

DOI: 10.13382/j.jemi.B1902772

基于多变量相空间重构和 RBF 神经网络的光伏功率预测方法*

丁明 虞海彪 刘练 毕锐 张超

(合肥工业大学 安徽省新能源利用与节能实验室 合肥 230009)

摘要:针对光伏功率单变量预测方法的不足,设计了一种新型光伏功率多变量相空间重构预测方法。首先,基于相关性分析,选取实际光伏电站的历史光伏功率和气象因素时间序列组成多变量时间序列;然后,利用 C-C 法和虚假邻近点(false nearest neighbors, FNN)法重构光伏功率预测的多变量相空间,并以小数据法识别其混沌特性;最后,结合径向基函数(radial basis function, RBF)神经网络强大的非线性拟合能力,建立了基于多变量相空间重构和 RBF 神经网络的光伏功率预测模型。算例分析表明,相较于单变量预测方法,所提出的多变量相空间重构预测方法性能更加优越。

关键词:光伏功率;气象因素;多变量相空间重构;Pearson 相关系数;RBF 神经网络

中图分类号: TM615 **文献标识码:** A **国家标准学科分类代码:** 470.4047

Power prediction method of photovoltaic generation based on multivariable phase space reconstruction and RBF neural network

Ding Ming Yu Haibiao Liu Lian Bi Rui Zhang Chao

(Anhui New Energy Utilization and Energy Saving Laboratory, Hefei University of Technology, Hefei 230009, China)

Abstract: In view of the shortcomings of the single variable prediction method of photovoltaic (PV) power, a new multivariable phase space reconstruction prediction method of PV power is designed. Firstly, based on the correlation analysis, the historical PV power and meteorological factors time series of the actual PV power plant are selected to form multivariate time series. Then, the multivariable phase space of PV power prediction is reconstructed by C-C method and false nearest neighbors (FNN) method, and its chaotic characteristics are identified by small data method. Finally, combined with the powerful nonlinear fitting ability of radial basis function (RBF) neural network, a PV power prediction model based on multivariate phase space reconstruction and RBF neural network is established. The example analysis shows that the proposed multivariate phase space reconstruction prediction method has better performance than the single variable prediction method.

Keywords: PV power; meteorological factors; multivariate phase space reconstruction; Pearson correlation coefficient; RBF neural network

0 引言

随着光伏发电技术的发展、发电成本的降低,太阳能光伏发电产业发展非常迅速,受到了人们的广泛关注。光伏功率的随机性、波动性、间歇性,会使得高比例光伏并网对电网造成不良影响,及时、准确地预测光伏功率显得尤为重要^[1]。光伏功率预测越准,光伏并网对电网的安全稳定运行带来的风险就越小,同时能够有效地帮助

电网调度部门制定合理的调度计划。

近年来,国内外学者一直在孜孜不倦地寻找、应用各种先进的方法理论,建立光伏功率预测的数学模型,以揭示光伏功率的内在发展规律,包括神经网络^[2-3]、支持向量机^[4]、神经网络分位数回归^[5]、Copula 理论^[6]、模糊理论^[7]、灰色模型^[8]、马尔可夫链^[9]、混沌理论^[10]等。其中,混沌理论用于光伏功率预测是指光伏功率时间序列混沌系统有其内在的客观发展规律,经过一段时间的演化后会呈现一种有规律的运动,会产生一种有形的、规则

收稿日期: 2019-11-21 Received Date: 2019-11-21

* 基金项目:国家重点研发计划(2016YFB0900400)、可再生能源与工业节能安徽省工程实验室开放课题(45000-411104/012)资助项目

的轨迹(混沌吸引子)。相空间重构技术可以从光伏功率时间序列提取、恢复出这种规律,从而将光伏功率的预测问题转化为相空间中相点演化过程的讨论,利用混沌理论对光伏功率进行预测已经取得了一些成果。文献[11]针对小采样间隔光伏功率数据的多维时间序列,提出了一种基于支持向量回归(SVR)的局部预测模型。文献[12]从定性、定量两方面判定光伏功率时间序列的混沌特性后,建立了混沌结合径向基函数(RBF)神经网络的光伏功率预测模型。文献[13]在对光伏功率时间序列相空间重构后,引入小波神经网络预测光伏功率。以上方法的共同特点是均为光伏功率时间序列的单变量预测方法,建模对象只选择光伏功率这一单变量时间序列,将单一光伏功率时间序列通过相空间重构嵌入到高维状态空间后,采用非线性模型预测光伏功率,未考虑气象因素对光伏功率的影响。而光伏功率预测既受历史光伏功率时间序列数据影响,又与辐射强度、温度等气象因素密切相关。理论上,光伏功率时间序列的单变量预测方法在参数选择适当的情况下能够取得较高的预测精度。然而,实际中采集到的长度有限、含噪声的单一光伏功率时间序列无法保证其重构的相空间能够有效地恢复非线性动力系统特征^[14]。相较于单变量相空间重构,多变量相空间重构已被证明能够更为准确地描述系统特征,充分考虑了光伏功率和其影响因素之间的内在关系,包含的系统动态信息更加丰富。

