

基于原子稀疏分解理论的短期风电功率滑动预测

崔明建¹, 孙元章¹, 柯德平¹, 王树鹏²

(1. 武汉大学 电气工程学院, 湖北 武汉 430072;

2. 中国地质大学 数理学院, 湖北 武汉 430074)

摘要: 采用一种具有很强的非平稳信号跟踪、预测能力的原子稀疏分解(ASD)法, 作为人工神经网络(ANN)的前置分解方法, 将风电功率序列分解为原子分量和残差分量, 对原子分量进行自预测, 残差分量进行 ANN 预测, 再通过追加最新的风电功率实时数据来更新 ASD 的结果, 进而滑动预测下一个时刻的风电功率。以实际风电场数据进行验证, 结果证明了该模型可以有效地处理风电功率非平稳性, 产生更为稀疏的分解效果, 显著地降低了绝对平均误差、均方根误差计算值的统计区间。

关键词: 风电; 预测; 原子稀疏分解; 人工神经网络; 模型

中图分类号: TM 614

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2014.01.021

0 引言

风能作为可再生能源中成本较低、技术较成熟、可靠性较高的新能源, 近年来发展很快并开始能源供应中发挥重要作用。随着风电场规模的增大, 风速的波动性^[1-4]和非平稳性成为制约风电大规模、高效并网的严峻问题。风电功率预测技术是解决风电波动^[5]、风电并网^[6]和电网调度^[7]的关键技术之一, 这也对风电功率的预测精确提出了更高的要求。

为得到较高的预测精度, 国内外很多研究集中在构造合适的预测模型。根据输入量的不同, 现有预测模型可以分为物理模型、统计模型和物理统计混合模型: 物理模型^[8-9]使用如气象学(数值天气预报等)、地质学(山岳形态等)和风电机组的技术特征(轮毂高度、功率曲线和推力系数)等信息作为模型输入量, 目的是得到本地风速的最佳估计值, 进而利用模式输出统计(MOS)方法减小预测残差; 统计模型^[10-12]使用解释变量和在线测量方法, 通常使用如递归最小二乘法和人工神经网络 ANN(Artificial Neural Network)法等递归技术; 混合模型^[13-15]作为最优模型, 先得到风电机组区域内的气流等物理量, 再使用先进的统计模型补充物理模型得到的信息, 因而能够得到更为精确的预测值。由于物理方法中风电场周围的物理信息等对预测结果的精确度有很大影响, 而统计方法能够根据风电场自身的特点和位置, 随时修改预测模型参数, 可以得到比较高的准确度。

国内对风电功率测报与预测提出了最新的技术要求, 2009 年国家电网公司发布企业标准 Q/GDW

392—2009《风电场接入电网技术规定实施细则(试行)》中明确规定, 风电功率预测系统应能通过专网向调度机构上报相关数据, 应至少具备日前预报功能和超短期预报功能, 每日 12:00 之前向调度机构申报次日日前风电功率预测曲线, 根据超短期预测结果, 滚动调整 2 h 以后的风电功率预测曲线^[16]。国外主要集中在预测模型的研究, 比国内起步早, 技术也相对成熟。为得到提前 0.5~36 h 的预测值, 丹麦科技大学(DTU)提出一种计及遗忘因子的自适应递归最小二乘估计法的风电功率预测模型; 马德里卡洛斯第三大学提出 Siplelico 模型, 该模型由 9 个自适应非参数统计模型组成, 使用递归最小二乘算法或者卡尔曼滤波算法循环计算; TrueWind 公司提出一种 EWIND 模型, 该模型使用一次性参数设计方法研究顺风向 NWP 模型输出量的局部效应^[17]。

现有的风电功率预测建模方法中, 很少有考虑原始风电功率序列的非平稳特性的方法, ANN 是一种应用广泛的风电功率预测建模方法, 但由于其自适应训练的收敛性受步长、隐含层神经元个数、隐含层输出函数和输出层输出函数等因素影响, 训练时间较长, 往往不能完全映射风电功率的非平稳特性。因此本文采用一种具有很强的非平稳信号跟踪、预测能力的信号处理新方法——原子稀疏分解 ASD(Atomic Sparse Decomposition)法, 作为 ANN 的前置分解手段。现实中的风电功率具有很强的非平稳性, 可看作具有多个不同参数的原子分量和残差分量的叠加, 其非平稳性导致原子参数不断变化。对原子分量进行自预测, 残差分量进行 ANN 预测, 叠加后得到最终预测结果。较之常规的 ANN 预测方法, 所提预测方法具有更好的处理非平稳特性的能力。将该方法应用于国内外某几个实际风电场的风电功率预测中, 取得了令人满意的结果, 预测精度也符合要求。

收稿日期: 2013-02-03; 修回日期: 2013-12-03

基金项目: 国家重点基础研究发展计划(973 计划)资助项目(2012-CB215101)

Project supported by the National Key Basic Research Program of China(973 Program)(2012CB215101)

1 ASD 理论

1.1 基本概念

近年来 ASD 技术在信号处理领域成为热点。该方法源于文献[18]提出的信号在过完备原子库上分解的思想,在信号建模、压缩、特征提取等方面具有重要作用。ASD 采取的是一种贪婪的自适应分解策略,其原子库是高度冗余(过完备)的,以保证任意信号都可以从中自适应地选择一组最佳的原子来表示,使得分解结果非常稀疏,此过程则为稀疏分解。核心问题是如何自适应地寻找最佳匹配原子及其系数。

