

# 基于近邻传播聚类 and 回声状态网络的光伏预测

李 乐, 刘天琪

(四川大学 电气信息学院, 四川 成都 610065)

**摘要:** 分析了天气因素对光伏出力的影响, 选择预报技术较为成熟的气象信息和能反映光伏变化趋势的波动分量作为分类特征。针对传统预测算法在突变天气条件下预测精度较低的问题, 提出基于近邻传播聚类和回声状态网络的组合算法, 通过近邻传播算法对光伏出力进行分类, 并根据预测日所属的类别建立回声网络状态方程进行光伏出力预测。仿真表明所提算法不仅能满足非突变型天气下的光伏预测要求, 还能较好地跟踪突变型天气下光伏出力变化, 具有更高的准确度和通用性。

**关键词:** 光伏发电; 预测; 波动分量; 近邻传播; 回声状态网络; 聚类算法

**中图分类号:** TM 615

**文献标识码:** A

**DOI:** 10.16081/j.issn.1006-6047.2016.07.007

## 0 引言

光伏能源具有随机性和间歇性的特点。光伏电站并网对电网的稳定和经济运行造成很大影响<sup>[1]</sup>, 较为准确的光伏日前预测系统有利于制定调度计划, 对提高电力系统的稳定性和安全性具有重要意义。

近年来, 光伏预测的研究主要有基于太阳辐射强度的间接预测方法和基于光伏电站历史数据的直接预测方法<sup>[2]</sup>。由于国外对光伏资源利用较早, 太阳辐照观测站多, 大多采用基于太阳辐射强度的间接预测法。而国内太阳辐照观测点较少, 尚未开展辐照预测业务, 多利用历史数据和当地气象条件进行预测。文献[3]建立广义天气类型, 对天气类型进行分类预测, 但该种分类方式并不均衡合理, 常出现同一天气类型下光伏出力波动变化大的现象, 导致预测结果与实测值差异大。文献[4]提出了天气类型指数的概念, 量化天气类型, 但该天气指数物理意义不明确。文献[5]将天气类型分为晴、阴、雨和突变天气进行分类预测, 选择预测日前一天的光伏出力作为预测条件, 但预测日和预测日前一天的光伏出力不存在相似性, 若预测日天气发生突变, 将产生较大误差。

光伏等间歇性能源出力变化多样, 对其历史数据统一建模的难度大。聚类预测是通过挖掘输入数据的内在属性相似性的组合预测方法, 具有较高的准确性<sup>[6-7]</sup>。近邻传播 AP(Affinity Propagation)聚类是一种新型聚类算法, 相较于其他聚类算法能更快地处理大规模数据, 避免局部最优等问题, 且利用直观信息更新方法, 简单实用。回声状态网络 ESN(Echo State Network)通过储蓄池完成训练, 较其他网络具备更好的记忆性和稳定性。本文提出一种基

于 AP 聚类和 ESN 的组合预测方法。

通过对光伏出力影响因素的研究, 发现仅靠天气信息对光伏数据进行分类并不合理。波动分量是能反映光伏出力受环境影响程度的趋势分量, 因此提出将光伏出力的波动分量和天气特征共同作为分类依据, 以完善聚类结果。首先按负荷分量的提取方法, 即滑动平均法分离光伏出力的波动分量, 并统计不同类型天气下光伏出力的变化情况, 用泰尔熵指数量化天气类型; 然后按历史数据的波动相似性和环境相似性进行 AP 聚类分析, 建立波动分类模型, 并对分类结果建立 ESN 方程进行二次预测; 最后以某实际光伏电站出力为算例, 将预测结果与几种常见的组合预测模型进行对比分析, 发现本文方法不仅在非突变天气下能获得较好的预测效果, 在突变天气下也能较好地跟踪光伏出力变化。

