

# 基于混沌特性分析和 Volterra 滤波器的光伏出力预测

虞海彪<sup>1</sup>, 李 林<sup>1,2</sup>, 丁 明<sup>1</sup>, 刘 练<sup>1</sup>, 高平平<sup>1</sup>

(1. 安徽省新能源利用与节能实验室, 合肥工业大学, 安徽 合肥 230009;  
2. 科大智能(合肥)科技有限公司, 安徽 合肥 230080)

**摘要:**在混沌理论中,现有嵌入维数计算方法往往难以获得时间序列的最佳嵌入维数,不同计算方法获得的嵌入维数稍有不同,相应光伏出力的预测结果也就不同。为减小嵌入维数对预测结果的影响,在分析光伏出力时间序列非线性动力学特性的基础上,设计了一种基于多嵌入维数的 Volterra 组合预测模型。组合模型采用神经网络对各嵌入维数下的 Volterra 单一模型进行组合,单一预测模型均采用性能表现最好的 2 阶 Volterra 滤波器。仿真结果验证了组合模型的可行性和有效性。

**关键词:**光伏出力;混沌特性;Volterra 滤波器;多嵌入维数;组合预测

**DOI:** 10.12067/ATEEE1909054      **文章编号:** 1003-3076(2020)10-0039-08      **中图分类号:** TM615

## 1 引言

随着光伏发电技术的迅速发展以及大规模集中并网光伏电站容量的不断增加,光伏发电系统已成为电力系统的重要组成部分<sup>[1,2]</sup>。及时、准确的光伏出力预测对电力系统的安全稳定运行以及经济调度至关重要。国内外学者对光伏出力预测进行了广泛研究,已经探索出了一些行之有效的预测方法,如时间序列法、神经网络法、支持向量机法等<sup>[3-7]</sup>。以上方法的共同特点是预先建立光伏出力时间序列的主观数学模型,再根据已建立的模型计算和预测,未考虑光伏出力时间序列可能具有的混沌特性。实际光伏出力系统是一个时变、具有高度不确定性和复杂非线性的系统,理论上,基于光伏出力非线性动力学特性分析的混沌预测法能够提高预测的精度和可靠性。相空间重构是光伏出力混沌预测的前提,而相空间重构的关键在于延迟时间和嵌入维数的选取。文献[8]利用最小预测误差法确定光伏出力的嵌入维数,建立了基于支持向量机的提前 1 h 光伏功率预测模型。文献[9,10]以 C-C 法确定时间序

列的嵌入维数,然后利用神经网络对光伏出力时间序列进行建模。上述方法在计算嵌入维数时,均采用某一种方法来获得单一、确定的嵌入维数。在实际应用中,利用不同方法计算得到的嵌入维数可能略有不同,重构的相空间也就不同,预测的结果也会随之改变。

意大利数学家 Volterra 首先提出了 Volterra 泛函级数,张家树等在此基础上提出了混沌时间序列的 Volterra 自适应预测法<sup>[11]</sup>,该预测方法可自动追踪混沌运动轨迹,预测精度较高<sup>[12]</sup>,近些年来已被广泛应用于风电、供热负荷、交通流量等领域。

基于以上分析,本文首先以实际光伏出力数据为研究对象,分别利用互信息法、Cao 氏法确定光伏出力时间序列的延迟时间和嵌入维数,重构光伏出力相空间;然后,以递归图法对其进行非线性动力学特性分析,验证光伏出力时间序列具有混沌特性;最后,采用 Volterra 自适应滤波器预测光伏出力,在此基础上,建立了基于多嵌入维数的神经网络组合模型。算例分析表明,建立的光伏出力组合模型具有较高的预测精度。

**收稿日期:** 2019-09-26  
**基金项目:** 国家重点研发计划资助项目(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)  
**作者简介:** 虞海彪(1993-),男,安徽籍,硕士研究生,研究方向为电力系统分析与运行;  
李 林(1979-),男,安徽籍,博士研究生,研究方向为配电网自动化及新能源接入技术。

2 光伏出力时间序列混沌特性分析

混沌是非线性动力系统的固有特性,是一种发生在确定性系统中的类随机、不规则的复杂运动。研究系统混沌特性的目的就是要挖掘这种貌似随机的运动内部存在的客观发展规律,并以此来推演系统未来的发展趋势。混沌系统因其对初始值敏感依赖性不能长期预测,但又由于其是一种确定性系统,可对其进行短期预测<sup>[13]</sup>。实际的光伏出力受太阳辐射、温度等多种因素的影响,在一个大的时间尺度范围内,其随日出日落有一个上升-保持-下降的过程,表现出一定的稳定性、规律性;在一个较小的时间尺度内,由于云层、温度等的影响又表现出随机性和波动性。这些多种复杂因素的作用使得光伏出力时间序列表现出混沌特性。研究光伏出力的混沌特性可以为光伏出力的预测提供一个新的途径,对提高其预测精度有着重要意义。