当前,ASD 法在电力系统中的应用才刚刚起步,且主要集中在电能质量扰动信号特征提取^[19-20]和低频振荡模式识别^[21]的研究。

1.2 字典集的构造

在 ASD 中,原子通常由一般性的核函数表示,在信号处理领域,多种核函数可用来表示原子,例如正弦函数^[22]、Chirp 函数^[23]。本文采用的核函数为高斯函数,如下式所示:

$$g(o) = \exp\left[-\frac{(o-c)^2}{2\sigma^2}\right] \quad (1)$$

其中, $g(o)$ 为高斯核函数; c 和 σ 分别为中心和尺度参数。选择不同的中心和尺度参数,可以构造一系列不同的原子,这些原子的集合称为字典集。图 1 中列举了 3 个不同的原子,其中, g_1 表示中心为 0、尺度为 2 的原子; g_2 表示中心为 2、尺度为 2 的原子; g_3 表示中心为 0、尺度为 3 的原子。

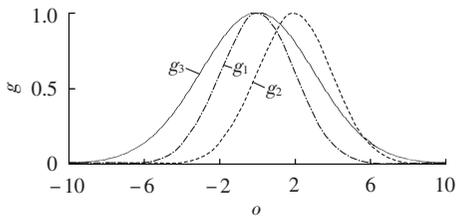


图 1 3 个不同原子(高斯核函数)的比较
Fig.1 Comparison among three different atoms(Gaussian kernel function)

1.3 双字典集的 ASD

在迭代分解过程中,每次迭代的待选择原子可以分为 2 类:先前已经被选择过的旧原子和尚未被选择过的新原子。因此,过完备字典集可以划分为 2 个分离的字典集:一个由旧原子构成,一个由新原子构成。

在开始阶段,所有的原子均属于新字典集,在分解过程的前面几次迭代中,大部分被选择的最优原子属于新字典集,随着迭代的继续,旧字典集慢慢增大。当旧字典集足够大时,被选择的最优原子大部分属于旧字典集。从稀疏性的角度看,新原子的选取不利于分解的稀疏性,为达到稀疏分解的目的应尽

可能从旧字典集中选取原子。因此,文献[24-25]提出了一种有利于分解稀疏性的最优原子选取流程,具体第 k 步迭代描述如下。

根据第 k 步以前的分解结果,过完备字典集已被分为旧和新 2 个字典集。由于 2 个信号的内积(各时刻 2 个信号乘积之和)描述了它们的线性相关性:内积的绝对值越大,2 个信号的相关性越强;内积为 0,2 个信号线性无关。所以,分别计算残差信号和 2 个字典集中各个原子的内积,并选出每个字典集中最大的内积 c^{old} 和 c^{new} ,其对应的旧和新字典集中的原子分别用 Φ^{old} 和 Φ^{new} 表示。

如果 $|c^{\text{old}}| \geq |c^{\text{new}}|$,选 Φ^{old} 作为该次迭代中的最优原子,即 $\Phi_{\text{opt}} = \Phi^{\text{old}}$, c^{old} 作为该最优原子的迭代系数,即 $c_{\text{opt}} = c^{\text{old}}$ 。显然,第 k 步之前的分解使得旧字典集中的每个原子都已有一个分解系数。因此,需将 c_{opt} 添加到被选原子 Φ^{old} 的分解系数上进行累加。最后,更新第 k 步的残差信号,即 $R^{(k)} = R^{(k-1)} - c_{\text{opt}} \Phi_{\text{opt}}$ 。

如果 $|c^{\text{old}}| < |c^{\text{new}}|$,那么第 k 步的最优原子按照如下步骤进行选择。

a. 分别计算旧和新字典集上的残差:

$$R^{\text{old}} = R^{(k-1)} - c^{\text{old}} \Phi^{\text{old}}, R^{\text{new}} = R^{(k-1)} - c^{\text{new}} \Phi^{\text{new}} \quad (2)$$

b. 计算相对误差 r_e :

$$r_e = \frac{\|R^{\text{old}} - R^{\text{new}}\|}{\|R^{\text{new}}\|} \quad (3)$$

其中, $\|\cdot\|$ 表示信号的欧氏范数。

c. 通过给定的阈值 T 决定最优原子:如果 $r_e \leq T$,选 Φ^{old} 作为该次迭代中的最优原子,后续的计算过程与 $|c^{\text{old}}| \geq |c^{\text{new}}|$ 情况下的相同;如果 $r_e > T$,选 Φ^{new} 作为该次迭代中的最优原子,更新变量,即令 $c_{\text{opt}} = c^{\text{new}}$, $\Phi_{\text{opt}} = \Phi^{\text{new}}$, $R^{(k)} = R^{\text{new}}$,将该原子添加到旧字典集中,并从新字典集中删除,系数 c_{opt} 作为该原子的分解系数。

d. 更新阈值。通过给定阈值 T ,在旧和新字典集中选择最优原子。为保证收敛和稳定性, T 是一个随着迭代步数而递减的函数,本文采用的是模拟退火算法中的退火函数:

$$T(k) = T_0 (\alpha^k)^{1/N} \quad (4)$$

其中, $0.7 \leq \alpha < 1$; T_0 为初始温度,并且设定小于 1; k 为当前迭代步数; N 为退火速度因子。随着迭代步数的增加, T 趋于 0。相关算法流程如图 2 所示。

2 ASD-ANN 滑动预测模型

2.1 数据预处理

在进行模型预测时,当输入或输出向量的各个分量量纲不同或大小相差很大时,应对不同的分量在其取值范围内分别进行归一化处理。考虑到本文所采用各分量的物理意义相同且为同一量纲,故采

