系统中的中间变量 $v(k)$ 不能直接测量。为解决这一问题, 采用前期研究工作中利用特殊的输入信号实现静态非线性子系统 $f(\cdot)$ 和动态线性子系统 $L(\cdot)$ 参数分离辨识的方法^[20], 简化了辨识过程。

在数据驱动的风力发电系统中, 由于缺少准确的机理模型来描述风力发电系统, 因此无法直接获得特殊信号的输出。为此, 本文提出了一种利用风力发电系统的标称模型来获取特殊信号的输出方法, 从而建立了具有分离辨识特征的 Hammerstein 模型风力发电系统模型, 其框架结构如图2所示。

具有分离辨识特征的 Hammerstein 模型风力发电系统模型的建立包括如下步骤:

step 1: 将风力发电系统的风速数据作为标称模型的输入 $u(k)$, 实际功率数据作为标称模型的输出 $y(k)$, 利用神经模糊模型^[21]建立风力发电系统的数据库、知识库和规则库, 得到高精度的标称模型。 $y_1(k)$ 为标称模型的估计输出, $e_1(k) = y(k) - y_1(k)$ 。

step 2: 可分离信号作为标称模型的输入, 并得到标称模型输出, 即可分离信号的输出 $y_2(k)$ 。

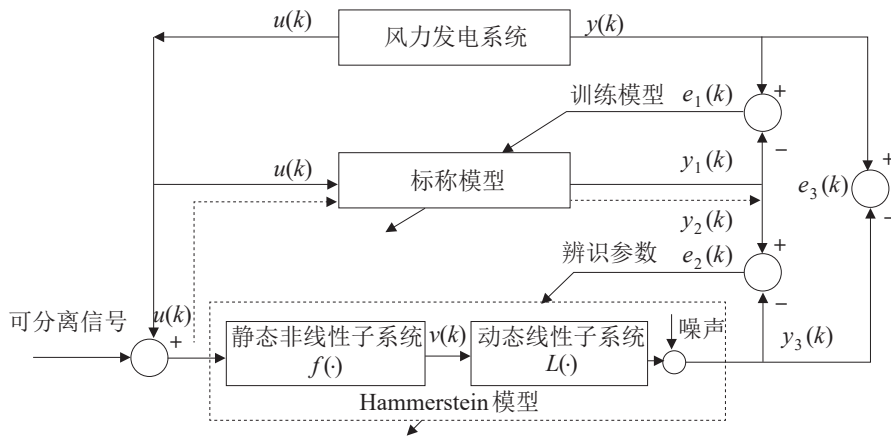


图2 基于Hammerstein模型的风力发电系统框架

Fig. 2 Wind power generation system model framework based on Hammerstein model

step 3: 将可分离信号和实际风速构成的组合式信号作为Hammerstein模型的输入,可分离信号经过标称模型的输出和实际功率作为Hammerstein模型的输出 $y_3(k)$ 。在此基础上,利用两阶段辨识方法辨识Hammerstein模型风力发电系统。

2.2 基于Hammerstein模型风力发电系统的两阶段辨识

在实际风力发电系统中,采集到的风速和功率数据容易受到噪声干扰,因此,考虑如图3所示噪声干扰下的Hammerstein模型,描述如下:

$$v(k) = f(u(k)) \tag{6}$$

$$y(k) = \frac{B(k)}{A(k)}v(k) + \frac{D(k)}{A(k)}e(k) \tag{7}$$

式中: $f(\cdot)$ 为静态非线性子系统; $v(k)$ 为静态非线性子系统的输出,为中间不可测变量; $e(k)$ 为白

噪声。

$$A(z) = 1 + a_1z^{-1} + \dots + a_{n_a}z^{-n_a}$$

$$B(z) = b_1z^{-1} + b_2z^{-2} + \dots + b_{n_b}z^{-n_b}$$

$$D(z) = 1 + d_1z^{-1} + \dots + d_{n_d}z^{-n_d}$$

式中: a_i 和 b_j 为线性子系统的参数; d_m 为噪声模型参数; n_a , n_b 和 n_d 为模型的阶次。

对于任意给定的 ϵ , Hammerstein 模型的参数要满足如下条件:

$$E = \frac{1}{2N_p} \sum_{k=1}^{N_p} (\hat{y}(k) - y(k))^2 \leq \epsilon$$

s.t.