Takens 理论认为,只要选取合适的延迟时间和嵌入维数,则相空间重构后的高维状态空间与原混沌系统的几何特征是等价的,并且具有相同的拓扑结构,这为混沌时间序列的预测奠定了坚实的理论基础<sup>[14]</sup>。

对光伏出力时间序列  $\{x(i)\}_{i=1}^N$  ( $N$  为光伏出力时间序列的长度)而言,其相空间重构的结果为:

$$\mathbf{X}(i) = [x(i), x(i + \tau), \cdots, x(i + (m - 1)\tau)]$$

(1)

式中,  $\mathbf{X}(i)$  为相空间重构后第  $i$  个相点;  $\tau$ 、 $m$  分别为延迟时间和嵌入维数;  $i = 1, 2, \cdots, M$ ; 相点个数  $M = N - (m - 1)\tau$ 。目前,对于  $\tau$  和  $m$  两个参数的选取,互信息法<sup>[15]</sup>和 Cao 氏法<sup>[16]</sup>是常用且效果较好的方法。因此,本文采用互信息法确定延迟时间,利用 Cao 氏法确定嵌入维数。

2.1 互信息法确定延迟时间

对光伏出力时间序列  $\{x(i)\}_{i=1}^N$ ,  $x(i)$  和  $x(i + \tau)$  之间的互信息函数为:

$$I(\tau) = \sum_{i=1}^N P[x(i), x(i + \tau)] \log_2 \frac{P[x(i), x(i + \tau)]}{P[x(i)]P[x(i + \tau)]}$$

(2)

式中,  $P[x(i), x(i + \tau)]$  为  $x(i)$  和  $x(i + \tau)$  的联合概率;  $P[x(i)]$ 、 $P[x(i + \tau)]$  分别为  $x(i)$  和  $x(i + \tau)$  的概率。互信息法将互信息函数的第一个局部极小值点作为最佳延迟时间。以互信息法求取光伏

出力时间序列的延迟时间  $\tau$ ,其计算结果如图 1 和表 1 所示。可以看出,光伏出力时间序列的互信息函数  $I(\tau)$  在  $\tau$  为 22 时取得第一个极小值,故光伏出力时间序列的延迟时间取  $\tau = 22$ 。




图 1 平均互信息-延迟时间关系曲线  
Fig.1 Relationship between average mutual information and delay time

表 1 平均互信息和延迟时间对应关系表

Tab.1 Correspondence table of average mutual information and delay time

延迟时间/ ×5min	平均互信息	延迟时间/ ×5min	平均互信息	延迟时间/ ×5min	平均互信息
1	3.137 1	11	2.137 6	21	1.888 7
2	2.779 9	12	2.104 6	22	1.856 4
3	2.640 7	13	2.050 1	23	1.862 2
4	2.488 5	14	2.036 3	24	1.831 0
5	2.426 7	15	2.003 3	25	1.829 6
6	2.367 2	16	1.999 5	26	1.809 9
7	2.301 5	17	1.973 6	27	1.797 1
8	2.246 5	18	1.930 7	28	1.809 3
9	2.222 9	19	1.922 0	29	1.781 9
10	2.143 1	20	1.900 9	30	1.792 5

2.2 Cao 氏法确定嵌入维数

Cao 在总结前人工作的基础上提出了求取时间序列嵌入维数的 Cao 氏法,该方法相对其他方法鲁棒性更强、实用性更高。在  $m$  维相空间中,对每个相点  $\mathbf{X}_m(i)$ ,都有一个某距离内的最邻域点  $\mathbf{X}_m^{NN}(i)$ 。对  $m + 1$  维相空间,每个相点  $\mathbf{X}_{m+1}(i)$  同样有最邻域点(Nearest Neighbour, NN)  $\mathbf{X}_{m+1}^{NN}(i)$ ,定义:

$$\alpha(i, m) = \frac{\|\mathbf{X}_{m+1}(i) - \mathbf{X}_{m+1}^{NN}(i)\|}{\|\mathbf{X}_m(i) - \mathbf{X}_m^{NN}(i)\|}$$

(3)