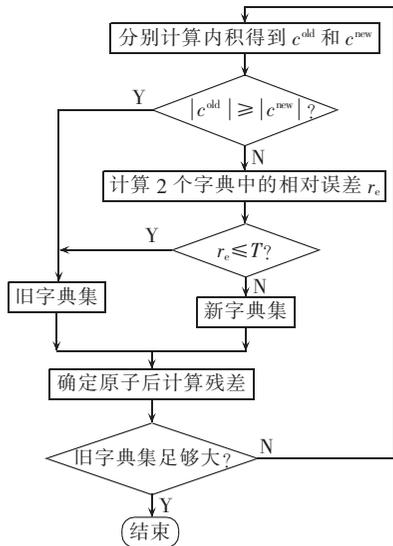


图 2 双字典集 ASD 法的算法流程图

Fig.2 Flowchart of ASD algorithm with two dictionaries

用先在整个数据范围内确定最大值和最小值再进行统一的归一化变换处理,进而将模型输入输出变换为 $[0,1]$ 区间的值,具体归一化公式如下:

$$\tilde{x}_{\text{put}} = \frac{x_{\text{put}} - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (5)$$

其中, x_{put} 为模型的输入或输出分量; \tilde{x}_{put} 为经过归一化处理后的输入或输出分量; x_{max} 和 x_{min} 分别为模型输入或输出量的最大值和最小值。

2.2 ASD 预测模型建立

风机的发电量由于受到平均风速、主导风向、最大风速、极大风速、气温、气压、空气密度、雷暴、电线覆冰等因素的影响,使得风电功率本质上具有很强的非平稳性。ANN 能较好地拟合输入输出数据间的非线性关系,但离线训练的 ANN 无法自适应输入信号的非平稳性,不能完全映射其特性。因此,本文采用 ASD 算法对风电功率进行滑动分解,并用残差信号取代原始信号作为 ANN 的输入量预测下个时刻的残差信号。由于残差信号的能量(相对于原始信号)很小,这样能极大地避免具有主导能量的信号成分(原子的线性组合)的非平稳性对 ANN 预测产生影响。模型结构见图 3,具体的预测过程描述如下。

a. 对风电功率数据进行 n 次 ASD,见式(6)。

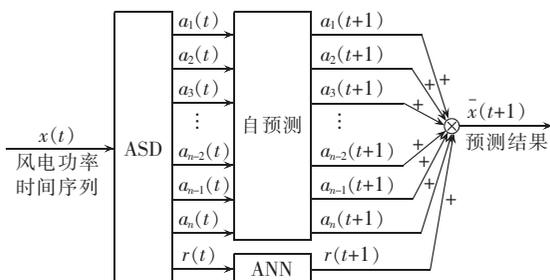


图 3 ASD-ANN 结构

Fig.3 Structure of ASD-ANN

$$x(t) = \sum_{j=1}^n a_j(t) + r(t) \quad (6)$$

其中, $r(t)$ 为残差分量; $a_j(t)$ 为第 j 个原子分量,等于原子与其分解系数的乘积。

b. 将残差信号作为 ANN 残差预测模型的输入量进行下一时刻的残差预测。

c. 根据 ASD 的表达式自预测下一时刻的原子分量值。

d. 将 ANN 残差预测结果与 ASD 预测结果叠加即得到下一时刻的原子稀疏分解-人工神经网络(ASD-ANN)模型预测值,如图 3 所示。图中, $x(t)$ 表示风电功率的时间序列, $\bar{x}(t+1)$ 表示模型预测值。

2.3 ANN 残差预测模型

文献[26-28]中已说明 ANN 可以用来拟合能量较小的风电功率残差分量。因此,本文采用常用的 ANN 作为残差预测模型,输入节点数设定为 15,根据 Kolmogorov 定理,中间节点数设定为 31,输出节点数设定为 1,对应于前 15 个时刻的残差分量,中间层采用正切 Sigmoid 传递函数,输出层采用对数 Sigmoid 传递函数,输出节点对应于下一时刻的风电功率残差分量预测值,模型网络结构如图 4 所示。

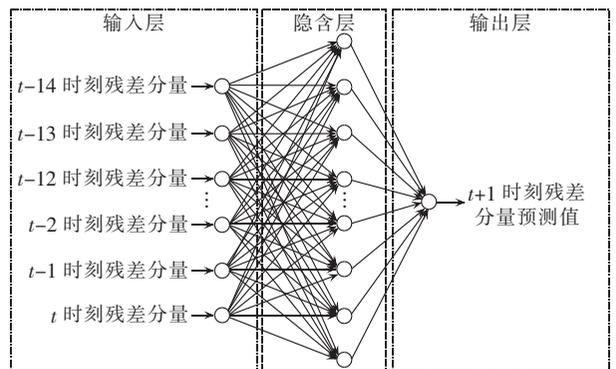


图 4 ANN 残差预测模型网络结构

Fig.4 Network structure of ANN residual forecasting model

2.4 滑动预测模型

一般而言,一个确定的风电功率序列经过 ASD-ANN 预测模型前置分解后,必然得到一组参数确定、平稳且具有主导能量的原子分量和非平稳、随机性强但能量小的残差分量。由于原子分量占有主导作用,这种方法从本质上讲还是片面地把风电功率数据当作平稳序列来处理。因此,本文提出一种滑动预测方法,通过 2.2 节建立 50 个最佳的预测模型。采用最新的输入变量和对应的不同模型来对下一个 15 min 风电功率进行滑动预测。每个模型对应的输入变量不同:模型 M_i 以第 i 点前的 400 点风电功率作为输入变量,对第 i 点预测; M_{i+1} 利用第 i 点的实测值和第 i 点前的 399 点风电功率作为输入变量,依

此类推。

采用时间尺度确定的时间窗进行下一时刻的预测,得到预测值后时间窗滑动向前推进一个时刻,继续类似的预测。该方法的优点在于,虽然时间窗内的分解得到的是平稳的原子分量,但随着时间窗不断地向前滑动,时间窗与时间窗之间的原子分量参数是不断变化的,当训练样本足够大时,时间窗个数很多,可视为对风电功率数据进行了非平稳化处理;同时,随着时间窗的滑动,原子分量自适应地调节自身的参数,以适应非平稳的风电功率数据,极大地增强了预测模型的泛化能力。

