

doi:10.11835/j.issn.1000-582X.2016.04.018

# 联想神经网络的风速序列预测分析

杨雨浓<sup>1,3</sup>, 修春波<sup>2</sup>

(1.西北大学 信息科学与技术学院,西安 710127;2.天津工业大学 电工电能新技术天津市重点实验室,天津 300387;  
3.重庆师范大学 教务处,重庆 401331)

**摘要:**为了提高风速序列预测的可靠性,针对具有混沌特性的风速序列,构造了一种用于风速序列预测的联想网络。以风速序列的波动性作为相似性测度准则,构造联想网络的存储样本模式,根据存储模式中蕴含的关联信息完成网络的无监督学习,从而完成具有自相似性的风速序列的一步或多步预测分析。与传统前向型神经网络相比,该网络预测机理明确,预测结果唯一,且可一次给出多步预测结果。仿真实验结果表明,该网络的具有良好预测性能,适用于风速序列的动态预测。

**关键词:**联想网络;风速序列;混沌;预测

**中图分类号:**TP391

**文献标志码:**A

**文章编号:**1000-582X(2016)04-139-08

## Wind speed time series prediction based on associative network

YANG Yunong<sup>1,3</sup>, XIU Chunbo<sup>2</sup>

(1. School of Information Science and Technology, Northwestern University, Xi'an 710127, P.R.China;  
2. Key Laboratory of Advanced Electrical Engineering and Energy Technology, Tianjin Polytechnic University, Tianjin 300387, P.R.China; 3. Teaching Affairs Office, Chongqing Normal University, Chongqing 401331, P.R.China)

**Abstract:** In order to improve the reliability of wind speed series prediction, a new associative network was constructed to predict the wind speed series with chaotic characteristics. Stored sample patterns were constructed according to the similarity measure of the volatile of the wind speed series. Utilizing the correlation information contained in the stored sample patterns, the network adopts an unsupervised learning algorithm to complete the weight training. One step or multi-step prediction of the wind speed series which have self-similarity can be completed by the associative network. Compared with the conventional forward neural network, the prediction mechanism of the associative prediction network is explicit, and the prediction result is uniqueness. The network can also give one step or multi-step prediction results simultaneously in once calculation. Simulation results show that the associative network has good prediction performance, and can be applied to predict dynamically the wind speed series.

**Keywords:** associative network; wind speed series; chaos; prediction

**收稿日期:**2016-01-20

**基金项目:**重庆市科委资助项目(cstc2013kjrc-qnrc40001, cstc2013jcyjA80013)。

Supported by Chongqing Science and Technology Commission (cstc2013kjrc-qnrc40001, cstc2013jcyjA80013).

**作者简介:**杨雨浓(1978-),男,西北大学博士研究生,主要从事神经网络、机器学习方向研究。

(E-mail)398490668@qq.com。

风能作为一种清洁能源,是目前世界上各国大力发展的新能源之一<sup>[1-4]</sup>。而风力发电又是利用风能的最佳途径之一<sup>[5-8]</sup>。但风电并网的技术问题一直制约着风电的发展和利用<sup>[9-10]</sup>。这是由于自然界的风具有较强的随机性和波动性,因此风电在并网过程中会对电力系统产生较大的冲击。解决该问题的有效途径之一就是风速进行有效的短期预测,并通过优化调度等方式缓解风速对电网的冲击<sup>[11]</sup>。目前,风电场每天都要对风速序列进行短期预测,以保证风电的质量。

由于气象系统具有复杂的非线性特点,风速序列虽然具有可预测性,但准确的预测却具有较大的难度。目前的风速数据预测的误差甚至高达 25%~40%,因此开展有效的风速预测研究具有重要的理论意义和应用价值<sup>[12]</sup>。

由于数值气象预报模型很难获取,因此基于历史数据的风速预测研究具有更现实的应用前景<sup>[13]</sup>。基于历史数据的风速预测的实质是试图利用各种理论和方法,挖掘出风速历史数据中蕴含的各种关联信息,再利用这些关联信息实现对未来风速的有效预测。实际风电场中常用的方法有持续预测法、时间序列分析方法、神经网络方法、卡尔曼滤波方法等<sup>[14-20]</sup>。这些方法试图根据历史数据的关联性建立风速序列的数学模型或者预测模型。但风速数据在不同时段可能会表现出不同的性质,其内在规律也会发生变化,因此,随着时间的推移,采用单一不变的模型进行预测分析会降低预测结果的可靠性。