式中,  $\|\cdot\|$  为距离范数。根据式(3)分别计算  $i =$

1,2,⋯,N−mτ 对应的 α(i,m) 值,然后取所有 α(i,m) 的平均值,记为 E(m),定义:

$$E_1(m) = E(m + 1)/E(m) \tag{4}$$

若时间序列来源于吸引子,则当 m 大于某一特定值 m<sub>0</sub> 时 E<sub>1</sub>(m) 趋于饱和, m<sub>0</sub> + 1 即为所求的嵌入维数。利用 Cao 氏法计算光伏出力时间序列嵌入维数,计算结果如图 2 和表 2 所示,可以看出, E<sub>1</sub> 在嵌入维数为 8 时不再明显变化( E<sub>1</sub> 的变化小于 10<sup>-3</sup> ),趋近饱和,故光伏出力时间序列的嵌入维数取为 m = 8。




图 2 E<sub>1</sub> 和嵌入维数关系曲线

Fig.2 Relationship curve of E<sub>1</sub> and embedding dimension

表 2 E<sub>1</sub> 和嵌入维数对应关系表

Tab.2 Correspondence table of E<sub>1</sub> and embedding dimension

嵌入维数	E <sub>1</sub>	嵌入维数	E <sub>1</sub>
1	0.051 7	8	1.000 2
2	0.444 0	9	1.001 1
3	0.835 5	10	1.001 3
4	0.944 8	11	1.003 4
5	0.975 7	12	1.004 0
6	0.988 4	13	1.004 8
7	0.994 6	14	1.004 8

2.3 光伏出力时间序列混沌特性识别

在利用光伏出力的混沌特性预测光伏出力前,需先识别其混沌特性。Eckmann<sup>[17]</sup>等提出的分析时间序列内部动力学行为的递归图法能够较好地判定光伏出力系统的混沌特性。该方法以相空间重构技术为基础,利用二维递归图来区分具有不同动力学特征的时间序列。

对相空间中的任意两个相点 X(i)、X(j), 计算其递归矩阵:

$$R_{ij} = H(\varepsilon - \|X(i) - X(j)\|) \tag{5}$$

式中, i,j = 1,2,⋯,M;ε 为截止距离; H(x) 为 Heaviside 阶跃函数,满足:

$$H(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases} \tag{6}$$

若 R<sub>ij</sub> = 1, 则在二维平面图上相应位置 (i,j) 处描黑点;若 R<sub>ij</sub> = 0, 则在 (i,j) 处留白,这样绘出的 M × M 平面图即为递归图。图 3(a)~图 3(c) 给出了周期序列、混沌序列、随机序列 3 种序列的递归图。周期序列在递归图上表现为网格结构,混沌序列表现为一些平行于主对角线的线段,随机序列表现为除主对角线外无规律的离散点。

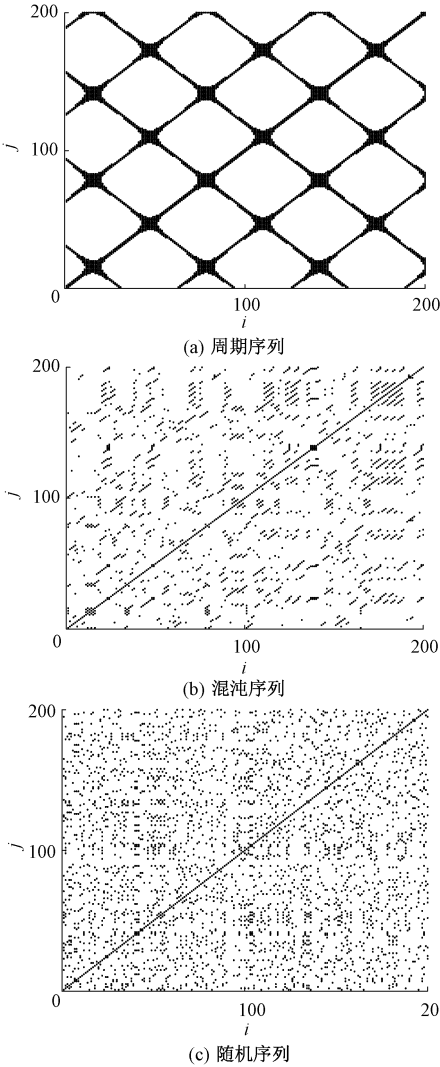


图 3 三种不同序列的递归图

Fig.3 Recurrence plots of three different sequences

为了得到更加准确的结论,本文基于文献[18]中 ε 取值方法,通过实验选取四组不同的 ε 值,得到光伏出力时间序列的递归图如图 4(a)~图 4(d) 所示。可以看到,图 4(a)~图 4(d) 均表现为一些平行于主对角线的线段,具有一定规律,可以判定光伏出力时间序列具有混沌特性。