2.5 预测结果校正

目前国内外的风电功率预测模型中,风电功率预测精度较差,使用滑动模型进行风电功率预测时有必要对预测结果进行校正。采用线性回归方法进行校正^[29],校正模型如下:

$$P_{ASD,t}^c = P_{ASD,t} - e_{ASD,t} \quad (7)$$

其中, $P_{ASD,t}$ 为采用 ASD-ANN 模型的 t 时刻的风电功率预测值; $P_{ASD,t}^c$ 为校正后的 t 时刻预测值; $e_{ASD,t} = a + bP_{ASD,t}$ 为 t 时刻的预测误差, a 和 b 为参数,可采用最小二乘法计算得到,由历史风电功率及其误差样本数据进行估计,方法如式(8)、(9)所示。

$$a = e_{ASD,i} - bP_{ASD,i} \quad (8)$$

$$b = \frac{N_c \sum_{i=1}^{N_c} (e_{ASD,i} P_{ASD,i}) - \sum_{i=1}^{N_c} e_{ASD,i} \sum_{i=1}^{N_c} P_{ASD,i}}{N_c \sum_{i=1}^{N_c} P_{ASD,i}^2 - \left| \sum_{i=1}^{N_c} P_{ASD,i} \right|^2} \quad (9)$$

其中, N_c 为历史样本数量; $e_{ASD,i} = P_{ASD,i} - P_{meas,i}$ 为历史风电功率预测误差, $P_{meas,i}$ 为风电场实测风电功率数据, $P_{ASD,i}$ 为实测数据的模型训练值。

综上所述,可以得到本文提出的 ASD-ANN 风电功率滑动预测模型结构如图 5 所示。

3 算例分析

3.1 算例 1

为验证本文采用的基于双字典集的 ASD 算法的有效性,使用 MATLAB 7.10 进行算法编程,构造一个典型非平稳的测试信号,如下所示:

$$y(i) = 0.1i + \frac{\sin i}{i} + \sin(0.5i) + e \quad (10)$$

其中, $i \in [-15, 15]$, 从中均匀抽取 600 个采样点, e 为随机白噪声信号。根据 2.3 节所述,取前 400 个点进行 ASD,残差信号序列作为 ANN 的训练样本,后 200 个点作为测试样本。

根据文献[24-25],计算过程中的迭代分解参数 $\alpha = 0.935$,初始温度 $T_0 = 0.09$,退火速度因子 $N = 2.5$,迭代终止阈值为 1.0×10^{-6} 。图 6 为构造的测试信号,图 7 为预测结果。

当 $i \in [-10, 10]$ 时,分析比较单字典集和双字典集的 ASD 算法仿真效果如表 1 所示。定义测试信号的绝对平均误差 e_{NMAE} 和均方根误差 e_{NRMSE} 的公式分别如式(11)、(12)所示。

$$e_{NMAE} = \frac{1}{M} \sum_{i=1}^M |\hat{y}(i) - y(i)| \quad (11)$$

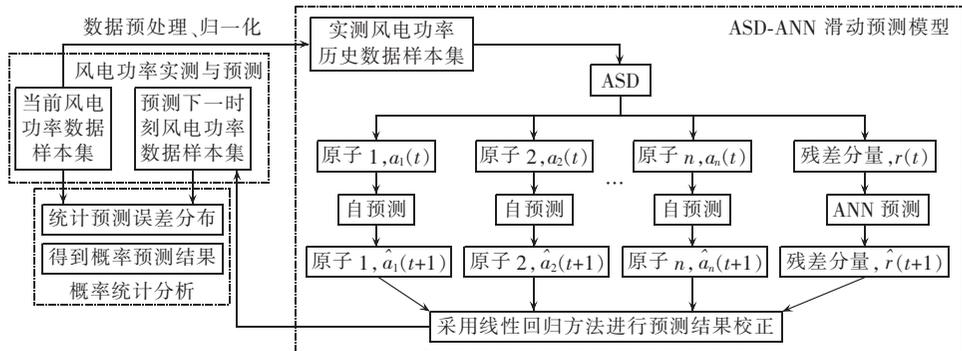


图 5 风电功率预测模型结构图

Fig.5 Structure of wind power forecasting model

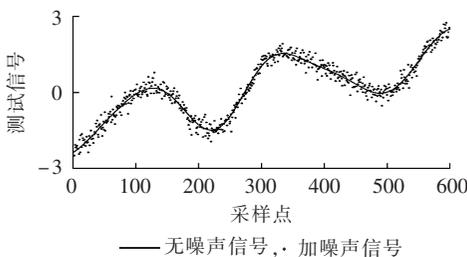


图 6 测试信号的采样数据

Fig.6 Sampling data of test signals

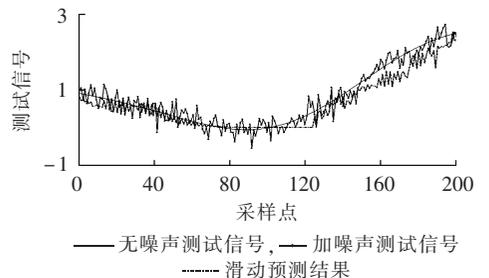


图 7 测试信号的预测结果对比

Fig.7 Comparison among forecasting results of test signals

$$e_{\text{NRMSE}} = \sqrt{\frac{1}{M} \sum_{i=1}^M [\hat{y}(i) - y(i)]^2} \quad (12)$$

其中, $y(i)$ 为测试信号; $\hat{y}(i)$ 为预测结果; M 为预测样本个数。

表 1 2 种 ASD 仿真结果对比

Tab.1 Comparison of simulative results between two kinds of ASD

信号	单字典集分解		双字典集分解	
	$e_{\text{NMAE}}/\%$	$e_{\text{NRMSE}}/\%$	$e_{\text{NMAE}}/\%$	$e_{\text{NRMSE}}/\%$
无噪声	7.83	10.09	5.85	7.26
加噪声	17.52	21.90	16.27	20.47
运行时间/s	4.453		3.485	