现有研究表明,风速具有复杂的非线性特性,并且往往会表现出混沌特性<sup>[21-22]</sup>。风速数据的混沌特性可通过计算风速序列的 Lyapunov 指数进行判断。由于混沌系统的相空间具有分形结构,表现出自相似性,因此具有混沌特性的风速序列一般也具有分数维和自相似的特点。为了提高风速预测的有效性,从风速数据自身特性入手,针对具有混沌特性的风速序列开展研究,挖掘风速数据蕴含的相似性关联信息,构造出风速的相似模式,并建立一种新的联想网络实现风速序列的预测分析。

## 1 风速序列的特性分析

风速序列往往具有复杂的动力学特性,可利用混沌理论对其开展动力学特性分析,并判断其是否具有混沌特性。

风速序列的混沌特性可结合相空间重构理论计算其 Lyapunov 指数进行判断。时间序列的相空间重构理论是通过重构相空间将时间序列中蕴含的混沌特性在高维空间中显示出来。设风速时间序列为  $\{x(t), t=1, 2, \dots\}$ , 其重构的相空间可表示为

$$Y(t) = \{x(t), x(t + \tau), \dots, x(t + (m - 1)\tau)\}, t = 1, 2, \dots, N, \quad (1)$$

式中:  $N$  为嵌入维数,  $\tau$  为延迟时间。根据 wolf 方法,利用构造好的相空间可计算时间序列的 Lyapunov 指数  $\lambda$ , 当  $\lambda$  大于 0 时,可判断该序列具有混沌特性。

$$\lambda = \frac{1}{t_M - t_0} \sum_{i=0}^M \ln \frac{L'_i}{L_i}, \quad (2)$$

式中:  $M$  为迭代次数,  $L$  为相邻点距离。根据混沌理论,混沌系统的相空间轨迹往往具有分形结构。时间序列的分形维数可通过计算 Hurst 指数进行求取。Hurst 指数可采用 R/S 分析方法进行计算,设时间区域为  $T$ , 时间序列  $\{x_i | t=1, 2, \dots\}$  的均值为  $\mu_T$ , 累积极差  $R(T)$  和标准差  $S(T)$  计算如下

$$X(t, T) = \sum_{i=1}^t [x_i - \mu_T], \quad (3)$$

$$R(T) = \max_{1 \leq t \leq T} X(t, T) - \min_{1 \leq t \leq T} X(t, T), \quad (4)$$

$$S(T) = \left\{ \frac{1}{T} \sum_{i=1}^T [x_i - \mu_T]^2 \right\}^{\frac{1}{2}}, \quad (5)$$

则

$$H = \frac{\ln\left(\frac{R}{S}\right)}{\ln T} - \frac{\ln c}{\ln T}, \quad (6)$$

式中: $H$ 为Hurst指数, $R/S$ 为重标极差, $c$ 为与 $T$ 无关的正值常数。

$H$ 体现了统计分形的自相似性以及自相似程度,与时间序列的分形维数 $D$ 有线性关系 $D=2-H$ 。

当 $0.5 < H \leq 1$ 时,表明时间序列具有统计自相似性和混沌初值敏感依赖性。 $H$ 越接近1,自相似程度越高,可预测性越强。

从直观上讲,风速序列具有自相似性也较容易理解,例如,一年中12个月的风力随时间变化的整体趋势与一天中12个时辰的风力随时间变化的趋势就具有一定的相似性。因此,从自相似性的角度入手研究风速序列的预测分析具有一定的合理性。

## 2 用于风速序列预测分析的联想记忆网络

神经网络具有自组织、自学习的能力,适合处理非线性数据分析问题。在时间序列的预测分析中具有良好的应用效果。但通常的用于时间序列预测分析的神经网络是前向型的神经网络,如BP神经网络。这类网络利用梯度下降等学习算法修改网络权值和参数,实现输入层到输出层的映射。当训练样本构造合理时,可完成时间序列的预测分析。但这类方法具有一定的不足,首先,神经网络的初始参数和权值为随机选取,对于同样的数据每次预测所得结果也不相同,预测结果具有一定的随机性。其次,网络在训练过程中易于陷入局部极小,预测性能无法得到保障。另外,前向型神经网络的预测机理不明确,无法获得输出与输入的显式表达关系,预测效果完全取决于网络的泛化能力,降低了预测结果的可靠性。