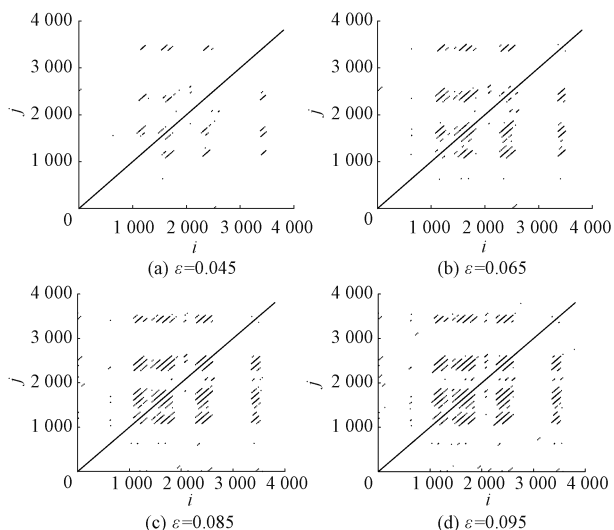


图4 不同截止距离  $\varepsilon$  对应的光伏出力  
时间序列递归图

Fig.4 Recurrence plots of PV output time series corresponding to different cutoff distances  $\varepsilon$

### 3 预测模型的建立

作为 Taylor 级数的推广, Volterra 泛函级数能够表征一大类非线性系统。随着计算机技术的发展, 以该泛函级数为基础的 Volterra 自适应滤波器因所需样本少、精度高、易于实现显现出了巨大的应用价值。

#### 3.1 基于 Volterra 的单一预测模型

设非线性离散动力系统输入为  $\mathbf{X}(n) = [x(n), x(n - \tau), \dots, x(n - (m - 1)\tau)]$ , 一步预测输出为  $y(n) = \hat{x}(n + 1)$ , 则该非线性系统的 Volterra 级数展开式<sup>[19]</sup>为:

$$\hat{x}(n + 1) = h_0 + \sum_{k=1}^p y_k(n) \quad (7)$$

其中

$$y_k(n) = \sum_{m_1, m_2, \dots, m_k=0}^{m-1} h_k(m_1, m_2, \dots, m_k) \prod_{i=1}^k x(n - m_i \tau) \quad (8)$$

式中,  $h_k(m_1, m_2, \dots, m_k)$  为  $k$  阶 Volterra 核;  $p$  为 Volterra 滤波器阶次。实际应用中这种无穷级数难以实现, 必须采用有限阶截断和有限次求和的形式。以二阶截断  $m$  次求和形式为例, 有:

$$\begin{aligned} \hat{x}(n + 1) = & h_0 + \sum_{m_1=0}^{m-1} h_1(m_1) x(n - m_1 \tau) + \\ & \sum_{m_1=0}^{m-1} \sum_{m_2=m_1}^{m-1} h_2(m_1, m_2) x(n - m_1 \tau) x(n - m_2 \tau) \end{aligned} \quad (9)$$

式(9)即为线性自适应 FIR 滤波器, 滤波器的输入矢量  $\mathbf{U}(n)$  和系数向量  $\mathbf{H}(n)$  为:

$$\mathbf{U}(n) = [1, x(n), x(n - \tau), \dots, x(n - (m - 1)\tau), x^2(n), x(n)x(n - \tau), \dots, x^2(n - (m - 1)\tau)]^T \quad (10)$$

$$\mathbf{H}(n) = [h_0, h_1(0), h_1(1), \dots, h_1(m - 1), h_2(0, 0), h_2(0, 1), \dots, h_2(m - 1, m - 1)]^T \quad (11)$$

则式(9)可以表示为:

$$\hat{x}(n + 1) = \mathbf{H}^T(n) \mathbf{U}(n) \quad (12)$$

式中, 自适应滤波器的系数向量  $\mathbf{H}(n)$  采用时间正交自适应算法<sup>[20]</sup>确定。Volterra 自适应滤波器如图 5 所示。