由图 6、图 7 和表 1 可见:

a. 相比基于单字典集的 ASD 算法, 基于双字典集的 ASD 算法预测结果的绝对平均误差和均方根误差均有一定程度的降低;

b. 在无噪声和加噪声的情况下, 基于双字典集的 ASD 算法的预测效果均更加精确;

c. 完成仿真计算的时间仅为 3.485 s, 约减少 1 s 的时间。

3.2 算例 2

选取 2006 年 5 月 10 日至 2006 年 5 月 24 日内国内某风电场 58 台风电机组中的某一台风电机组输出功率数据, 时间分辨率为 15 min, 总共 1440 个数据。选取其中前 450 点作为样本数据进行实验, 如图 8 所示。

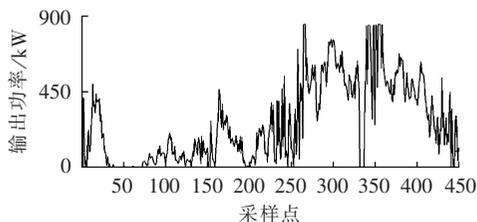


图 8 前 450 个点的风电功率数据

Fig.8 Wind power data of former 450 points

选取图 8 中前 400 个数据点分解的残差信号作为 ANN 的训练样本, 后 50 个数据点作为测试样本。预测结果如图 9 所示, 参数如表 2 所示。

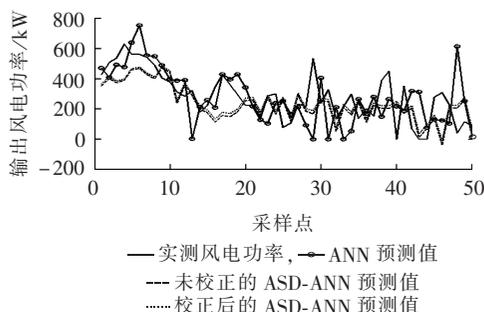


图 9 采用 ANN 和 ASD-ANN 的预测结果对比

Fig.9 Comparison of forecasting results between ANN and ASD-ANN

表 2 前 400 个数据点的 ASD 结果参数表

Tab.2 ASD parameters of former 400 points

原子编号	中心	尺度	权值
1	7.7444	1.0000	0.8472
2	4.4361	1.0000	0.8799
3	9.6491	0.5000	0.4475
4	-1.5789	1.0000	0.2622
5	-9.1980	0.2500	0.4975
6	6.6416	0.1250	-0.5789
7	1.3283	0.5000	0.2548
8	4.0351	0.1250	-0.4873
9	3.2331	0.0625	0.4849

作为对比, 采用常规 ANN 预测风电功率^[27]。由于预测误差大小和风机容量有直接关系, 为了定量评价预测效果, 采用国际上普遍的归一化绝对平均误差 e_{NMAE} 和归一化均方根误差 e_{NRMSE} 为依据, 定义如下:

$$e_{\text{NMAE}} = \frac{1}{P_{\text{cap}}} \frac{1}{M} \sum_{i=1}^M |\hat{x}(i) - x(i)| \quad (13)$$

$$e_{\text{NRMSE}} = \frac{1}{P_{\text{cap}}} \sqrt{\frac{1}{M} \sum_{i=1}^M [\hat{x}(i) - x(i)]^2} \quad (14)$$

其中, $x(i)$ 为实际值; $\hat{x}(i)$ 为预测值; P_{cap} 为风机的额定容量。表 3 分别列出了常规 ANN 法、校正前后 ASD-ANN 风电功率的绝对平均误差和均方根误差。

表 3 3 种预测方法的误差对比

Tab.3 Comparison of errors among three forecasting methods

预测方法	$e_{\text{NMAE}}/\%$	$e_{\text{NRMSE}}/\%$
ANN	16.32	21.44
未校正的 ASD-ANN	13.10	16.53
校正后的 ASD-ANN	12.71	15.86

由图 9 和表 3 可见:

a. 校正后得到的风电功率预测结果相对于校正前得到较大的改善, 而常规 ANN 法不能较好地自适应风电功率的强非平稳性, 导致其预测误差最大;

b. ASD-ANN 滑动预测的误差总体上小于 ANN 预测的误差;

c. 对预测结果的校正只能有限地提高预测精度, 而采用合适的预测方法、充分考虑风电功率的非平稳性才是提高预测精度的主要方法。

3.3 算例 3

为验证所提预测方法的鲁棒性, 采用统计学方法分析单台风机在不同时段和不同风机在同一时段的预测效果。

3.3.1 单台风机在不同时段预测误差统计分析

选取 2001 年 1 月 1 日至 2008 年 6 月 23 日内国外某风机输出功率数据作为样本。统计过程中, 每 600 个采样点作为一个时间段记录一次预测结果, 总共统计 50 个时间段, 即 30000 个采样点。计算每

个时间段的绝对平均误差并统计出现的频率,结果如图 10 所示。图中,频率直方图指样本观测值在各区间单位长度内的频数与总数的比值。

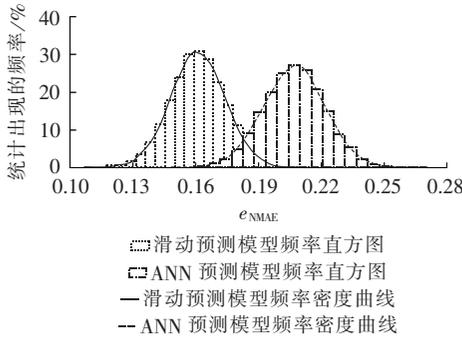


图 10 统计绝对平均误差出现的频率

Fig.10 Statistical frequency of absolute mean error

采用统计学常用的正态分布拟合方法分别拟合图 10 中 2 种预测方法的绝对平均误差(置信区间取值均为 95%),得到均值的估计值分别为 16.13% 和

20.72%,标准差的估计值分别为 1.26% 和 1.46%。可见,就单台风机在不同时段的预测误差统计分析而言,统计结果有效验证了本文预测方法的鲁棒性,绝对平均误差由常规 ANN 预测方法得到的 20.72% 降至本文所提方法的 16.13%,精度提高约 30%。