基于以上分析,本文设计了一种基于多变量相空间重构和 RBF 神经网络的光伏功率预测方法,重点讨论了以下问题:光伏功率的影响因素及其相关性分析;光伏功率预测的多变量相空间重构、参数优化以及混沌特性判定;RBF 神经网络的实现结构、预测模型的建立和预测流程的设计。最终,以澳大利亚和美国两个实际光伏电站的数据验证了本文方法的有效性。

1 光伏功率影响因素及其相关性分析

光伏功率是由多种复杂变量共同作用的结果,在工程实际中,光伏功率受两方面因素影响^[15]:1)光伏阵列的转换效率、总面积和安装角度等系统参数;2)太阳辐射强度、温度等气象因素。在光伏发电系统的使用周期内,系统参数的变化是很小的,可以认为是一个常数。因此,预测模型的输入变量主要考虑太阳辐射强度、温度等气象因素的影响。选取哪些气象因素重构光伏功率预测的多变量相空间对最终的预测结果具有重要的意义。人为主观选取的气象因素带有明显的不确定性,可能会掩盖重要变量的作用、增加模型复杂度、降低模型可用性和准确性。

为了充分挖掘和定量描述光伏功率和气象因素之间

的内在关系、更加准确地选取模型输入变量,本文选用 Pearson 相关系数^[16]对光伏功率和气象因素进行相关性分析。Pearson 相关系数能够考察两个事物之间的相关程度,其计算公式如下:

$$\rho_{XY} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum (X - \bar{X})^2} \sqrt{\sum (Y - \bar{Y})^2}} \quad (1)$$

式中: X 为光伏功率; Y 为气象因素(太阳辐射强度、温度等)。其中 $\rho_{XY} \in [-1, 1]$, ρ_{XY} 绝对值越大,两个变量之间相关性越大。若 $\rho_{XY} = 0$,则两个变量不相关。表 1 为 Pearson 相关系数取值范围和相关程度之间的对应关系,根据 Pearson 相关系数分析结果,本文选择与光伏功率 Pearson 相关系数绝对值大于 0.2 或者小于但接近 0.2 的气象因素作为参与光伏功率预测的变量。需要说明的是,上述 Pearson 相关系数不是固定不变的,分析结果可能会随着光伏电站的位置以及所取数据时间段的不同而有所变化,实际应用中可对同一光伏电站可按月或季度更新 Pearson 相关系数分析结果,进而重新选取变量。这样做最大程度地考虑了不同气象因素在不同时间段对光伏功率影响程度的差异,提高了模型的动态自适应能力。

表 1 Pearson 相关系数和相关程度对应关系

Table 1 Correspondence between Pearson correlation coefficient and correlation degree

Pearson 相关系数取值范围	相关程度
$ \rho_{XY} \in [0.8, 1]$	极强相关
$ \rho_{XY} \in [0.6, 0.8)$	强相关
$ \rho_{XY} \in [0.4, 0.6)$	中等程度相关
$ \rho_{XY} \in [0.2, 0.4)$	弱相关
$ \rho_{XY} \in [0, 0.2)$	极弱相关或无相关

2 光伏功率预测的多变量相空间重构及混沌特性判定

2.1 光伏功率预测的多变量相空间重构

以光伏功率时间序列 x_1 和与光伏功率密切相关的 D 个气象因素时间序列 x_2, x_3, \dots, x_{D+1} 构成 M 维多变量时间序列 X_1, X_2, \dots, X_N ,其中 $x_i = (x_i(1), x_i(2), \dots, x_i(N))$ ($i = 1, 2, \dots, M, N$ 为单变量时间序列的长度), $X_t = (x_1(t), x_2(t), \dots, x_M(t))$ ($t = 1, 2, \dots, N$),其多变量相空间重构结果为:

$$\begin{aligned} V_n = & (x_1(n), x_1(n - \tau_1), \dots, x_1(n - (m_1 - 1)\tau_1), \\ & x_2(n), x_2(n - \tau_2), \dots, x_2(n - (m_2 - 1)\tau_2), \dots, \\ & x_M(n), x_M(n - \tau_M), \dots, x_M(n - (m_M - 1)\tau_M)) \quad (2) \end{aligned}$$