$$\hat{v}(k) = \hat{f}(u(k)) \tag{8}$$

$$\hat{y}(k) = \frac{\hat{B}(z)}{\hat{A}(z)}\hat{v}(k) + \frac{\hat{D}(z)}{\hat{A}(z)}e(k)$$

式中: N_p 为输入输出数据的数目; 符号 $\hat{\cdot}$ 为估计。




图3 Hammerstein非线性系统
Fig. 3 Hammerstein nonlinear system

2.2.1 动态线性子系统辨识

前期的研究工作中利用组合式信号源实现静态非线性子系统 $f(\cdot)$ 和动态线性子系统 $L(\cdot)$ 参数的分离辨识^[20], 本文将组合式信号拓展到 Hammerstein 模型风力发电系统模型中, 利用可分离输入信号及其标称模型的输出辨识动态线性子系统。

定理 1: 对于 Hammerstein 模型, 如果输入信号是可分离信号, 那么存在常数 b_0 , 使得如下关系成立:

$$R_{vu}(\tau) = b_0 R_u(\tau) \quad (9)$$

式中: $R_{vu}(\tau) = E(v(k)u(k-\tau))$, 为输入 $u(k)$ 和中间不可测变量 $v(k)$ 的互协方差函数; $R_u(\tau) = E(u(k)u(k-\tau))$, 为输入 $u(k)$ 的自协方差函数; b_0 为常数。

定理 1 的证明可参照文献[21], 这里省略证明。

根据式(7)可得:

$$y(k) = -\sum_{i=1}^{n_a} a_i y(k-i) + \sum_{j=1}^{n_b} b_j v(k-j) + \sum_{m=1}^{n_d} d_m e(k-m) + e(k) \quad (10)$$

式(10)两边乘以 $u(k-\tau)$, 计算数学期望得到:

$$R_{yu}(\tau) = -\sum_{i=1}^{n_a} a_i R_{yu}(\tau-i) + \sum_{j=1}^{n_b} b_j R_{vu}(\tau-j) + \sum_{m=1}^{n_d} R_{eu}(\tau-m) + R_{eu}(\tau) \quad (11)$$

由于输出噪声和模型的输入是不相关的, 所以有 $R_{eu}(\tau) = 0$ 。因此, 可以得到:

$$R_{yu}(\tau) = -\sum_{i=1}^{n_a} a_i R_{yu}(\tau-i) + \sum_{j=1}^{n_b} b_j R_{vu}(\tau-j) \quad (12)$$

根据定理 1, 可以得到:

$$R_{yu}(\tau) = -\sum_{i=1}^{n_a} a_i R_{yu}(\tau-i) + \sum_{j=1}^{n_b} \tilde{b}_j R_u(\tau-j) \quad (13)$$

式中: $\tilde{b}_j = b_0 b_j$ 。

利用相关性分析方法估计动态线性子系统的参数, 设 $\tau = 1, 2, \dots, P, P \geq n_a + n_b$, 则

$$\theta = R\psi^T (\psi\psi^T)^{-1} \quad (14)$$

式中: $\theta = [a_1, \dots, a_{n_a}, \tilde{b}_1, \dots, \tilde{b}_{n_b}]$;

$$R = [R_{yu}(1), R_{yu}(1), \dots, R_{yu}(P)];$$

$$\psi = \begin{bmatrix} -R_{yu}(0) & -R_{yu}(1) & -R_{yu}(2) & \dots & -R_{yu}(P-1) \\ 0 & -R_{yu}(0) & -R_{yu}(1) & \dots & -R_{yu}(P-2) \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \dots & -R_{yu}(P-n_a) \\ R_u(0) & R_u(1) & R_u(2) & \dots & R_u(P-1) \\ 0 & R_u(0) & R_u(1) & \dots & R_u(P-2) \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \dots & R_u(P-n_b) \end{bmatrix}。$$