3.3.2 不同风机在同一时段的预测结果对比分析

选取某风电场 4 台风电机组输出功率数据,时间为 2006 年 5 月 10 日至 2006 年 5 月 16 日,分辨率为 15 min,每台机组选取 600 个采样点,前 400 个点作为训练样本,后 200 个点作为测试样本^[30]。不同风机在同一时段的预测结果如表 4 所示。

由图 10 和表 4 可得出以下结论。

a. 根据文献[31]提出的相关系数判断随机变量相关性的准则,ANN 预测方法的预测结果与实测结果相关系数约为 0.36~0.49,二者具有低度相关;本文所提预测方法的预测结果与实测结果相关系数约为 0.50~0.57,二者具有中度相关。

表 4 不同风机在同一时段的预测结果对比

Tab.4 Comparison of forecasting results for same period among different wind turbines

机组编号	装机容量/MW	样本数	ANN 预测方法				ASD-ANN 滑动预测方法					
			$e_{NMAE}/\%$	$e_{NRMSE}/\%$	合格率/%		相关系数	$e_{NMAE}/\%$	$e_{NRMSE}/\%$	合格率/%		相关系数
					$e_{NRMSE}<20\%$	$e_{NRMSE}<10\%$				$e_{NRMSE}<20\%$	$e_{NRMSE}<10\%$	
A	850	600	17.22	22.41	75.00	57.00	0.4674	16.76	21.78	85.50	71.00	0.5071
B	850	600	17.03	23.48	78.00	61.50	0.4841	17.64	22.57	84.50	71.00	0.5215
C	850	600	16.91	22.84	76.50	65.00	0.4134	15.60	20.22	83.50	73.50	0.5616
D	850	600	18.10	23.57	76.50	59.00	0.3637	17.27	22.22	81.00	68.50	0.5214

b. 预测结果与实测结果的偏差分析可知,ANN 预测方法的绝对平均误差约为 17%~19%,均方根误差约为 22%~24%,预测数据合格率($e_{NRMSE}<10\%$)约为 57%~65%;本文所提预测方法的绝对平均误差约为 15%~18%,均方根误差约为 20%~23%,预测数据合格率($e_{NRMSE}<10\%$)约为 68%~74%。

可以看出,就不同风机在同一时段的预测结果对比分析而言,所提预测方法提高了预测结果与实测结果的相关度和预测数据合格率的统计区间,降低了绝对平均误差、均方根误差计算值的统计区间。

4 结论

ASD 是近年来信号稀疏分解领域的新热点,可实现对信号更加灵活、简洁和自适应的表示。针对风电功率的非平稳性,本文将双字典集 ASD 和 ANN 相结合的方法引入到风力发电功率时间序列的预测中。通过滑动的 ASD,信号中能量占主导地位的非平稳部分能较准确地被预测。同时,ANN 可以较好地映射出较平稳的残差信号输入输出之间的非线性关系。将该方法应用于某几个实际风电场的功率预测中,结果表明,该方法可以有效地处理风电功率的非平稳性,能够产生更为稀疏的分解效果,降低绝对

平均误差、均方根误差计算值的统计区间。

参考文献:

- [1] 孙元章,林今,李国杰,等. 采用变速恒频机组的风电场并网问题研究综述[J]. 电力系统自动化,2010,34(3):75-80.
SUN Yuanzhang,LIN Jin,LI Guojie,et al. A survey on the grid integration of wind farms with variable speed wind plant systems [J]. Automation of Electric Power Systems,2010,34(3):75-80.
- [2] 刘亚南,卫志农,朱艳,等. 基于 D-S 证据理论的短期风速预测模型[J]. 电力自动化设备,2013,33(8):131-136.
LIU Yanan,WEI Zhinong,ZHU Yan,et al. Short-term wind speed forecasting model based on D-S evidence theory[J]. Electric Power Automation Equipment,2013,33(8):131-136.
- [3] SORENSEN P,CUTULULIS N A,VIGUERAS-RODRIGUEZ A, et al. Power fluctuations from large wind farms[J]. IEEE Trans on Power Systems,2007,22(3):958-965.
- [4] 刘振亚. 中国电力与能源[M]. 北京:中国电力出版社,2012:104-109.
- [5] 林今,孙元章,李国杰,等. 采用变速恒频机组的风电场有功功率波动对系统节点频率影响的动态评估模型[J]. 电力自动化设备,2010,30(2):14-18.
LIN Jin,SUN Yuanzhang,LI Guojie,et al. Dynamic evaluation model of node frequency deviation caused by power fluctuation of wind farm with variable speed wind turbine systems [J]. Electric Power Automation Equipment,2010,30(2):14-18.
- [6] 杨捷,金新民,吴学智,等. 兆瓦级全功率风电并网变流器功率组