## 1 计及波动相似性的聚类特征集

### 1.1 光伏出力影响因子分析

光伏发电基本原理是利用半导体界面的“光生伏打效应”将光能转换成电能。其输出功率  $P_t$  为:

$$P_t = P_0 \frac{I_t}{I_0} [1 + \alpha_T (T_t - T_0)] \quad (1)$$

其中,  $P_t$  为  $t$  时刻的光电输出功率;  $P_0$  为标准条件下光伏板的出力;  $\alpha_T$  为光伏板的功率温度系数;  $I_t$  为  $t$  时刻太阳辐射强度;  $T_t$  为  $t$  时刻光伏板的温度。

由式(1)可知, 影响光伏出力的主要因素是太阳辐射强度和温度。但我国辐照观测点少, 获取辐射强度数据困难。考虑太阳辐射强度受天气因素的影响显著, 在未设立太阳辐照观测点的情况下, 部分文献采用天气类型(晴、阴、多云等)代替太阳辐射强度变化<sup>[8-9]</sup>。

2013 年的典型天气类型下的光伏出力如图 1 所示。通过比较不同天气类型下相邻几日的光伏出力, 发现仅晴天时日出力变化具有较高的一致性; 在

收稿日期: 2015-08-05; 修回日期: 2016-05-21  
基金项目: 四川省科技厅科技计划项目(2016GZ0143)  
Project supported by the Science and Support Project of Sichuan Province(2016GZ0143)

雨天等突变性较大的天气类型下,其大气物理状态存在较大波动,同一天气类型下的日出力曲线波动规律差异较大。由此说明天气类型不能完整表征辐射强度变化。

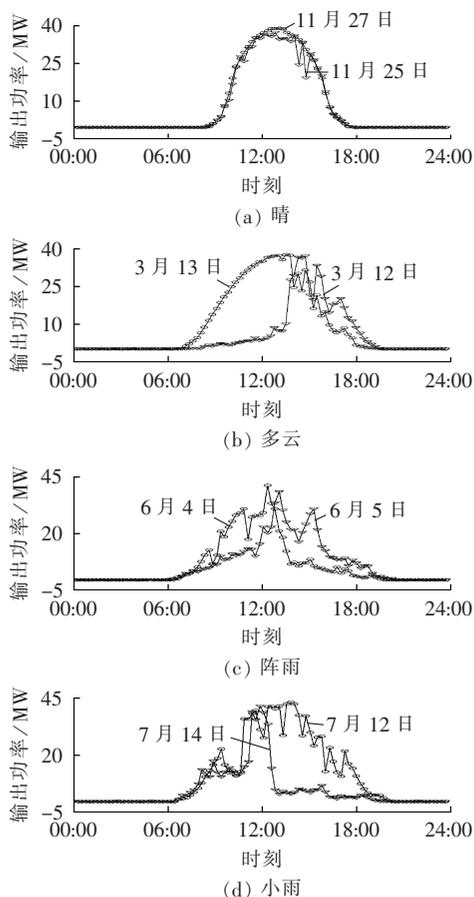


图 1 典型天气下邻近两天的光伏出力  
Fig.1 PV output power of two successive days for typical weathers

## 1.2 特征元素选择及波动分量提取

光伏出力不仅受气象因素的直接影响,还和历史出力数据有关。在气象数据获取受限的情况下,考虑引入光伏历史出力数据以表征其变化趋势。光伏出力日出力差异大,为避免聚类的结果过多,考虑以出力波动程度的相似性衡量日出力相关性。因此,本文提出以光伏出力的波动分量和天气条件(天气类型、温度)共同作为聚类特征元素。

日内波动量的变化直观反映了光伏出力的波动特性,借鉴负荷分钟级分量分离算法,本文选择滑动平均法提取光伏出力的波动分量<sup>[10-12]</sup>。设原始光伏出力序列为  $L_t$ ,则经平滑处理后的新出力序列为:

$$L_{ti} = \frac{1}{2M} (L_{t-(M-1)} + L_{t-(M-2)} + \dots + L_t + \dots + L_{t+M}) \quad (2)$$