联想记忆网络是另一类神经网络,典型的网络如Hopfield网络,这类网络一般根据存储模式蕴含的关联信息构造出无监督学习算法实现存储模式的联想记忆。与BP神经网络相比,该网络的机理明确,能够显性利用存储模式数据内部的关联信息,因此,在联想记忆中得到较好的应用。但由于网络结构的限制,这类网络很少用于时间序列预测分析中。

针对具有混沌特性的风速序列,基于联想网络的工作机理,构建了一种可用于风速序列预测分析的新型联想网络,实现了一种新的风速时间序列预测方法。该方法根据当前风速序列的波动性,在历史数据中构造出相似模式向量,利用相似模式之间的关联信息与统计信息构建无监督学习算法,采用所构建的联想网络实现风速序列的预测分析。

### 2.1 相似模式的确定

联想网络需要构造一定数量的存储样本,利用存储样本的关联信息才能实现联想记忆。为了采用联想记忆网络进行风速序列的预测分析,利用已知风速序列构造联想存储样本模式。

对于具有混沌特性和自相似性的风速序列,可提取与当前风速序列段相似的序列段构造存储样本。由于风速具有较强的波动性,因此以风速的波动情况衡量样本模式之间的相似性。

设风速序列为 $\{x_i | i=1, 2, 3, \dots, n\}$ ,可获得该序列的波动模式序列 $\{y_i | i=2, 3, \dots, n\}$ ,其中

$$y_i = \text{sign}(x_i - x_{i-1}) = \begin{cases} +1, & \text{if } (x_i - x_{i-1}) \geq 0, \\ -1, & \text{if } (x_i - x_{i-1}) < 0, \end{cases} \quad (7)$$

式中: $y_i$ 的取值为 $\pm 1$ ,当 $x_i$ 的值比前一时刻的值小时,也就是风速值变小时, $y_i$ 取 $-1$ ,否则为 $+1$ 。根据 $y_i$ 的取值可判断出风速的变化或波动趋势。

根据风速序列的波动性对不同序列段的风速状态进行匹配性测度。

设输入模式长度为 $N$ 。则可确定输入模式向量 $X_{in} = [x_{n-N+1}, x_{n-N+2}, \dots, x_{n-1}, x_n]$ ,这样,输入模式向量对应的输入波动模式为 $Y_{in} = [y_{n-N+2}, \dots, y_{n-1}, y_n]$ 。设联想网络存储样本模式数量为 $P$ ,从后向前寻找与输入波动模式相同的 $P$ 个向量作为联想模式向量 $\{Z_i, i=1, 2, \dots, P\}$ ,其中, $Z_i = [z_1^i, z_2^i, \dots, z_{N-1}^i] = [y_k, y_{k+1}, y_{k+2}, \dots, y_{k+N-2}]$ , $Z_i$ 的各元素取值均为 $\pm 1$ ,且 $Z_i = Y_{in}$ ,而 $Z_i$ 对应的风速序列段为 $[x_{k-1}, x_k, x_{k+1}, \dots, x_{k+N-2}]$ 。

设风速序列的最大预测步长为 $p$ ,则利用寻找到的相似模式构造训练样本对集 $\{B_i, i=1, 2, \dots, P\}$ ,其中

$$\mathbf{B}_j = [(b_1^j, b_2^j, \dots, b_N^j), (b_{N+1}^j, b_{N+2}^j, \dots, b_{N+p}^j)] = [(x_{k-1}, x_k, x_{k+1}, \dots, x_{k+N-2}), (x_{k+N-1}, x_{k+N}, \dots, x_{k+N-2+p})] \quad (8)$$

设输入模式

$$\mathbf{X}_{in} = \mathbf{A} = [a_1, a_2, \dots, a_N] = [x_{n-N+1}, x_{n-N+2}, \dots, x_{n-1}, x_n], \quad (9)$$

训练样本对  $B_j$  由 2 部分组成,  $(b_1^j, b_2^j, \dots, b_N^j)$  对应与输入样本模式  $A$  具有相同波动性的序列段,  $(b_{N+1}^j, b_{N+2}^j, \dots, b_{N+p}^j)$  为该样本对应的未来数据, 这 2 部分共同组成了训练样本对。