算法中采用 $R_{yu}(\tau) = \frac{1}{N} \sum_{k=1}^N y(k)u(k-\tau)$ 和 $R_u(\tau) =$

$\frac{1}{N} \sum_{k=1}^N u(k)u(k-\tau)$ 估计 $R_{yu}(\tau)$ 和 $R_u(\tau)$ 。

2.2.2 静态非线性子系统和噪声模型辨识

本文采用 4 层神经模糊模型拟合 Hammerstein 模型的静态非线性子系统^[21]。利用实际风速数据以及相应的功率数据辨识静态非线性子系统的参数。基于风电系统的风速数据, 利用聚类算法估计出模糊模型的中心 c_j 和宽度 σ_j ^[21], 由式(6)可得, 神经模糊模型的输出表示为

$$\hat{v}(k) = \hat{f}(u(k)) = \sum_{j=1}^N \phi_j(u(k)) w_j \quad (15)$$

式中: $\phi_j(u(k)) = \frac{\exp\left[-\frac{(u(k)-c_j)^2}{b_j^2}\right]}{\sum_{j=1}^N \exp\left[-\frac{(u(k)-c_j)^2}{b_j^2}\right]}$; c_j 为高斯

型隶属度函数的中心; b_j 为宽度; w_j 为权重, N 为模糊规则数。

结合式(7)和式(15)可以得到:

$$y(k) = -\sum_{i=1}^{n_a} \hat{a}_i y(k-i) + \sum_{j=1}^{n_b} \sum_{l=1}^L \hat{b}_j \phi_l(u(k)) \hat{w}_l + \sum_{m=1}^{n_d} \hat{d}_m e(k-m) + e(k) \quad (16)$$

式(16)又可表述为

$$y(k) = \Phi(k)^T \theta + e(k) \quad (17)$$

式中:

$$\begin{aligned} \Phi(k) = & [-y(k-1), \dots, -y(k-n_a), \\ & f_1(u(k-1)), \dots, f_N(u(k-1)), f_1(u(k-2)), \dots, \\ & f_N(u(k-2)), \dots, f_1(u(k-n_b)), \dots, \\ & f_N(u(k-n_b)), e(k-1), \dots, e(k-n_d)]^T \end{aligned} \quad (18)$$

$$\begin{aligned} \theta = & [\hat{a}_1, \dots, \hat{a}_{n_a}, \hat{b}_1 \hat{w}_1, \dots, \hat{b}_1 \hat{w}_N, \dots, \hat{b}_{n_b} \hat{w}_1, \dots, \\ & \hat{b}_{n_b} \hat{w}_N, \hat{d}_1, \dots, \hat{d}_{n_d}]^T \end{aligned} \quad (19)$$

定义极小化准则函数:

$$J[\theta] = \sum_{k=1}^N [y(k) - \Phi^T(k)\hat{\theta}]^2 \quad (20)$$

利用随机梯度方法辨识非线性子系统的参数:

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \frac{\Phi(k)}{r(k)} [y(k) - \Phi(k)\hat{\theta}(k-1)] \quad (21)$$

$$r(k) = r(k-1)\sigma + \|\Phi(k)\|^2 \quad (22)$$

由于 $\Phi(k)$ 包含未知噪声项 $e(k-i)$ ($i=1, 2, \dots, n_d$), 上述辨识方法不能实现。一个可行的方法是将不可测的噪声项用其估计的残差 $\hat{e}(k-i)$ 代替, 即

$$\hat{e}(k) = y(k) - \hat{\Phi}^T(k)\hat{\theta} \quad (23)$$

因此, 推导了下列带遗忘因子的递推增广随机梯度方法:

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \frac{\hat{\Phi}(k)}{r(k)} [y(k) - \hat{\Phi}(k)\hat{\theta}(k-1)] \quad (24)$$

$$r(k) = r(k-1)\sigma + \|\hat{\Phi}(k)\|^2 \quad (25)$$

$$\begin{aligned} \hat{\Phi}(k) = & [-y(k-1), \dots, -y(k-n_a), \\ & \phi_1(u(k-1)), \dots, \phi_N(u(k-1)), \phi_1(u(k-2)), \dots, \\ & \phi_N(u(k-2)), \dots, \phi_1(u(k-n_b)), \dots, \\ & \phi_N(u(k-n_b)), \hat{e}(k-1), \dots, \hat{e}(k-n_d)]^T \end{aligned} \quad (26)$$

$$\begin{aligned} \hat{\theta} = & [\hat{a}_1, \dots, \hat{a}_{n_a}, \hat{b}_1 \hat{w}_1, \dots, \hat{b}_1 \hat{w}_N, \dots, \hat{b}_{n_b} \hat{w}_1, \dots, \\ & \hat{b}_{n_b} \hat{w}_N, \hat{d}_1, \dots, \hat{d}_{n_d}]^T \end{aligned} \quad (27)$$

$$\hat{e}(k) = y(k) - \hat{\Phi}^T(k)\hat{\theta} \quad (28)$$

综上所述, Hammerstein 模型风力发电系统模型的辨识方法概括为以下步骤:

step 1: 使用 3σ 准则对采集到的风速数据和功率数据进行预处理, 剔除异常数据。

step 2: 利用清洗后的风速数据和功率数据训

练风力发电系统的标称模型。

step 3: 基于可分离输入信号以及标称模型的输出数据, 利用相关性分析方法得到线性子系统的参数估计。

step 4: 将系统的风速数据作为输入, 根据聚类算法, 计算隶属度函数的 c_l 和宽度 σ_l 。

step 5: 系统的风速和功率分别作为 Hammerstein 模型的输入和输出, 利用带遗忘因子的递推增广随机梯度方法估计非线性子系统和噪声模型的参数。

3 仿真

选取土耳其 Yalova 地区某风力发电场 3.5 MW 风力发电机组的数据集 (<https://www.kaggle.com/winternguyen/wind-power-curve-modeling/data>)。土耳其地区地形特殊, 气候类型变化大, 但规律性很强, 特征明显。根据风能资源的季节性特征, 考虑整体规律和局部特征, 选取公开数据集中大风季 (8 月) 风力发电数据, 建立相应的 Hammerstein 风力发电系统。通过上文所述的 3σ 准则数据清洗方法, 剔除异常数据, 清洗后的风速和发电机输出功率数据如图 4 所示。




图4 清洗后的风速和功率分布

Fig. 4 Wind speed and power distribution of cleaning

将清洗后实际风速为输入, 功率作为输出, 训练高精度的神经模糊标称模型。风力发电系统的标称模型训练结果如图 5 所示, 预测结果如图 6

所示。

从标称模型的训练和预测结果可以看出, 模型 MSE(mean square error)为 2.956×10^{-4} , MAE(maximum absolute error)为 0.116 9。从图 6 容易看出, 标称模型预测精度较高。




图 5 标称模型训练
Fig. 5 Training of nominal model




图 6 标称模型的预测
Fig. 6 Nominal model prediction

对于 2.2 节中提出的两阶段辨识方法, 假设多项式的阶次 $n_a=2$ 和 $n_b=2$ 。利用 1 000 组 $[-1, 1]$ 的高斯信号和清洗后随机抽取的 906 组风速数据组成组合式输入信号, 高斯信号经过标称模型的输出和实际风速对应的功率数据作为 Hammerstein 模型的输出, 图 7 展示了组合式信号的部分输入输出数据。




图 7 组合式信号的部分输入输出
Fig. 7 Partial input and output of combined signal

首先, 根据 1 000 组高斯信号的输入数据以及高斯信号经过标称模型的输出数据, 采用相关性分析方法辨识线性子系统的参数, 辨识得到的结果为 $[a_1, a_2, b_1, b_2] = [-0.934 9, -3.696 9, 0.747 7, 2.904 3]$ 。