- 件设计[J]. 电力自动化设备, 2013, 33(10): 21-27.
- YANG Jie, JIN Xinmin, WU Xuezhong, et al. Power stack design of MW-level full-power grid-connected converter for wind power generation[J]. Electric Power Automation Equipment, 2013, 33(10): 21-27.
- [7] 龙虹毓, 徐瑞林, 何国军, 等. 基于热风电协调调度的系统日调峰能力分析[J]. 电力自动化设备, 2013, 33(4): 30-34.
- LONG Hongyu, XU Ruilin, HE Guojun, et al. Analysis of peak-load regulation capability based on combined dispatch of wind power and thermal power[J]. Electric Power Automation Equipment, 2013, 33(4): 30-34.
- [8] 冯双磊, 王伟胜, 刘纯, 等. 风电场功率预测物理方法研究[J]. 中国电机工程学报, 2010, 30(2): 1-6.
- FENG Shuanglei, WANG Weisheng, LIU Chun, et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE, 2010, 30(2): 1-6.
- [9] 冯双磊, 王伟胜, 刘纯, 等. 基于物理原理的风电场短期风速预测研究[J]. 太阳能学报, 2011, 32(5): 611-616.
- FENG Shuanglei, WANG Weisheng, LIU Chun, et al. Short term wind speed prediction based on physical principle[J]. Acta Energetica Solaris Sinica, 2011, 32(5): 611-616.
- [10] 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, 2011, 35(16): 44-48.
- SHI Hongtao, YANG Jingling, DING Maosheng, et al. A short-term wind power prediction method based on wavelet decomposition and BP neural network[J]. Automation of Electric Power Systems, 2011, 35(16): 44-48.
- [11] 杨秀媛, 肖洋, 陈树勇. 风电场风速和发电功率预测研究[J]. 中国电机工程学报, 2005, 25(11): 1-5.
- YANG Xiuyuan, XIAO Yang, CHEN Shuyong. Wind speed forecast model for wind farms based on time series analysis[J]. Proceedings of the CSEE, 2005, 25(11): 1-5.
- [12] 邵能灵, 侯志俭, 李涛, 等. 基于小波分析的电力系统短期负荷预测方法[J]. 中国电机工程学报, 2003, 23(1): 45-50.
- TAI Nengling, HOU Zhijian, LI Tao, et al. New principle based on wavelet transform for power system short-term load forecasting[J]. Proceedings of the CSEE, 2003, 23(1): 45-50.
- [13] 洪翠, 温步瀛, 林维明. 基于改进 OLS-RBF 神经网络模型的短期风电场出力预测[J]. 电力自动化设备, 2012, 32(9): 40-43.
- HONG Cui, WEN Buyang, LIN Weiming. Short-term forecasting of wind power output based on improved OLS-RBF ANN model[J]. Electric Power Automation Equipment, 2012, 32(9): 40-43.
- [14] 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, 2013, 33(7): 34-38.
- LING Wuneng, HANG Naishan, LI Ruqi. Short-term wind power forecasting based on cloud SVM model[J]. Electric Power Automation Equipment, 2013, 33(7): 34-38.
- [15] GIEBEL G, LANDBERG L, NIELSEN T S, et al. The ZEPHYR-project: the next generation prediction system[C]//Proc of the 2001 European Wind Energy Conference, EWEC'01. Copenhagen, Denmark; [s.n.], 2001: 777-780.
- [16] 国家电网公司. Q/GDW392—2009 风电场接入电网技术规定实施细则[S]. 北京: 国家电网公司企业标准, 2009.
- [17] SIDERATOS G, HATZIARGYRIOU N D. An advanced statistical method for wind power forecasting[J]. IEEE Trans on Power Systems, 2007, 22(1): 258-265.
- [18] MALLAT S G, ZHANG Z. Matching pursuits with time frequency dictionaries[J]. IEEE Trans on Signal Processing, 1993, 41(12): 3397-3415.
- [19] 王宁, 李林川, 贾清泉, 等. 应用原子分解的电能质量扰动信号分类方法[J]. 中国电机工程学报, 2011, 31(4): 51-58.
- WANG Ning, LI Linchuan, JIA Qingquan, et al. Classification of power quality disturbance signals using atomic decomposition method[J]. Proceedings of the CSEE, 2011, 31(4): 51-58.
- [20] 刘林, 林涛, 肖英伟, 等. 基于组合滤波和时频原子变换的故障录波数据分析新算法[J]. 电力自动化设备, 2012, 32(7): 83-88.
- LIU Lin, LIN Tao, XIAO Yingwei, et al. Fault recording data analysis based on combinational filter and time-frequency transform[J]. Electric Power Automation Equipment, 2012, 32(7): 83-88.
- [21] 李勋, 龚庆武, 贾晶晶. 采用原子分解能量熵的低频振荡主导模式检测方法[J]. 中国电机工程学报, 2012, 32(1): 131-139.
- LI Xun, GONG Qingwu, JIA Jingjing. A detection method of low frequency oscillation dominant modes based on atomic decomposition energy entropy[J]. Proceedings of the CSEE, 2012, 32(1): 131-139.
- [22] LOVISLO L, da SILVA E A B, RODRIGUES M A M, et al. Efficient coherent adaptive representations of monitored electric signals in power systems using damped sinusoids[J]. IEEE Trans on Signal Processing, 2005, 53(10): 3831-3846.
- [23] 朱明, 金炜东, 胡来招. 基于原子分解的辐射源信号二次特征提取[J]. 西南交通大学学报, 2007, 42(6): 659-664.
- ZHU Ming, JIN Weidong, HU Laizhao. Cascade feature extraction for radar emitter signals based on atomic decomposition[J]. Journal of Southwest Jiaotong University, 2007, 42(6): 659-664.
- [24] XU Peng, YAO Dezhong. Two dictionaries matching pursuit for sparse decomposition of signals[J]. IEEE Trans on Signal Processing, 2006, 54(11): 3472-3480.
- [25] 王树鹏, 王文祥, 李宏伟. 基于双字典集的信号稀疏分解算法[J]. 计算机应用, 2012, 32(9): 2512-2515.
- WANG Shupeng, WANG Wenxiang, LI Hongwei. Signal sparse decomposition based on the two dictionary sets[J]. Journal of Computer Applications, 2012, 32(9): 2512-2515.
- [26] 王丽婕, 冬雷, 廖晓钟, 等. 基于小波分析的风电场短期发电功率预测[J]. 中国电机工程学报, 2009, 29(28): 30-33.
- WANG Lijie, DONG Lei, LIAO Xiaozhong, et al. Short-term power prediction of a wind farm based on wavelet analysis[J]. Proceedings of the CSEE, 2009, 29(28): 30-33.
- [27] 范高锋, 王伟胜, 刘纯, 等. 基于人工神经网络的风电功率预测[J]. 中国电机工程学报, 2008, 28(34): 118-123.
- FAN Gaofeng, WANG Weisheng, LIU Chun, et al. Wind power prediction based on artificial neural network[J]. Proceedings of the CSEE, 2008, 28(34): 118-123.
- [28] KARNIOTAKIS G, STAVRAKAKIS S G, NOGARET E F. Wind power forecasting using advanced neural network models[J]. IEEE Trans on Energy Conversion, 1996, 11(4): 762-767.
- [29] 王彩霞, 鲁宗相, 乔颖, 等. 基于非参数回归模型的短期风电功