## 2.2 联想预测网络

根据上述所构造的  $P$  个训练样本对, 可设计如图 1 所示的联想网络。

联想网络包含输入层和输出层 2 层结构, 输入层有  $N$  个单元, 对应输入模式的  $N$  个分量, 输出层含有  $p$  个单元, 对应  $1 \sim p$  步的预测值。2 层之间有双向连接权值, 连接权值根据  $P$  个训练样本对所蕴含的关联信息进行设计, 实现模式记忆。

设待预测点  $x_{n+h}$  的预测值为  $x'_{n+h}$ ,  $x'_{n+h}$  就是输出层第  $h$  个单元的输出值。输入层第  $i$  个单元与输出层第  $h$  个单元之间的连接权值设计为

$$w_{ih} = \frac{1}{NP} \sum_{j=1}^P \frac{b_{N+h}^j}{b_i^j}, \quad (10)$$

权值  $w_{ih}$  表征了存储模式的第  $N+h$  个元素与第  $i$  个元素比值的平均值。

第  $h$  个单元的输出  $x'_{n+h}$  为

$$x'_{n+h} = \sum_{i=1}^N w_{ih} a_i = \frac{1}{NP} \sum_{i=1}^N \sum_{j=1}^P \frac{b_{N+h}^j}{b_i^j} a_i, \quad (11)$$

第  $h$  个单元的输出  $x'_{n+h}$  根据存储模式各元素与第  $N+h$  个元素的比例关系, 计算当前输入模式下的  $h$  步的预测值。

## 2.3 连续预测的算法步骤

上述预测方法根据当前风速序列段的波动性特点, 在历史风速数据序列段中寻找相似序列段作为联想网络的训练样本。由于针对具有混沌特性的风速序列开展预测研究, 混沌序列中蕴含着不稳定周期, 且其相空间具有自相似性, 因此, 当前风速序列的动力学行为与根据历史数据所构建的训练样本的动力学行为应具有一定的相似性。这样, 利用联想网络对训练样本间蕴含的关联信息的统计和挖掘能力, 能够完成对当前风速序列的预测分析。采用上述网络可实现风速序列的多步预测研究, 具体步骤可描述如下:

Step1. 将所采集到的当前风速时间序列段数据  $A$  作为网络当前输入样本, 根据输入样本模式的单元数和最大预测步数确定联想预测网络输入层和输出层的单元数, 从而构建出联想预测网络。

Step2. 根据  $A$  的波动性, 在已知序列中从后往前寻找  $P$  个相似的波动模式, 构成联想存储样本对。

Step3. 根据所构建的  $P$  个训练样本, 利用式(9)设计网络权值。

Step4. 利用式(10)完成时间序列  $1$  至  $p$  步的预测分析。

Step5. 当获取到新的风速序列测量值后, 将其加入到已知风速序列中, 并计算预测误差, 然后转至 Step1 进行下一次预测分析。

与现有常用的风速序列预测方法相比, 本预测网络具有如下特点。

1) 根据当前风速序列的波动性, 动态地在历史数据中构建具有相似性的训练样本, 根据训练样本元素间的关联信息设计网络权值, 满足风速序列动态预测的要求。

2) 该预测网络一次计算可同时给出  $1 \sim p$  步预测结果。

3) 该预测网络采用无监督学习算法, 无需反复训练网络参数, 计算量小。

4) 预测机理明确, 根据历史相似数据的关联信息实现对未来数据的预测分析, 预测结果唯一, 克服了前向型预测网络预测结果具有随机性的缺点。

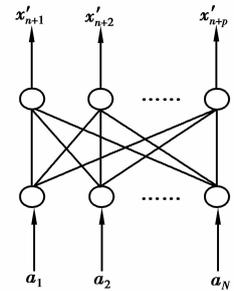


图 1 联想预测网络结构图

Fig.1 the structure of the associative prediction network

### 3 仿真实验

以某风电场实际采集到的风速数据作为研究对象,开展风速序列的预测研究。针对优化调度、减轻风电对电网冲击的目的开展短期预测研究。风速数据每隔 10 min 采集一次,采用所提方法和目前常用预测方法实现了风速序列的单步及多步预测对比研究。