其中,  $2M$  为滑动平均时间长度。

分别对 30 min、1 h、2 h 等时刻进行滑动平均处理,发现随着滑动时间长度的增加,波动分量幅度增

大,但增大幅度并不明显。为保证波动分量反映天气短时变化,同时减少计算复杂度,选取 1 h 为滑动平均时间长度,以实际光伏电站某日的光伏出力为例,其分离效果如图 2 所示。

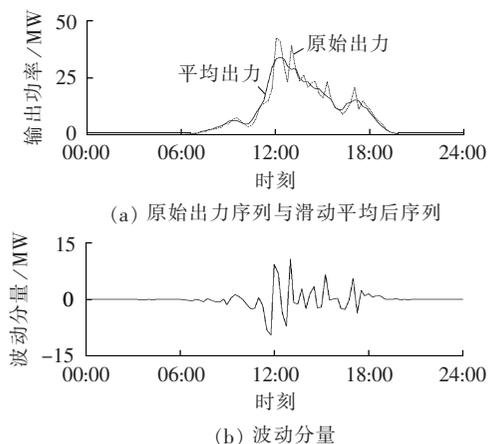


图 2 波动分量的分离

Fig.2 Extraction of fluctuant components

## 1.3 基于泰尔熵指标的天气类型量化

由式(1)可知,光伏出力主要受太阳辐射强度和温度影响,通过对光伏出力波动性分析,选择以历史波动分量和天气类型代替太阳辐射强度这一影响因素。因此,波动分类模型的输入特征确定为历史波动分量、天气类型和温度。其中历史波动分量和温度皆可用数值表示,但天气类型目前还没有较为统一且规范的方法量化。在此,选择泰尔熵指数作为天气类型的量化值<sup>[13]</sup>。

与其他量化指标不同,泰尔熵通过组间差异  $T_w$  和组内差异  $T_b$  共同描述对象间的差异度。考虑波动量和波动变化率是衡量光伏出力变化的重要指标,通过研究不同天气类型下的波动变化情况量化天气差异,以  $T_w$  和  $T_b$  共同作为天气类型量化值,即:

$$\begin{cases} T_w = \sum_i \left[ \frac{W_i}{W} \sum_j \left( \frac{W_{ij}}{W_i} \right) \ln \left( \frac{W_{ij}/W_i}{Y_{ij}/Y_i} \right) \right] \\ T_b = \sum_i \left[ \left( \frac{W_i}{W} \right) \ln \left( \frac{W_i/W}{Y_i/Y} \right) \right] \end{cases} \quad (3)$$

其中,  $W$  为光伏出力年波动总量,  $W_i$  为某种天气类型下光伏出力总波动量,  $W_{ij}$  为该种天气类型下日波动量;  $Y$  为光伏年度出力总和,  $Y_i$  为某种天气类型下光伏出力总和,  $Y_{ij}$  为该种天气下光伏日出力值。

本文选择甘肃某区的光伏电站出力量化当地天气类型,表 1 列出了该地 4 种典型天气类型的泰尔熵值。

表 1 典型天气类型的量化值  
Table 1 Quantization of typical weathers

天气类型	$T_w$	$T_b$	天气类型	$T_w$	$T_b$
晴	0.6432	0.1311	阵雨	0.6810	0.0980
多云	0.6609	0.1262	多云转晴	0.7316	0.1293

## 2 预测方法

### 2.1 AP 聚类

光伏出力具有间歇性,直接对光伏历史数据进行分析,不仅运算量大,而且无法跟踪其变化特性,因此需要对光伏历史数据进行聚类分析。选择历史波动数据和天气条件作为输入,为使聚类效果更好地反映光伏变化特性,往往需要 1 a 甚至更长时间的历史数据,输入量大。为此本文选择 AP 聚类算法,与其他聚类算法相比,该算法不依赖聚类中心的选择,能更好地处理大规模数据,且运行结果较稳定<sup>[14-15]</sup>。