式中: $n = \max_{1 \leq i \leq M} (m_i - 1)\tau_i + 1, \dots, N$; τ_i 和 m_i 分别第 i 个单变量时间序列的延迟时间和嵌入维数。当 $M=1$ 时, V_n 退化为单变量相空间重构结果。由 Takens 嵌入定理可知, 当嵌入维数 m 或 m_i 足够大, $m = m_1 + m_2 + \dots + m_M > 2D$ 时, 其中 D 为吸引子维数, 则存在确定性映射 $F: \mathbf{R}^m \rightarrow$

\mathbf{R}^m ($m = \sum_{i=1}^M m_i$), 使得式(3)成立。

$$\mathbf{V}_{n+1} = F(\mathbf{V}_n) \quad (3)$$

其等价形式为:

$$x_i(n+1) = F_i(\mathbf{V}_n) \quad (4)$$

根据式(2)可知, 多变量相空间重构后的相点 \mathbf{V}_n 不仅包含了和仅以光伏功率 x_1 为基础的单变量相空间重构一致的演化关系, 还引入了气象因素 x_2, x_3, \dots, x_{D+1} 等耦合变量, 使得 \mathbf{V}_n 包含了更为丰富的系统信息, 能够更好地逼近原非线性动力系统的局部变化规律^[17]。要获取下一时刻光伏功率的预测值, 只需求解式(4)在 $i=1$ 时的方程即可。

2.2 光伏功率预测的多变量相空间重构参数优化

延迟时间 τ 和嵌入维数 m 是多变量相空间重构的两个重要参数。在延迟时间的众多计算方法中, C-C 法因计算简单、易于实现而被广泛使用。C-C 法的基本原理如下。

根据统计学原理, 取 $2 \leq m \leq 5, r_i = (i \cdot std)/2$ ($i=1, 2, 3, 4$; std 为时间序列的标准差), 计算下列各个变量:

$$\begin{cases} \bar{S}(\tau) = \frac{1}{16} \sum_{m=2}^5 \sum_{i=1}^4 S(m, r_i, \tau) \\ \bar{\Delta S}(\tau) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, \tau) \\ S_{cor}(\tau) = |\bar{S}(\tau)| + \bar{\Delta S}(\tau) \end{cases} \quad (5)$$

其中, $\bar{S}(\tau)$ 和 $\bar{\Delta S}(\tau)$ 反映了所求时间序列的自相关性。寻找 $\bar{S}(\tau)$ 第 1 个零点或 $\bar{\Delta S}(\tau)$ 的第 1 个局部极小值点即可确定延迟时间。对于嵌入维数 m , 本文采用 Kennel 等^[18] 提出的 FNN 法来确定。设时间序列 $\mathbf{y} = (x(1), x(2), \dots, x(N))$, 以延迟时间 τ 和不同的嵌入维数 m 重构 \mathbf{y} 的相空间, 则相空间中的相点为 $\mathbf{X}_i = [x(i), x(i+\tau), \dots, x(i+(m-1)\tau)]$, 其中 $i=1, 2, \dots, N-(m-1)\tau$ 。通过计算两相点之间的欧氏距离可以找到 \mathbf{X}_i 的最近邻点 \mathbf{X}_j 。当 m 较小时, 相空间吸引子没有完全打开, \mathbf{X}_j 并非 \mathbf{X}_i 真正的最近邻点, 称之为虚假邻近点。当 m 逐渐增大时, 虚假邻近点占总相点的比例将会慢慢下降直至小于某一阈值或者虚假邻近点不再随 m 的增加而减小, 此时认为吸引子完全展开。

定义如下判据 A 和判据 B。

判据 A:

$$\left[\frac{R_{m+1}^2(i, j) - R_m^2(i, j)}{R_m^2(i, j)} \right]^{1/2} = \frac{|x(i+m\tau) - x(j+m\tau)|}{R_m(i, j)} > R_{tol} \quad (6)$$

式中: $R_m(i, j), R_{m+1}(i, j)$ 分别为嵌入维数为 m 和 $m+1$ 时相空间任一最近邻点对 $(\mathbf{X}_i, \mathbf{X}_j)$ 之间的距离; R_{tol} 为门限值, 可在 $[10, 50]$ 取值, 本文取 $R_{tol} = 15$ 。

判据 B:

$$\frac{R_{m+1}(i, j)}{\sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - \bar{x})^2}} > A_{tol}, A_{tol} = 2 \quad (7)$$