在风速预测前,先要对待预测序列进行动力学特性分析。计算风速序列的 Lyapunov 指数,计算结果为 0.302,大于 0,表明该段风速序列具有混沌特性。进一步计算该序列段的 Hurst 指数,根据式(5),以  $\ln N$  为自变量、 $\ln(R/S)$  为因变量,采用最小二乘法进行线性拟合,所得直线的斜率即为 Hurst 指数的估计值,其结果为 0.97,接近于 1,说明其具有很好的自相似性,满足预测方法应用的前提。

采用研究方法对风速序列进行预测分析,由于目前风电场对风速序列的短期预测分析主要采用 ARIMA 模型和 BP 神经网络方法,因此将这 2 种方法与研究方法进行对比分析。

对于 ARIMA 模型,采用 Box-Jenkins 方法对其进行定阶。即首先采用差分方法对风速序列进行平稳化处理,然后根据自相关函数和偏相关函数确定模型的阶数。最后所确定的模型及阶数为 ARIMA(1,1,3)。

风速时间序列 1 步预测的对比结果如图 2 所示。

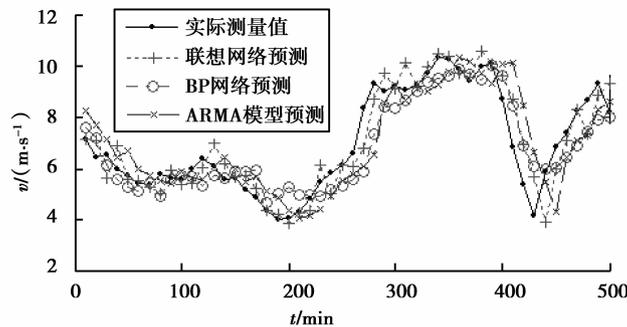


图 2 风速序列 1 步预测结果

Fig.2 One-step ahead prediction results of wind speed series

上述各种预测方法的预测性能指标比较如表 1 所示。

表 1 风速序列 1 步预测误差指标  
Table 1 One-step ahead prediction errors

预测方法	最大误差	平均误差	均方根误差
联想网络	1.97	0.56	0.76
BP 网络	2.51	0.71	0.90
ARIMA 模型	3.29	0.89	1.18

从预测结果可见,上述各种方法都能够得到与测量数据变化趋势相似的预测结果,并且都存在一定的滞后性,其中 ARIMA 模型的滞后性最严重。可见,传统的 ARIMA 时间序列分析方法在对具有复杂非线性的风速序列预测分析中表现出一定的局限性,所确定的模型结构很难跟随风速时间序列的激烈变化,从而造成预测曲线与测量曲线之间存在较大的滞后现象。而 BP 神经网络和所提出的联想网络具有自学习的能力,网络能够根据序列的变化趋势来调节网络的权值参数,从而使得网络模型能够适应风速序列的复杂运动,因此预测性能能够得到改善,滞后现象得到缓解。但 BP 神经网络是一种全局逼近网络,要求蕴含在历史数据中的规律信息不变或者缓慢变化,而且其预测结果与初始权值的选取有关,容易陷入局部极小,且预测机理不明确,预测结果随机性较大,在波动性较大的风速序列的预测中,其预测的可靠性较差。而本文所提出的联

想预测网络专门针对具有混沌特性的风速序列开展预测研究,由于混沌序列具有不稳定周期结构和自相似性结构,因此该网络利用与当前序列段相似的历史数据段实现预测分析,预测机理明确,且预测结果唯一,与 BP 网络相比具有更好的预测可靠性,其预测性能优于 BP 神经网络。

利用预测方法,在不改变网络结构的情况下,可同时实现 1 至  $p$  步的预测分析。图 3 和图 4 分别给出了 3 步与 5 步的预测结果图,表 2 和表 3 给出了预测误差指标。