AP 聚类算法是基于“信息互递”机制的竞争迭代算法,信息交互过程如图 3 所示。该算法定义了 2 个重要传递参数:可信度  $r$  和可用度  $a$ 。其中  $r(i, j)$  反映了  $x_i$  对  $x_j$  作为聚类中心的支持程度,  $a(i, j)$  反映了  $x_j$  作为  $x_i$  的聚类中心的适合程度。对于  $x_j$  而言,  $a$  和  $r$  值越大,成为类代表点的概率就越大。

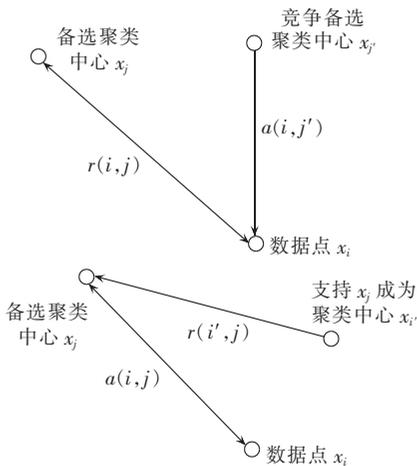


图 3 AP 算法信息传递

Fig.3 Information transfer of AP algorithm

计算步骤如下。

步骤 1 计算样本点间的相似度,获得相似矩阵  $S$ 。

步骤 2 按式(4)计算样本点间的可信度和可用度:

$$\begin{cases} r(i, j) = s(i, j) - \max_{j' \neq j} \{s(i, j') + a(i, j')\} \\ a(i, j) = \min \left\{ 0, r(j, j) + \sum_{i' \in (i, j)} \max \{0, r(i', j)\} \right\} \\ a(j, j) = \sum_{i' \neq j} \max \{0, r(i', j)\} \end{cases} \quad (4)$$

步骤 3 按式(5)更新可信度和可用度值:

$$\begin{cases} r^{t+1}(i, j) = \lambda r^{t-1}(i, j) + (1 - \lambda) r^t(i, j) \\ a^{t+1}(i, j) = \lambda a^{t-1}(i, j) + (1 - \lambda) a^t(i, j) \end{cases} \quad (5)$$

其中,  $\lambda$  为阻尼系数,取值范围一般为  $[0.5, 1]$ ,主要用于调节算法速度及迭代稳定性。研究表明阻尼系数越大,则迭代振荡越小,算法运行越稳定,因此

本文选择  $\lambda$  为 0.9。

步骤 4 重复迭代步骤 2 和 3,当取  $E = r(i, j) + a(i, j)$  最大值时,样本点  $x_j$  将作为本次迭代  $x_i$  选择的候选聚类中心,并将样本  $x_i$  归入  $x_j$  一类。

步骤 5 重复上述迭代过程,至聚类中心保持稳定,或达到一定迭代次数,结果收敛。

### 2.2 ESN

ESN 是一种新型递归神经网络,由输入层、输出层和储备池构成。其基本思想是通过储备池中大规模随机稀疏连接的神经元模拟系统特性,利用其内部状态线性组合出需要的输出量。相较于其他神经网络,隐藏层神经元数据大,具有完全不同的内部连接权值生成方式,在收敛速度和稳定性方面有极大的改进<sup>[16-18]</sup>。储备池状态更新方程为:

$$\mathbf{x}(n+1) = f(\mathbf{w}^{\text{in}} \mathbf{u}(n+1) + \mathbf{w} \mathbf{x}(n) + \mathbf{w}^{\text{back}} \mathbf{y}(n)) \quad (6)$$