式中: \bar{x} 为时间序列 \mathbf{y} 的均值。若最近邻点满足以上任一判据, 则为虚假邻近点。令 $m=1$ 开始统计虚假邻近点占总相点的比例。当其比例小于 5% 或者虚假邻近点不再随 m 的增加而减小时, 此时的 m 即为所求嵌入维数。

2.3 光伏功率预测的多变量时间序列混沌特性判定

光伏功率预测的多变量时间序列由多个单变量时间序列组成, 在利用混沌理论预测前, 需确定多变量时间序列是否具有混沌特性。最大李雅普诺夫 (Lyapunov) 指数是常用的判据之一, 用以表征系统是否对初始值敏感。采用抗噪能力强的小数据法计算最大 Lyapunov 指数, 具体计算原理参考文献^[19], 若其值大于 0, 则表明多变量时间序列具有混沌特性。

3 基于多变量相空间重构和 RBF 神经网络的光伏功率预测方法

基于相空间重构的光伏功率预测方法是通过相空间重构技术, 使得重构后的 m 维状态空间与光伏功率原混沌动力学系统具有等价的几何特征和相同的拓扑结构。通过系统当前的状态, 利用非线性预测模型推演光伏功率未来的发展趋势。在各种非线性预测模型中, RBF 神经网络优势明显, 具有收敛速度快、能避免陷入局部极小值、所需参数少等优点。因此, 采用 RBF 神经网络来确定光伏功率预测输出变量和输入变量之间的非线性关系。

3.1 RBF 神经网络

RBF 神经网络是一种包含输入层、隐含层、输出层的 3 层前馈神经网络, 其输出层第 k 个节点的输出可以描述为:

$$y_k = \sum_{j=1}^J w_{kj} \theta_j(\mathbf{x}) \quad (8)$$

式中: $\mathbf{x} = (x_1, x_2, \dots, x_J)$ 为输入向量; w_{kj} ($k=1, 2, \dots, K$; $j=1, 2, \dots, J$) 为隐含层第 j 个节点和输出层第 k 个节点之间的连接权重; J, K 分别为隐含层和输出层节点数; θ_j 为

隐含层第 j 个节点的输出,有:

$$\theta_j(\mathbf{x}) = \exp(-\|\mathbf{x} - \mathbf{c}_j\|^2 / 2\sigma_j^2) \quad (9)$$

式中: \mathbf{c}_j 为第 j 个基函数的中心向量; σ_j 为基宽。

定义 RBF 的总误差为:

$$E = \frac{1}{2} \sum_{q=1}^Q \sum_{k=1}^K (y_{dk}^q - y_k^q)^2 \quad (10)$$

式中: Q 为样本个数; y_k^q 、 y_{dk}^q 分别为第 q 个样本第 k 个输出层节点的预测输出和期望输出。

根据网络的总误差 E , 输出层权重 w_{ij} , 中心向量 \mathbf{c}_j , 基宽 σ_j (统一用 α 表示) 的迭代公式如下:

$$\alpha(t+1) = \alpha(t) - \eta \frac{\partial E}{\partial \alpha(t)} \quad (11)$$

式中: η 为学习率。

3.2 RBF 神经网络结构的确定

多变量相空间重构的相点 \mathbf{V}_n 同时包含了光伏功率和相应的气象信息,完整刻画了光伏功率在 m 维状态空间的变化规律,揭示了光伏功率内在的波动本质。因此将 \mathbf{V}_n 选为预测模型的输入向量,则输入层节点数确定为 $I = m$ 。此时, RBF 能够完成对光伏功率的精准预测。同时,对不同光伏电站和不同时段的光伏功率,其多变量相空间重构的嵌入维数 m 是不同的,这在一定程度上保证了预测模型的动态性和适应性。隐含层节点数直接影响神经网络的预测精度。节点数过少,无法保证较好的网络性能;节点数过多,则会增加网络的学习时间,易使网络出现“过拟合”现象。隐含层的最佳节点数 J 可通过 RBF 神经网络建模函数 $\text{net} = \text{newrb}()$ 来确定。随着隐含层节点数的不断增加,系统通过计算其对应的误差来搜寻最优的隐含层节点数。根据式(4)可知,模型通过 \mathbf{V}_n 来预测下一时刻的光伏功率 $x_1(n+1)$, 为单步预测,故输出层节点数确定为 $K = 1$ 。