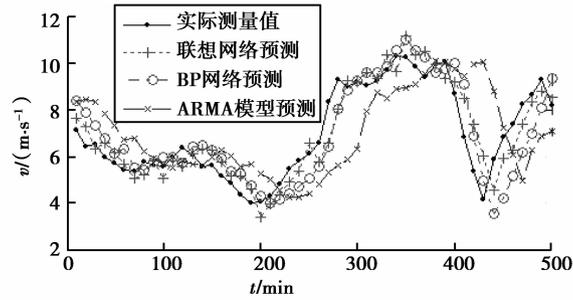


图 3 风速序列 3 步预测结果

Fig.3 Three-step ahead prediction results of wind speed series

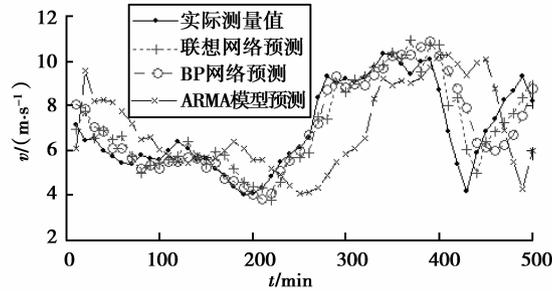


图 4 风速序列 5 步预测结果

Fig.4 Five-step ahead prediction results of wind speed series

表 2 风速序列 3 步预测误差指标

Table 2 Three-step ahead prediction errors

预测方法	最大误差	平均误差	均方根误差
联想网络	2.03	0.66	0.80
BP 网络	2.64	0.81	1.10
ARIMA 模型	5.90	1.51	1.93

表 3 风速序列 5 步预测误差指标

Table 3 Five-step ahead prediction errors

预测方法	最大误差	平均误差	均方根误差
联想网络	2.98	0.71	0.93
BP 网络	3.73	0.83	1.12
ARIMA 模型	5.93	1.94	2.37

从实验结果可见,随着预测步长的增加,ARIMA 方法预测结果的滞后现象越来越严重,其预测性能迅速下降。而 BP 网络与联想网络的学习能力使得预测性能下降并不严重。与全局逼近的 BP 神经网络相比,

联想网络针对具有混沌特性的时间序列开展预测研究,能够更好地利用序列自身蕴含的规律信息,因此在预测步长增加的情况下,仍然具有较好的预测性能。从预测效果和预测误差来看,所提预测方法都能给出更好的预测结果。

## 4 结 语

针对具有混沌特性的风速序列提出了一种基于联想神经网络的风速序列预测新方法。该方法根据当前序列段的波动性,动态地设计网络权值,满足了风速序列动态预测的要求。并且预测机理明确,计算量小。仿真结果表明,该方法预测性能稳定,预测结果可靠,能够满足风速序列单步或多步预测的要求。

### 参考文献:

- [1] 伍见军,王咏薇,丁源,等.风电场超短期风速预测方法对比[J].科学技术与工程,2013,13(11):2965-2969.  
Wu Jianjun, Wang Yongwei, Ding Yuan, et al. A comparison of very short term wind prediction by different methods[J]. Science Technology and Engineering, 2013,13(11): 2965-2969. (in Chinese)
- [2] Dowell, J, Weiss, S, Infield, D. Kernel methods for short-term spatio-temporal wind prediction[C]//IEEE PES General Meeting. 2015.
- [3] 孙国强,卫志农,翟玮星.基于RVM与ARMA误差校正的短期风速预测[J].电工技术学报,2012,27(8):187-193.  
Sun Guoqiang, Wei Zhinong, Zhai Weixing. Short term wind speed forecasting based on RVM and ARMA error correcting[J]. Transactions of China Electrotechnical Society, 2012, 27(8): 187-193. (in Chinese)
- [4] 罗文,王莉娜.风场短期风速预测研究[J].电工技术学报,2011,26(7):68-74.  
LUO Wen, WANG Lina. Short-term wind speed forecasting for wind farm[J]. Transactions of China Electrotechnical Society, 2011,26(7):68-74. (in Chinese)
- [5] 王媛媛,秦政,张超,等.基于自适应线性逻辑网络的风电功率预测方法性能评估与分析[J].可再生能源,2013,31(6):61-65.  
WANG Yuanyuan, QIN Zheng, ZHANG Chao, et al. Performance assessment and analysis of wind power forecasting method based on adaptive linear logic network[J]. Renewable Energy Resources, 2013, 31(6): 61-65. (in Chinese)
- [6] XIU Chunbo, WANG Tiantian, TIAN Meng, et al. Short-term prediction method of wind speed series based on fractal interpolation[J]. Chaos Solitons & Fractals, 2014, 68:89-97.
- [7] 修春波,任晓,李艳晴,等.基于卡尔曼滤波的风速序列短期预测方法[J].电工技术学报,2014,29(2):253-259.  
XIU Chunbo, REN Xiao, LI Yanqing, et al. Short-term prediction method of wind speed series based on kalman filtering fusion[J]. Transactions of China Electrotechnical Society. 2014, 29(2): 253-259. (in Chinese)
- [8] Chitsaz H, Amjady N, Zareipour H. Wind power forecast using wavelet neural network trained by improved Clonal selection algorithm[J]. Energy Conversion & Management, 2015, 89: 588-598.
- [9] Liu H, Hong-qi Tian, Yan-fei Li. Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction[J], Applied Energy, 2012, 98(12): 415-424.
- [10] Zhao H, Wu Q, Hu S, et al. Review of energy storage system for wind power integration support[J]. Applied Energy, 2015, 137: 545-553.
- [11] 武峰雨,乐秀璠,南东亮.相空间重构的极端学习机短期风速预测模型[J].电力系统及其自动化学报,2013,25(1):136-141.  
WU Fengyu, LE Xiufan, NAN Dongliang. A short-term wind speed prediction model using phase-space reconstructed extreme learning machine[J]. Proceedings of the CSU-EPSA, 2013, 25(1): 136-141. (in Chinese)
- [12] 高爽,冬雷,高阳,等.基于粗糙集理论的中长期风速预测[J].中国电机工程学报,2012,32(1):32-37.  
GAO Shuang, DONG Lei, GAO Yang, et al. Mid-long term wind speed prediction based on rough set theory[J]. Proceedings of the CSEE, 2012, 32(1): 32-37. (in Chinese)