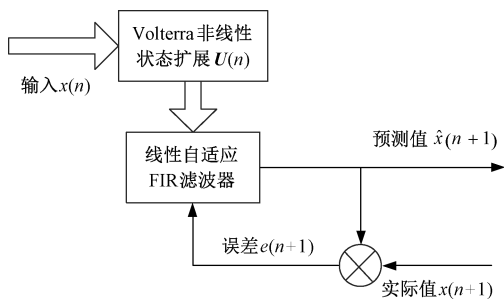


图5 Volterra 自适应滤波器

Fig.5 Volterra adaptive filter

#### 3.2 基于多嵌入维数的组合预测模型

不同的单一预测模型由于所利用的数据不同, 其提供的有效预测信息也就不同。为了获得更加全面的预测信息, 组合预测模型应运而生。组合模型能够综合不同单一模型的特点, 实现各单一模型优势互补、信息互用。不同嵌入维数计算方法原理的差异以及人工主观因素都会影响  $m$  的计算结果, 以不同嵌入维数重构的相空间包含的系统动态信息也就有所区别, 从而导致光伏出力预测结果有所差别。对此, 采用神经网络对各单一预测模型进行组合构成组合预测模型。

记  $x(n) (n = 1, 2, \dots, N)$  在  $c$  个不同嵌入维数下的预测值分别为  $\hat{x}_1(n), \hat{x}_2(n), \dots, \hat{x}_c(n)$ , 则组合模型预测的结果为:

$$\hat{x}(n) = f(\hat{x}_1(n), \hat{x}_2(n), \dots, \hat{x}_c(n)) \quad (13)$$

式中,  $f$  为非线性函数。神经网络因其强大的非线性拟合能力和自主学习能力而被广泛使用。选用三层 BP 神经网络<sup>[21]</sup>作为组合预测模型, 来拟合光伏出力预测的自变量和因变量的非线性关系  $f$ 。将  $x(n) (n = 1, 2, \dots, N)$  在  $c$  个不同嵌入维数下的预测



值  $\hat{x}_1(n), \hat{x}_2(n), \dots, \hat{x}_c(n)$  作为神经网络的输入,对应的实际值  $x(n)$  为输出,采用反向传播算法将误差反向传播不断修正权值,训练神经网络,获取最优光伏出力组合预测模型。

4 光伏出力预测算例

算例的光伏出力数据源自某 15 kW 实际光伏电站,采样时间为 2012 年 6 月 1 日到 2012 年 6 月 30 日每天 07:05~18:00,采样间隔为 5 min,一共产生 3 960 个数据。利用该数据作为模型的训练样本,预测未来一天(2012 年 7 月 1 日 07:05~18:00) 132 个点的光伏出力。为评价预测模型的优劣,采用表 3 所示的平均绝对误差、均方根误差两种评价指标进行度量。表 3 中,  $E$  为光伏发电系统额定装机容量。

表 3 预测模型的评价指标

Tab.3 Evaluation index of prediction model	
评价指标	公式表达
平均绝对误差 $E_{\text{MAE}}$	$E_{\text{MAE}} = \frac{1}{N} \sum_{n=1}^N \frac{1}{E}  \hat{x}(n) - x(n)  \times 100\%$
均方根误差 $E_{\text{RMSE}}$	$E_{\text{RMSE}} = \frac{1}{E} \sqrt{\sum_{n=1}^N \frac{(\hat{x}(n) - x(n))^2}{N}} \times 100\%$

为了探寻不同计算方法对嵌入维数的影响,本文分别以 Cao 氏法、关联维数法<sup>[22]</sup>以及假近邻法<sup>[23]</sup>计算光伏出力时间序列的嵌入维数,计算结果分别为 8、9、7。以上三种方法均以某个参数不再变化或者达到饱和(Cao 氏法的  $E_1$  值、关联维数法的关联维数、假近邻法的假近邻率)为基准选取  $m$ ,在这一过程中不可避免地带有主观性和不确定性。通过以上分析可知,虽然无法确定光伏出力时间序列的最佳嵌入维数,但不同计算方法得到的  $m$  相差不大。以 Cao 氏法得到的嵌入维数  $m=8$  为基准,分别建立  $m=7,8,9$  的 Volterra 单一预测模型,再采用神经网络组合模型对光伏出力进行预测。

4.1 单一预测模型预测结果分析

以延迟时间  $\tau=22$ 、嵌入维数分别为  $m=7,8,9$  重构光伏出力时间序列相空间,构建模型的训练样本,训练 Volterra 自适应滤波器,完成训练后获得 3 个 Volterra 单一模型的预测结果。Volterra 自适应滤波器的阶次  $p$  如何选取目前没有统一的标准,本文分别使用 2 阶、3 阶、4 阶、5 阶 Volterra 自适应滤波器预测未来 132 个点的光伏出力,表 4 给出了嵌