其次, 基于清洗后的系统风速和功率数据, 利用聚类算法和带遗忘因子的随机梯度方法辨识静态非线性子系统的参数。设置参数: $S_0=0.994 9$, $\rho=2.0$ 和 $\lambda=0.01$, 图 8 给出了实际功率输出和 Hammerstein 模型风力发电系统的功率输出。从图 8 可以看出, 提出的数据清洗方法和两阶段辨识方法能够有效辨识 Hammerstein 模型风力发电系统。




图 8 Hammerstein 模型风力发电系统的功率输出
Fig. 8 Power output of Hammerstein model wind power generation system

为了验证文中提出的建模辨识方法的有效性,随机选取600组风速数据作为输入,将提出的方法用于风力发电系统的功率预测,图9给出了不同方法下的Hammerstein模型风力发电系统的功率预测输出。本文提出方法的平均绝对百分比误差(mean absolute percentage error, MAPE)为4.99%,而增广随机梯度算法^[22](extended stochastic gradient identification algorithms, ESG)的MAPE为14.73%,本文方法的平均绝对百分比误差比ESG方法减少了9.74%,因此本文方法具有较好的预测精度。

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|$$

式中: \hat{y}_i 为预测值; y_i 为真实值。




图9 Hammerstein模型风力发电系统的功率输出
Fig. 9 Power output of a Hammerstein model wind power system

4 结论

为了改善风力发电系统的预测性能,本文提出了一种基于Hammerstein非线性模型的风力发电系统的建模与辨识方法。在研究中,利用神经模糊模型和带外部干扰的自回归滑动平均模型分别建立Hammerstein模型的静态非线性模块和动态线性模块,并利用高斯信号分离静态非线性模块和动态线性模块。在此基础上,利用相关分析法和带遗忘因子的递推增广随机梯度方法分别辨识静态非线性模块和动态线性模块的参数,实现了

Hammerstein模型的分离辨识,改善了辨识的精度。仿真结果表明,提出的方法能够有效辨识Hammerstein模型风力发电系统,具有较好的预测性能。

参考文献:

- [1] Wiser R, Rand J, Seel J, et al. Expert Elicitation Survey Predicts 37% to 49% Declines in Wind Energy Costs by 2050[J]. *Nature Energy*, 2021, 6(5): 555-565.
- [2] Li Jie, Liu Chao, Zhang Pengfei, et al. Difference Between Grid Connections of Large-scale Wind Power and Conventional Synchronous Generation[J]. *Global Energy Interconnection*, 2020, 3(5): 486-493.
- [3] Ahmad T, Zhang Hongcai, Yan Biao. A Review on Renewable Energy and Electricity Requirement Forecasting Models for Smart Grid and Buildings[J]. *Sustainable Cities and Society*, 2020, 55: 102052.
- [4] 杨茂, 许传宇, 王凯旋. 基于切换输出机制的超短期风电功率预测[J]. *高电压技术*, 2022, 48(2): 420-429.
Yang Mao, Xu Chuanyu, Wang Kaixuan. Ultra-short-term Wind Power Forecasting Based on Switching Output Mechanism[J]. *High Voltage Engineering*, 2022, 48(2): 420-429.
- [5] Zhang Gang, Liu Hongchi, Zhang Jiangbin, et al. Wind Power Prediction Based on Variational Mode Decomposition Multi-frequency Combinations[J]. *Journal of Modern Power Systems and Clean Energy*, 2019, 7(2): 281-288.
- [6] Yuan Xiaohui, Tan Qingxiong, Lei Xiaohui, et al. Wind Power Prediction Using Hybrid Autoregressive Fractionally Integrated Moving Average and Least Square Support Vector Machine[J]. *Energy*, 2017, 129: 122-137.
- [7] Jonata C de Albuquerque, Ronaldo R B de Aquino, Otoni Nóbrega Neto, et al. Power Curve Modelling for Wind Turbine Using Artificial Intelligence Tools and Pre-established Inference Criteria[J]. *Journal of Modern Power Systems and Clean Energy*, 2021, 9(3): 526-533.
- [8] 王子赞, 纪志成. 基于滤波极大似然随机梯度的弃风电量预测[J]. *系统仿真学报*, 2017, 29(3): 589-594.
Wang Ziyun, Ji Zhicheng. Filtering Based Maximum Likelihood Stochastic Gradient Prediction on Wind Power Curtailment[J]. *Journal of System Simulation*, 2017, 29(3): 589-594.
- [9] Quachio R, Garcia C. MPC Relevant Identification Method for Hammerstein and Wiener Models[J]. *Journal of Process Control*, 2019, 80: 78-88.
- [10] Li Junhong, Zheng Weixing, Gu Juping, et al. A