- [13] 甘敏,丁明,董学平.基于改进 Mycielski 方法的风速预测[J].系统工程理论与实践,2013,33(4):1084-1088.  
GAN Min, DING Ming, DONG Xueping. Improved Mycielski approach for wind speed prediction [J]. Systems Engineering Theory & Practice, 2013, 33(4): 1084-1088. (in Chinese)
- [14] Xiu C B, Guo F H. Wind speed prediction by chaotic operator network based on Kalman Filter [J]. Science China technological sciences, 2013, 56(5): 1169-1176.
- [15] Dowell J, Pinson P. Very-Short-Term probabilistic wind power forecasts by sparse vector autoregression[J]. IEEE Transactions on Smart Grid, 2015: 1.
- [16] Papavasiliou A, Oren S S, Aravena I. Stochastic modeling of multi-area wind power production[J]. 2015:2616-2626.
- [17] Carpinone A, Giorgio M, Langella R, et al. Markov chain modeling for very-short-term wind power forecasting[J]. Electric Power Systems Research, 2015, 122: 152-158.
- [18] 陈妮亚,钱政,孟晓风,等.基于空间相关法的风电场风速多步预测模型[J].电工技术学报,2013,28(5):15-21.  
Chen Niya, Qian Zheng, Meng Xiaofeng, et al. Multi-step ahead wind speed forecasting model based on spatial correlation and support vector machine[J]. Transactions of China electrotechnical society, 2013, 28(5): 15-21. (in Chinese)
- [19] 刘新婷,修春波,张欣,等.基于混沌不稳定周期方法的风速时间序列预测[J].东南大学学报(自然科学版),2012,42(s1): 78-81.  
LIU Xinting, XIU Chunbo, ZHANG Xin, et al. Prediction of wind speed series based on chaotic unstable period[J]. Journal of Southeast University (Natural Science Edition), 2012, 42(s1): 78-81. (in Chinese)
- [20] Guo Z H, Zhao W G, Lu H Y, et al. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model[J]. Renewable Energy, 2014, 37(1): 241-249.
- [21] Xu G W, Xiu C B, Wan Z K. Hysteretic chaotic operator network and its application in wind speed series prediction[J]. Neurocomputing, 2015, 165: 384-388.
- [22] 王富强,王东风,韩璞.基于混沌相空间重构与支持向量机的风速预测[J].太阳能学报,2012,33(8):1321-1326.  
WANG Fuqiang, WANG Dongfeng, HAN Pu. Wind speed prediction based on chaos phase space reconstruction and support vector machine[J]. Acta Energiæ Solaris Sinica, 2012, 33(8): 1321-1326. (in Chinese)

(编辑 侯 湘)