入维数分别为 7、8、9 时不同阶次下的预测误差对比,表 5 给出了各嵌入维数不同阶次下的时间成本对比。可以得到,Volterra 自适应滤波器阶次的提升不仅不能提高预测精度,还会增加时间成本,相对来说,2 阶 Volterra 自适应滤波器的预测性能最好。由于篇幅所限,只给出了嵌入维数  $m=8$  的 2 阶自适应滤波器的预测结果,预测结果及一步预测误差如图 6 所示。由图 6 可知,2 阶 Volterra 自适应滤波器能够较好地跟踪光伏出力的波动趋势,一步预测误差主要集中在  $[-0.4,0.4]$ ,误差较大的地方主要出现在光伏出力波动剧烈的拐点处,预测结果较为稳定。后续组合模型将以 2 阶 Volterra 自适应滤波器为基础,实现光伏出力的组合预测。

表 4 不同嵌入维数下的预测误差对比

Tab.4 Comparison of prediction errors under different embedding dimensions			
嵌入维数 $m$	阶次 $p$	$E_{\text{MAE}}(\%)$	$E_{\text{RMSE}}(\%)$
7	2	7.90	12.28
	3	7.96	12.30
	4	7.99	12.31
	5	8.00	12.31
8	2	8.01	12.38
	3	8.13	12.44
	4	8.17	12.46
	5	8.19	12.47
9	2	8.02	12.31
	3	8.16	12.40
	4	8.21	12.42
	5	8.23	12.43

表 5 不同阶次下的时间成本对比

Tab.5 Comparison of time cost under different orders			
阶次 $p$	$T/\text{s}$		
	$m=7$	$m=8$	$m=9$
2	4.29	3.64	3.73
3	4.44	4.23	4.18
4	5.19	5.52	5.89
5	6.57	7.64	9.68

4.2 组合预测模型预测结果分析

在获得上述 3 个 Volterra 单一模型的预测结果后,将其光伏出力预测值作为神经网络的输入,实际值作为输出训练神经网络,构建神经网络组合预测模型。神经网络的结构确定为 3-8-1。神经网络组合模型的预测结果如图 7 所示,其与各单一模型的预测误差对比见表 6。




图 6 2 阶 Volterra 自适应滤波器预测结果及误差曲线

Fig.6 Prediction results and error curves of second-order Volterra adaptive filter




图 7 组合模型预测结果

Fig.7 Prediction results of combined model

表 6 单一模型和组合模型预测误差

Tab.6 Comparison of prediction error between single model and combined model			
预测模型		$E_{MAE}(\%)$	$E_{RMSE}(\%)$
Volterra 单一模型	$m=7$	7.90	12.28
	$m=8$	8.01	12.38
	$m=9$	8.02	12.31
本文组合模型		7.38	11.96

从图 6 和图 7、表 4~表 6 可以看出:组合模型和 3 种单一模型都具有较好的预测性能,基本反映了光伏出力的变化规律;3 种 Volterra 单一模型中, $m$  为 7 时的单一模型预测效果最好;神经网络组合模型明显优于 3 种 Volterra 单一模型,预测误差在所有模型中最小。但相对而言,组合模型需要每一个单一模型的预测数据来训练神经网络,因而其时间成本一般会比单一模型大。

为进一步说明组合预测模型的优劣,将其与 BP 神经网络模型、RBF 神经网络模型、SVM 模型的预测结果作对比,部分预测结果及误差对比分别如图 8、表 7 所示。由表 7 可知,四种模型中本文组合模型的  $E_{MAE}$  和  $E_{RMSE}$  最小,预测精度在所有模型中最高,而 RBF 的预测性能最差,其两个预测误差在所有模型中也是最大的。BP 和 SVM 在不同嵌入维数下的  $E_{MAE}$  平均值分别为 7.71% 和 7.63%, $E_{RMSE}$  平均值分别为 12.24% 和 12.35%。由图 8 可知,不同单一模型在不同时刻的预测性能表现不同,在某些时刻误差会很大。相对来说,组合模型在这些时刻则表现出较强的鲁棒性和较好的稳定性。综上,组合模型在综合 3 种单一模型的基础上,实现了其预测性能最优。




图 8  $m$  为 8 时四种模型预测结果

Fig.8 Prediction results of four models with  $m$  is 8

表 7 四种模型的预测误差对比

Tab.7 Comparison of prediction error of four models			
预测模型		$E_{MAE}(\%)$	$E_{RMSE}(\%)$
$m=7$	BP 模型	7.43	12.22
	RBF 模型	7.79	12.35
	SVM 模型	7.61	12.32
$m=8$	BP 模型	7.83	12.17
	RBF 模型	8.26	12.57
	SVM 模型	7.71	12.39
$m=9$	BP 模型	7.86	12.33
	RBF 模型	8.28	12.47
	SVM 模型	7.56	12.33
本文组合模型		7.38	11.96