率预测[J]. 电力系统自动化,2010,34(16):78-82.

WANG Caixia,LU Zongxiang,QIAO Ying,et al. Short-term wind power forecast based on non-parametric regression model [J]. Automation of Electric Power Systems,2010,34(16):78-82.

[30] 陈颖,周海,王文鹏,等. 风电场输出功率超短期预测结果分析与改进[J]. 电力系统自动化,2011,35(15):30-33.

CHEN Ying,ZHOU Hai,WANG Wenpeng,et al. Improvement of ultra-short-term forecast for wind power[J]. Automation of Electric Power Systems,2011,35(15):30-33.

[31] 林卫星,文劲宇,艾小猛,等. 风电功率波动特性的概率分布研究[J]. 中国电机工程学报,2012,32(1):38-46.

LIN Weixing,WEN Jinyu,AI Xiaomeng,et al. Probability density function of wind power variations[J]. Proceedings of the CSEE,2012,32(1):38-46.

作者简介:



崔明建

崔明建(1987-),男,河北衡水人,博士研究生,研究方向为风电功率预测与控制等(E-mail:mj_cui@whu.edu.cn);

孙元章(1954-),男,湖南岳阳人,教授,博士研究生导师,主要研究方向为电力系统分析与控制等(E-mail:yzsun@tsinghua.edu.cn);

柯德平(1983-),男,湖北黄石人,讲师,博士,主要从事电力系统分析与控制等方面的研究工作(E-mail:ee-dp.ke@connect.polyu.hk);

王树鹏(1987-),男,河北衡水人,硕士研究生,研究方向为模式识别等(E-mail:wangshupeng728@126.com)。

Short-term wind power forecasting based on atomic sparse decomposition theory

CUI Mingjian¹,SUN Yuanzhang¹,KE Deping¹,WANG Shupeng²

(1. School of Electrical Engineering,Wuhan University,Wuhan 430072,China;

2. School of Mathematics and Physics,China University of Geosciences,Wuhan 430074,China)

Abstract: ASD(Atomic Sparse Decomposition),which has excellent ability to track and forecast unstable signal,is applied as the pre-decomposition of ANN(Artificial Neural Network) to decompose the wind power series into atomic component and residual component. The former is self-forecasted while the latter is forecasted by ANN. The latest real-time data of wind power are added to update the result of ASD for forecasting the wind power of next instant. The model is verified by the practical data of a wind farm, which shows that,the instability of wind power is effectively dealt with to produce more sparse decomposition effect,significantly reducing the statistical intervals of absolute mean error and root mean square error.

Key words: wind power; forecasting; atomic sparse decomposition; ANN; models

(上接第 119 页 continued from page 119)

PENG Huifeng,SUN Jianping,CAO Xiangchun,et al. MPPT algorithm based on power duty cycle differential characteristic curve for photovoltaic system[J]. Electric Power Automation Equipment,2013,33(6):124-127.

[17] 唐磊,曾成碧,徐伟,等. 一种新颖的光伏自适应变步长最大功率点跟踪算法[J]. 电力自动化设备,2013,33(11):128-133.

TANG Lei,ZENG Chengbi,XU Wei,et al. Variable-step adaptive MPPT algorithm for photovoltaic system[J]. Electric Power Automation Equipment,2013,33(11):128-133.

[18] 尤鋈,郑建勇. 基于模糊 PI 调节 Boost 电路的光伏系统最大功率点跟踪控制[J]. 电力自动化设备,2012,32(6):94-98.

YOU Jun,ZHENG Jianyong. MPPT of photovoltaic system with

Boost circuit based on fuzzy PI control[J]. Electric Power Automation Equipment,2012,32(6):94-98.

作者简介:



孙博

孙博(1987-),男,江苏徐州人,博士研究生,主要研究方向为电力电子与电力传动(E-mail:sb16897168@sina.com);

梅军(1971-),男,江苏淮安人,副教授,主要研究方向为电力电子与电力传动;

郑建勇(1966-),男,江苏南京人,教授,博士研究生导师,主要研究方向为电力电子与电力传动。

Improved MPPT method under partial shading conditions

SUN Bo,MEI Jun,ZHENG Jianyong

(College of Electrical Engineering,Southeast University,Nanjing 210096,China)

Abstract: The output characteristics of photovoltaic array under different partial shading conditions are simulated with MATLAB and the relationship between the voltage of probable local maximum power point and the open circuit voltage of photovoltaic array is summarized,according to which,an improved incremental conductance method is proposed. It sets the voltage of probable partial maximum power point as the reference voltage successively to prevent any peak point missing and compares the local maximum power points to track the global maximum power point. The reference voltage threshold is set to detect the local maximum power point for reducing the searching time. Simulative results verify that the proposed method can accurately find out the global maximum power point under both none and partial shading conditions.

Key words: photovoltaic cells; partial shading; global MPPT algorithm; incremental conductance; open circuit voltage