3.3 光伏功率预测流程设计

基于多变量相空间重构和 RBF 神经网络的光伏功率预测方法预测步骤如图 1 所示。

1) 提取光伏电站的历史光伏功率和相应气象数据时间序列,组成光伏功率预测的多变量时间序列。

2) 分别利用 C-C 法和 FNN 法确定多变量时间序列的延迟时间 τ_i 和嵌入维数 m_i , 重构光伏功率预测的多变量相空间。

3) 建立基于 RBF 神经网络的光伏功率预测模型。确定神经网络的拓扑结构,并将样本数据分为训练样本集和测试样本集,将相点 \mathbf{V}_n 作为模型的输入, $x_1(n+1)$ 作为输出,训练 RBF 神经网络预测模型。

4) 根据所建立的模型和预测信息 \mathbf{V}_t 预测下一时刻的光伏功率 $x_1(t+1)$, 然后将 $t+1$ 时刻的光伏功率实测值加入到预测信息 \mathbf{V}_{t+1} 中,再以此预测 $t+2$ 时刻的光伏功率,依此类推,完成光伏功率的预测。

5) 待预测完所有样本点的光伏功率后,将预测结果反归一化,还原为光伏功率预测的实际值。

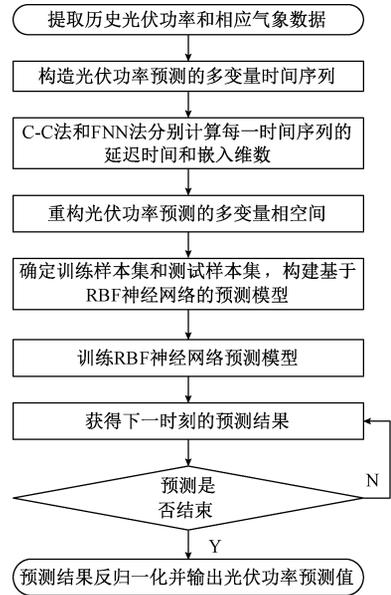


图 1 光伏功率预测流程

Fig. 1 PV power prediction flow chart

4 算例分析

4.1 算例描述

选择澳大利亚和美国两个不同装机容量光伏电站实测数据验证本文预测方法。算例 1 和算例 2 的光伏电站详细参数如表 2 所示,表 2 中, P 、 v 、 T 、 H 、 I 分别代表光伏功率、风速、温度、相对湿度、太阳辐射强度。由美国 15 kW 光伏电站的光伏功率和气象因素组成的多变量时间序列如图 2 所示。

表 2 光伏电站参数

Table 2 Detailed parameters of PV power station

光伏电站参数	算例 1	算例 2
地理位置	澳大利亚	美国
装机容量	327.6 kW	15 kW
气象数据	P 、 v 、 T 、 H 、 I	P 、 v 、 T 、 I
每天采样时段	7:00~18:00	7:00~18:00
每次采样间隔	15 min	1 h
训练时段	2016-07-06~ 2016-09-30	2015-01-01~ 2015-03-01
预测时段	2016-10-01~	2015-03-02~
	2016-10-20(20 d)	2015-3-9(8 d)

4.2 评价指标

采用国际通用的平均绝对误差 E_{MAE} 、均方根误差

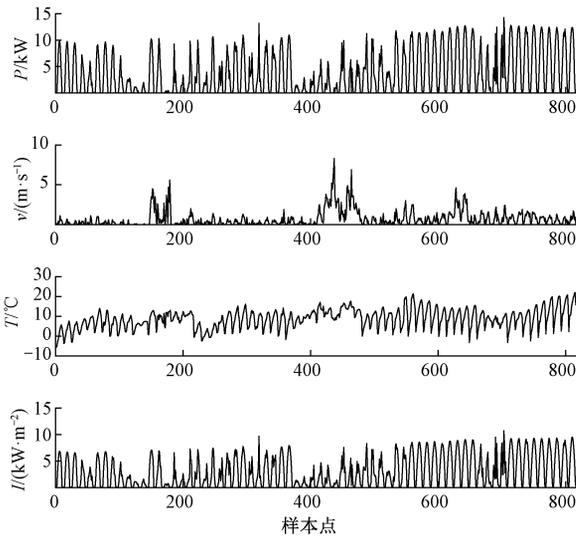


图 2 算例 2 多变量时间序列

Fig. 2 Multivariable time series of example 2

E_{RMSE} 度量本文方法的优劣, E_{MAE} 、 E_{RMSE} 分别用以表征预测方法的预测能力和预测结果的稳定性, 对应公式为:

$$E_{MAE} = \frac{1}{S} \sum_{i=1}^S \frac{|\hat{P}'_i - P'_i|}{P_N} \times 100\% \quad (12)$$

$$E_{RMSE} = \sqrt{\frac{1}{S} \sum_{i=1}^S \left(\frac{\hat{P}'_i - P'_i}{P_N} \right)^2} \times 100\% \quad (13)$$