- Recursive Identification Algorithm for Wiener Nonlinear Systems With Linear State-space Subsystem[J]. *Circuits Systems and Signal Processing*, 2018, 37(6): 2374-2393.
- [11] Ase H, Katayama T. A Subspace-based Identification of Wiener-hammerstein Benchmark Model[J]. *Control Engineering Practice*, 2015, 44: 126-137.
- [12] Jalaleddini K, Kearney R E. Subspace Identification of SISO Hammerstein Systems: Application to Stretch Reflex Identification[J]. *IEEE Transactions on Biomedical Engineering*, 2013, 60(10): 2725-2734.
- [13] Filipovic V. Recursive Identification of Block-oriented Nonlinear Systems in the Presence of Outliers[J]. *Journal of Process Control*, 2019, 78: 1-12.
- [14] 李峰, 罗印升, 李博, 等. 基于组合式信号源的 Hammerstein-Wiener 模型辨识方法[J]. *控制与决策*, 2022, 37(11): 2959-2967.
Li Feng, Luo Yinsheng, Li Bo, et al. Identification Method of the Hammerstein-wiener Model Based on Combined Signal Sources[J]. *Control and Decision*, 2022, 37(11): 2959-2967.
- [15] Rahmani M R, Farrokhi M. Identification of Neuro-fractional Hammerstein Systems: A Hybrid Frequency-/time-domain Approach[J]. *Soft Computing*, 2018, 22(24): 8097-8106.
- [16] Li Feng, Zhu Xinjian, He Naibao, et al. Parameter Learning for the Nonlinear System Described by Hammerstein Model with Output Disturbance[J]. *Asian Journal of Control*, 2023, 25(2): 886-898.
- [17] Li Feng, Jia Li. Correlation Analysis-based Error Compensation Recursive Least-square Identification Method for the Hammerstein Model[J]. *Journal of Statistical Computation and Simulation*, 2018, 88(1): 56-74.
- [18] 邹同华, 高云鹏, 伊慧娟, 等. 基于Thompson tau-四分位和多点插值的风电功率异常数据处理[J]. *电力系统自动化*, 2020, 44(15): 156-162.
Zou Tonghua, Gao Yunpeng, Yi Huijuan, et al. Processing of Wind Power Abnormal Data Based on Thompson Tau-quartile and Multi-point Interpolation[J]. *Automation of Electric Power Systems*, 2020, 44(15): 156-162.
- [19] Shen Xiaojun, Fu Xuejiao, Zhou Chongcheng. A Combined Algorithm for Cleaning Abnormal Data of Wind Turbine Power Curve Based on Change Point Grouping Algorithm and Quartile Algorithm[J]. *IEEE Transactions on Sustainable Energy*, 2019, 10(1): 46-54.
- [20] Li Feng, Jia Li, Peng Daogang, et al. Neuro-fuzzy Based Identification Method for Hammerstein Output Error Model with Colored Noise[J]. *Neurocomputing*, 2017, 244: 90-101.
- [21] Li Feng, Jia Li, Peng Daogang. Identification Method of Neuro-fuzzy-based Hammerstein Model with Coloured Noise[J]. *IET Control Theory & Applications*, 2017, 11(17): 3026-3037.
- [22] Wang Dongqing, Ding Feng. Extended Stochastic Gradient Identification Algorithms for Hammerstein-wiener ARMAX Systems[J]. *Computers & Mathematics With Applications*, 2008, 56(12): 3157-3164.