5 结论

本文在光伏出力相空间重构的基础上分别建立了 Volterra 自适应滤波器的单一预测模型和基于多

嵌入维数的神经网络组合预测模型,通过算例分析得到以下结论:对 Volterra 单一模型而言,提高 Volterra 自适应滤波器的阶次不能提高其性能,2 阶 Volterra 自适应滤波器的表现最好;所建立的基于多嵌入维数的神经网络组合模型预测性能明显优于 Volterra 单一模型,有效提高了预测精度。在与 BP、RBF、SVM 三种模型的对比中,本文组合模型的预测精度更高、鲁棒性更强、稳定性更好。

## 参考文献 (References):

- [1] 钟嘉庆,李茂林,江静,等 (Zhong Jiaqing, Li Maolin, Jiang Jing, et al.). 基于 Copula 理论的风/光出力预测误差分析方法的研究 (Method of wind/solar output forecast error analysis based on Copula theory) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (6): 39-46.
- [2] 郝利东,潘尚智,蒋建波,等 (Hao Lidong, Pan Shangzhi, Jiang Jianbo, et al.). 一种适应于两级直流配电系统的光伏直流变换器及控制策略研究 (Research on PV DC-DC converter and control strategy for two-stage DC power distribution system) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2019, 38 (8): 71-80.
- [3] Li Y T, Su Y, Shu L J. An ARMAX model for forecasting the power output of a grid connected photovoltaic system [J]. Renewable Energy, 2014, 66: 78-89.
- [4] 丁明,刘志,毕锐,等 (Ding Ming, Liu Zhi, Bi Rui, et al.). 基于灰色系统校正-小波神经网络的光伏功率预测 (Photovoltaic output prediction based on grey system correction-wavelet neural network) [J]. 电网技术 (Power System Technology), 2015, 39 (9): 2438-2443.
- [5] 王昕,黄柯,郑益慧,等 (Wang Xin, Huang Ke, Zheng Yihui, et al.). 基于萤火虫算法-广义回归神经网络的光伏发电功率组合预测 (Combined PV power forecast based on firefly algorithm-generalized regression neural network) [J]. 电网技术 (Power System Technology), 2017, 41 (2): 455-461.
- [6] 栗然,李广敏 (Li Ran, Li Guangmin). 基于支持向量机回归的光伏发电出力预测 (Photovoltaic power generation output forecasting based on support vector machine regression technique) [J]. 中国电力 (Electric Power), 2008, 41 (2): 74-78.
- [7] 茆美琴,龚文剑,张榴晨,等 (Mao Meiqin, Gong Wenjian, Zhang Liuchen, et al.). 基于 EEMD-SVM 方法的光伏电站短期出力预测 (Short-term photovoltaic generation forecasting based on EEMD-SVM combined method) [J]. 中国电机工程学报 (Proceedings of the CSEE), 2013, 33 (34): 17-24.
- [8] 黄磊,舒杰,姜桂秀,等 (Huang Lei, Shu Jie, Jiang Guixiu, et al.). 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 (Photovoltaic generation forecast based on multidimensional time series and local support vector regression in microgrids) [J]. 电力系统自动化 (Automation of Electric Power Systems), 2014, 38 (5): 19-24.
- [9] 王育飞,付玉超,孙路,等 (Wang Yufei, Fu Yuchao, Sun Lu, et al.). 基于混沌-RBF 神经网络的光伏发电功率超短期预测模型 (Ultra-short term prediction model of photovoltaic output power based on chaos-RBF neural network) [J]. 电网技术 (Power System Technology), 2018, 42 (4): 1110-1116.
- [10] 罗毅,千雨乐 (Luo Yi, Qian Yule). 基于相空间重构和小波神经网络的光伏阵列发电量预测 (Power generation forecast of PV array based on phase space reconstruction and wavelet neural network) [J]. 太阳能学报 (Acta Energiæ Solaris Sinica), 2014, 35 (6): 992-997.
- [11] 张家树,肖先赐 (Zhang Jiashu, Xiao Xianci). 混沌时间序列的 Volterra 自适应预测 (Prediction low-dimensional chaotic time series using Volterra adaptive filters) [J]. 物理学报 (Acta Physica Sinica), 2000, 49 (3): 403-408.
- [12] 张家树,肖先赐 (Zhang Jiashu, Xiao Xianci). 混沌时间序列的自适应高阶非线性滤波预测 (Prediction of chaotic time series by using adaptive higher-order nonlinear Fourier infrared filters) [J]. 物理学报 (Acta Physica Sinica), 2000, 49 (7): 1221-1227.
- [13] 田中大,李树江,王艳红,等 (Tian Zhongda, Li Shujiang, Wang Yanhong, et al.). 短期风速时间序列混沌特性分析及预测 (Chaotic characteristics analysis and prediction for short-term wind speed time series) [J]. 物理学报 (Acta Physica Sinica), 2015, 64 (3): 246-257.
- [14] 张玉梅,吴晓军,白树林 (Zhang Yumei, Wu Xiaojun, Bai Shulin). 交通流量序列混沌特性分析及 DF-PSOVF 预测模型 (Chaotic characteristic analysis for traffic flow series and DFPSOVF prediction model) [J]. 物理学报 (Acta Physica Sinica), 2013, 62 (19): 120-128.
- [15] Abarbanel H D I, Masuda N, Rabinovich M I, et al. Distribution of mutual information [J]. Physics Letters A, 2001, 281 (5-6): 368-373.
- [16] Cao L. Practical method for determining the minimum embedding dimension of a scalar time series [J]. Physica