式中: S 为预测样本个数; P'_i 、 \hat{P}'_i 分别第 i 个预测样本的实测值和预测值; P_N 为光伏电站的额定装机容量。

4.3 预测结果分析

在预测光伏功率前, 首先计算算例 1、2 的最大 Lyapunov 指数, 结果分别为 0.007 9 和 0.014 6, 两者均大于 0, 表明两个算例的多变量时间序列具有混沌特性。然后, 利用 Pearson 相关系数分析结果选取模型的输入变量, 分析结果如表 3 所示。算例 2 缺少相对湿度 H , 为表述方便, 将其 H 与 P 、 v 、 T 、 I 的相关系数全部置 0。根据表 3 选取与光伏功率相关系数绝对值大于或小于但接近于 0.2 的气象因素作为参与光伏功率预测的变量, 即算例 1、2 分别选取 P 、 v 、 T 、 H 、 I 5 个变量时间序列和 P 、 v 、 T 、 I 4 个变量时间序列构成光伏功率预测的多变量时间序列。最后, 根据 C-C 法和 FNN 法分别计算两个多变量时间序列的相空间重构参数, 计算结果如表 4 所示。

采用所提出的光伏功率多变量相空间预测方法对算例 1、2 预测时段的光伏功率进行预测, 并与单变量预测方法作比较, 部分预测结果如图 3、4 所示。从图 3、4 可以看出, 本文方法的预测功率曲线更加贴近实测功率, 能够更好地跟踪光伏功率的变化规律, 在大多数时刻预测效果更优。表 5 为两种方法的预测误差, 由表 5 可知, 基

于本文预测方法的两个算例 E_{MAE} 、 E_{RMSE} 平均值分别为 4.60% 和 6.84%, 而基于单变量预测方法的两个算例 E_{MAE} 、 E_{RMSE} 平均值分别为 5.00% 和 7.12%。本文方法能够有效减小预测误差, 显著提高了预测精度。

表 3 Pearson 相关系数分析结果

算例	变量	P	v	T	H	I
1	P	1.000	0.270	0.355	-0.338	0.807
	v	0.270	1.000	0.292	-0.291	0.283
	T	0.355	0.292	1.000	-0.687	0.427
	H	-0.338	-0.291	-0.687	1.000	-0.491
	I	0.807	0.283	0.427	-0.491	1.000
2	P	1.000	0.190	0.267	0.000	0.978
	v	0.190	1.000	0.371	0.000	0.196
	T	0.267	0.371	1.000	0.000	0.340
	H	0.000	0.000	0.000	0.000	0.000
	I	0.978	0.196	0.340	0.000	1.000

表 4 多变量时间序列相空间参数

算例	变量	τ	m
1	P	9	8
	v	13	7
	T	13	6
	H	10	7
	I	9	7
2	P	3	7
	v	6	6
	T	3	5
	I	3	7

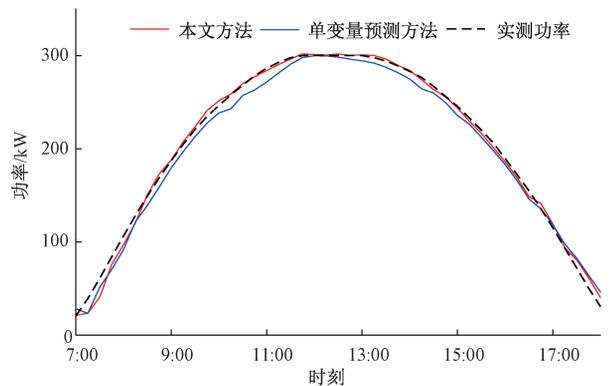


图 3 算例 1 某天预测结果

Fig. 3 Forecast result for a certain day of example 1

表 5 两种方法的预测误差

算例	预测方法	$E_{MAE}/\%$	$E_{RMSE}/\%$
1	本文方法	3.67	6.84
	单变量预测方法	4.05	7.11
2	本文方法	5.52	6.84
	单变量预测方法	5.95	7.12