其中,  $\mathbf{x}(n)$  为第  $n$  步储备池的状态向量;  $\mathbf{u}(n)$  和  $\mathbf{y}(n)$  分别为第  $n$  步的输入向量和输出向量;  $f$  为储备池节点函数;  $\mathbf{w}$  为储备池内部连接矩阵,通常保持 1%~5% 的稀疏连接,且要求谱半径小于 1 以保证网络稳定性和动态记忆能力;  $\mathbf{w}^{\text{in}}$  为输入矩阵;  $\mathbf{w}^{\text{back}}$  为输出反馈矩阵。

$\mathbf{w}$ 、 $\mathbf{w}^{\text{in}}$  和输出权值矩阵  $\mathbf{w}^{\text{out}}$  在网络建立前随机生成,在整个网络训练过程中保持不变。通过训练获得网络输出  $\mathbf{y}(n+1)$ ,即:

$$\mathbf{y}(n+1) = f^{\text{out}}(\mathbf{w}^{\text{out}} [\mathbf{u}(n+1), \mathbf{x}(n+1), \mathbf{y}(n+1)]) \quad (7)$$

其中,  $f^{\text{out}}$  为网络输出节点函数;  $\mathbf{w}^{\text{out}}$  可通过训练计算获得。

## 3 基于 AP-ESN 算法的光伏预测模型

通过对光伏出力波动性分析,选择历史波动分量、当地温度和天气类型作为分类特征。可将特征分为波动分量和天气数据两部分,即:

$$Q = \{ \{W_t, W_{t+1}, \dots, W_{t+n}\}, \{\Delta T, T_w, T_b\} \} \quad (8)$$

其中,  $W_t$  为光伏出力日波动量,光伏出力在夜间为零,因此选择出力波动幅度较明显的一段时间内的波动量作为特征元素,本文选择 07:00—19:00 时间段内的波动分量作为输入;  $\Delta T$  为日最大温差变化率;  $T_w$  和  $T_b$  为日天气类型的量化值,由各天气类型下光伏日出力的泰尔熵值确定。

统计样本点间输入特征元素的相似度,进行 AP 聚类。将历史光伏出力分成  $n$  类,分别建立 ESN 预测模型,并将竞争迭代后的聚类中心作为该类模型的典型日出力。根据预测日的光伏出力情况和天气条件选择相应模型进行预测。本文以欧氏距离作为选择依据:

$$d_{ij} = \frac{1}{\sqrt{m}} \sqrt{\sum_{k=1}^m (x_{ik} - x_{jk})^2} \quad (9)$$

其中,  $x_{ik}$  为预测日的特征元素;  $x_{jk}$  为各聚类中心点特征元素;  $m$  为  $x$  的维数, 即特征元素的个数。其中预测日的温度变化率和天气类型这 2 个特征元素可从天气预测系统获取, 但波动分量未知。为获取预测日的波动分量, 采用 ESN 算法对预测日的出力进行初步预测, 将预测结果的波动分量作为预测日的波动特征元素。图 4 为光伏出力预测的流程图。

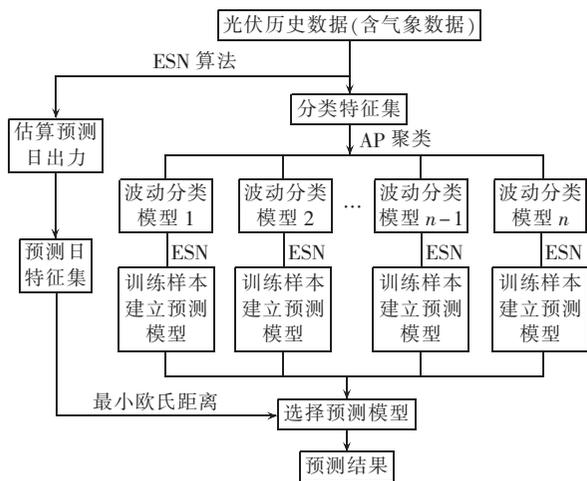


图 4 基于 AP-ESN 组合预测流程

Fig.4 Flowchart of PV output power forecasting based on AP-ESN

## 4 算例分析

本文选择甘肃地区某光伏电站 2013 年的历史数据进行分析, 并预测 2014 年 1 月的光伏出力。为验证本文预测模型的优越性, 采用基于集合经验模态分解和人工神经网络 (EEMD-ANN) 的组合预测算法, 以及基于广义天气类型聚类的预测算法分别对光伏电站出力进行预测, 图 5(a) 和 (b) 分别是在非突变天气和突变天气下的预测结果对比。