D, 1997, 110 (1-2): 43-50.

[17] Echmann J P, Kamphorst S O, Ruelle D. Recurrence plots of dynamical systems [J]. Europhys Lett, 1987, 4 (9): 973-977.

[18] 王春华, 仲兆平, 李睿, 等 (Wang Chunhua, Zhong Zhaoping, Li Rui, et al.). 气-固流化床压力脉动递归图分析 (Recurrence plots analysis of pressure fluctuation in gas-solids fluidized bed) [J]. 化工学报 (CIESC Journal), 2010, 61 (3): 557-564.

[19] 陆振波, 蔡志明, 姜可宇 (Lu Zhenbo, Cai Zhiming, Jiang Keyu). 基于奇异值分解的混沌时间序列 Volterra 预测 (Prediction of chaotic time series using singular value decomposition Volterra filter) [J]. 武汉理工大学学报: 交通科学与工程版 (Journal of Wuhan University of Technology: Transportation Science & Engineering), 2007, 31 (4): 672-675.

[20] 张学清, 梁军 (Zhang Xueqing, Liang Jun). 风电功率时间序列混沌特性分析及预测模型研究 (Chaotic

characteristics analysis and prediction model study on wind power time series) [J]. 物理学报 (Acta Physica Sinica), 2012, 61 (19): 70-81.

[21] 王丽婕, 冬雷, 胡国飞, 等 (Wang Lijie, Dong Lei, Hu Guofei, et al.). 基于多嵌入维数的风力发电功率组合预测模型 (Combined prediction of wind power generation in multi-dimension embedding phase space) [J]. 控制与决策 (Control and Decision), 2010, 25 (4): 577-580, 586.

[22] Grassberger P, Procaccia I. Measuring the strangeness of strange attractors [J]. Physica D, 1983, 9 (1-2): 189-208.

[23] 张永明, 齐维贵 (Zhang Yongming, Qi Weigui). 供热负荷时间序列混沌特性分析及预报模型研究 (Chaotic property analysis and prediction model study for heating load time series) [J]. 物理学报 (Acta Physica Sinica), 2011, 60 (10): 98-107.

Photovoltaic output prediction based on chaotic characteristic analysis and Volterra filter

YU Hai-biao<sup>1</sup>, LI Lin<sup>1,2</sup>, DING Ming<sup>1</sup>, LIU Lian<sup>1</sup>, GAO Ping-ping<sup>1</sup>

(1. Anhui New Energy Utilization and Energy Saving Laboratory, Hefei University of Technology, Hefei 230009, China; 2. CSG Science & Technology Co. Ltd., Hefei 230080, China)

**Abstract:** In chaotic theory, the existing embedding dimension calculation methods are often difficult to obtain the optimal embedding dimension of time series. Different calculation methods have different embedding dimensions, and the corresponding photovoltaic (PV) output prediction results are also different. To reduce the impact of embedding dimension on the prediction results, a Volterra combination prediction model based on multi-embedding dimension is designed on the basis of analyzing the non-linear dynamic characteristics of PV output time series. The combined model uses neural network to combine the Volterra single models under different embedding dimensions. The single prediction model adopts the 2-order Volterra filter with the best performance. The simulation results verify the feasibility and effectiveness of the combined model.

**Key words:** PV output; chaotic characteristics; Volterra filter; multi-embedding dimension; combination prediction