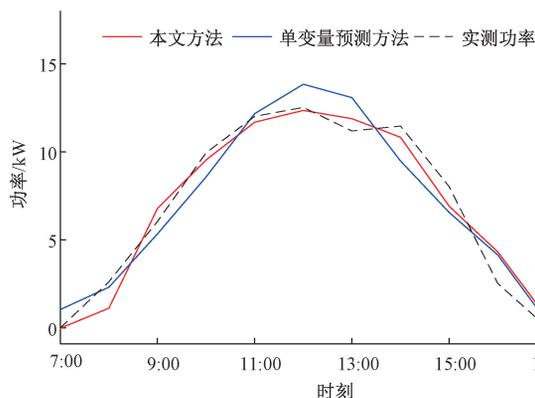


图 4 算例 2 某天预测结果

Fig. 4 Forecast result for a certain day of example 2

为了充分证明本文方法的优越性,以算例 2 美国 15 kW 光伏电站 2015 年 1~6 月的数据为训练样本,预测 2015 年 7~11 月多个月的光伏功率,预测误差如表 6 所示。通过 7~11 月两种方法的误差对比可以看出,本文方法在 7~11 月所有月份的预测精度均高于单变量预测方法,具有更好的泛化能力,在一定程度上能够减小由光伏功率波动性、随机性所带来的预测风险。以上分析充分表明,本文方法是可行的。

表 6 两种方法多月预测误差

Table 6 Multi-month prediction error of two methods

月份	预测方法	$E_{MAE}/\%$	$E_{RMSE}/\%$
7 月	本文方法	6.42	9.46
	单变量预测方法	6.93	10.25
8 月	本文方法	7.38	11.09
	单变量预测方法	7.64	11.45
9 月	本文方法	8.30	11.87
	单变量预测方法	8.95	12.55
10 月	本文方法	8.83	12.21
	单变量预测方法	9.34	12.72
11 月	本文方法	7.91	10.36
	单变量预测方法	8.40	10.97

5 结 论

在光伏功率单变量相空间重构的基础上,本文设计了一种基于多变量相空间重构和 RBF 神经网络的光伏功率预测方法。本文方法既兼顾了光伏功率单变量预测方法的优点,又综合考虑了实际光伏功率混沌系统往往受到的是多种变量的影响。算例分析表明,由光伏功率和气象因素组成的光伏功率预测的多变量时间序列能够重构出更为准确的相空间。本文方法比单变量方法具有更小的预测误差,显示出了优良的预测性能。

参考文献

- [1] 龚莺飞,鲁宗相,乔颖,等. 光伏功率预测技术[J]. 电力系统自动化,2016,40(4):140-151.
GONG Y F, LU Z X, QIAO Y, et al. An overview of photovoltaic energy system output forecasting technology[J]. Automation of Electric Power Systems, 2016, 40(4): 140-151.
- [2] HUANG C M, CHEN S J, YANG S P, et al. One-day-ahead hourly forecasting for photovoltaic power generation using an intelligent method with weather-based forecasting models [J]. IET Generation, Transmission & Distribution, 2015, 9(14): 1874-1882.
- [3] ZERVAS P L, SARIMVEIS H, PALYVOS J A, et al. Prediction of daily global solar irradiance on horizontal surfaces based on neural-network techniques [J]. Renewable Energy, 2008, 33(8): 1796-1803.
- [4] SHI J, LEE W J, LIU Y Q, et al. Forecasting power output of photovoltaic systems based on weather classification and support vector machines [J]. IEEE Transactions on Industry Applications, 2012, 48(3): 1064-1069.
- [5] 程泽,刘冲,刘力. 基于相似时刻的光伏出力概率分布估计方法[J]. 电网技术,2017,41(2):448-455.
CHENG Z, LIU CH, LIU L. A method of probabilistic distribution estimation of PV generation based on similar time of day [J]. Power System Technology, 2017, 41(2): 448-455.
- [6] 赵唯嘉,张宁,康重庆,等. 光伏发电出力的条件预测误差概率分布估计方法[J]. 电力系统自动化,2015, 39(16):8-15.
ZHAO W J, ZHANG N, KANG CH Q, et al. A method of probabilistic distribution estimation of conditional forecast error for photovoltaic power generation [J]. Automation of Electric Power Systems, 2015, 39(16): 8-15.
- [7] MONFARED M, FAZELI M, LEWIS R, et al. Fuzzy predictor with additive learning for very short-term PV power generation [J]. IEEE Access, 2019 (7): 91183-91192.
- [8] 丁明,刘志,毕锐,等. 基于灰色系统校正-小波神经网络的光伏功率预测[J]. 电网技术,2015, 39(9): 2438-2443.
DING M, LIU ZH, BI R, et al. Photovoltaic output prediction based on grey system correction-wavelet neural network[J]. Power System Technology, 2015, 39(9): 2438-2443.
- [9] 丁明,徐宁舟. 基于马尔可夫链的光伏发电系统输出功率短期预测方法[J]. 电网技术,2011, 35(1):

- 152-157.
- DING M, XU N ZH. A method to forecast short-term output power of photovoltaic generation system based on Markov chain [J]. *Power System Technology*, 2011, 35(1): 152-157.
- [10] 王建平, 谢云林, 朱程辉, 等. 基于相空间重构小波神经网络的太阳逐日辐射能量预测[J]. *太阳能学报*, 2013, 34(9): 1651-1655.
- WANG J P, XIE Y L, ZHU CH H, et al. Daily solar radiation prediction based on phase space reconstruction of wavelet neural network [J]. *Acta Energetica Solaris Sinica*, 2013, 34(9): 1651-1655.
- [11] 黄磊, 舒杰, 姜桂秀, 等. 基于多维时间序列局部支持向量回归的微网光伏发电预测[J]. *电力系统自动化*, 2014, 38(5): 19-24.
- HUANG L, SHU J, JIANG G X, et al. Photovoltaic generation forecast based on multidimensional time series and local support vector regression in microgrids [J]. *Automation of Electric Power Systems*, 2014, 38(5): 19-24.
- [12] 王育飞, 付玉超, 孙路, 等. 基于混沌-RBF神经网络的光伏发电功率超短期预测模型[J]. *电网技术*, 2018, 42(4): 1110-1116.
- WANG Y F, FU Y CH, SUN L, et al. Ultra-short term prediction model of photovoltaic output power based on chaos-RBF neural network [J]. *Power System Technology*, 2018, 42(4): 1110-1116.
- [13] 罗毅, 千雨乐. 基于相空间重构和小波神经网络的光伏阵列发电量预测[J]. *太阳能学报*, 2014, 35(6): 992-997.
- LUO Y, QIAN Y L. Power generation forecast of PV array based on phase space reconstruction and wavelet neural network [J]. *Acta Energetica Solaris Sinica*, 2014, 35(6): 992-997.
- [14] 雷绍兰, 孙才新, 周涑, 等. 电力短期负荷的多变量时间序列线性回归预测方法研究[J]. *中国电机工程学报*, 2006, 26(2): 25-29.
- LEI SH L, SUN C X, ZHOU Q, et al. The research of local linear model of short-term electrical load on multivariate time series [J]. *Proceedings of the CSEE*, 2006, 26(2): 25-29.
- [15] YONA A, SENJYU T, FUNABASHI T. Application of recurrent neural network to short-term-ahead generating power forecasting for photovoltaic system [C]. 2007 IEEE Power Engineering Society General Meeting (PES), 2007.
- [16] 赵峰, 孙波, 张承慧. 基于多变量相空间重构和卡尔曼滤波的冷热电联供系统负荷预测方法[J]. *中国电机工程学报*, 2016, 36(2): 399-406.
- ZHAO F, SUN B, ZHANG CH H. Cooling, heating and electrical load forecasting method for CCHP System based on multivariate phase space reconstruction and Kalman filter [J]. *Proceedings of the CSEE*, 2016, 36(2): 399-406.
- [17] 高光勇, 蒋国平. 采用优化极限学习机的多变量混沌时间序列预测[J]. *物理学报*, 2012, 61(4): 37-45.
- GAO G Y, JIANG G P. Prediction of multivariable chaotic time series using optimized extreme learning machine [J]. *Acta Physica Sinica*, 2012, 61(4): 37-45.
- [18] KENNEL M B, BROWN R, ABARBANEL H D I. Determining embedding dimension for phase space reconstruction using a geometrical construction [J]. *Physical Review A*, 1992, 45(6): 3403-3411.
- [19] ROSENSTEIN M T, COLLINS J J, DE LUCA C J. A practical method for calculating largest Lyapunov exponents from small data sets [J]. *Physical D: Nonlinear Phenomena*, 1993, 65(1-2): 117-134.

作者简介



丁明, 1984年于西安交通大学获得硕士学位, 现为合肥工业大学教授、博士生导师, 主要研究方向为电力系统规划及其可靠性、新能源技术及其应用。

E-mail: mingding56@126.com

Ding Ming received his M. Sc. degree from Xi'an Jiaotong University in 1984. Now he is a professor, Ph. D. supervisor at Hefei University of Technology. His main research interests include power planning and its reliability, new energy technology and application.



虞海彪(通信作者), 2016年于合肥工业大学获得学士学位, 现为合肥工业大学硕士研究生, 主要研究方向为光伏功率预测。

E-mail: yhb1599626951@163.com

Yu Haibiao (Corresponding author) received his B. Sc. degree from Hefei University of Technology in 2016. Now he is a M. Sc. candidate at Hefei University of Technology. His main research interests include photovoltaic power prediction.