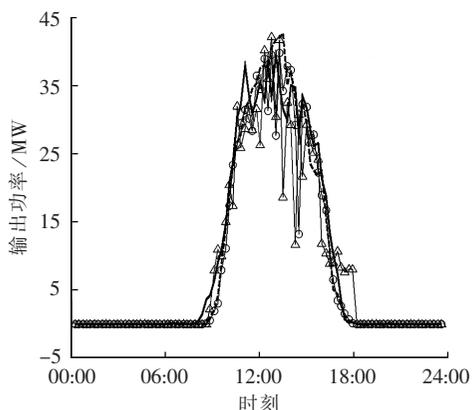
为定量评价预测方法的准确度, 本文选择国际上普遍采用的归一化绝对平均误差  $E_{\text{mae}}$  和归一化均方根误差  $E_{\text{mse}}$  来评价各预测模型的精度, 计算公式如下:

$$E_{\text{mae}} = \frac{1}{P} \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i| \quad (10)$$

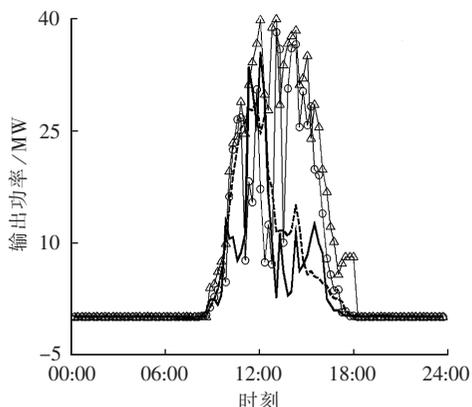
$$E_{\text{mse}} = \frac{1}{P} \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2} \quad (11)$$

其中,  $N$  为测试样本数;  $P$  为光伏电站容量;  $x_i$  为实际出力值;  $\hat{x}_i$  为预测值。

表 2 为 3 种预测模型的预测误差对比。由图 5 和表 2 可知, 3 种模型在无天气突变的情况下, 都能较好地完成预测。这是由于在非突变天气条件下, 光伏日内波动较为平稳, 无急剧变化。但 3 种预测模型在天气发生突变时, 预测效果差异明显。其中基于 EEMD-ANN 的组合预测模型误差最大, 平均误



(a) 非突变天气下预测结果对比图



(b) 突变天气下预测结果对比图

---实际值,  $\triangle$  EEMD-ANN  
 $\circ$  天气聚类, — 本文预测方法

图 5 光伏出力预测结果

Fig.5 Results of PV output power forecasting

表 2 不同模型的预测误差比较

Table 2 Comparison of forecasting errors among different models

预测模型	$E_{\text{mae}}/\%$		$E_{\text{mse}}/\%$	
	非突变天气	突变天气	非突变天气	突变天气
EEMD-ANN	8.54	18.44	13.37	26.22
基于天气聚类预测	4.14	14.45	7.72	7.37
本文模型	5.21	22.49	7.04	11.09

差接近 20%, 这是由于经 EEMD 的出力数据不具有明确物理意义, 而且在预测过程中预测误差叠加, 降低了预测效果; 基于天气聚类的预测模型平均误差降低至 15%, 但只能预测光伏出力的大体趋势, 在光伏出力发生突变时, 预测值不能跟踪其变化; 本文提出的组合预测模型预测误差为 7%, 且误差波动幅度小, 其预测误差和误差波动都降低了一半以上。

本文提出的预测模型不仅能在非突变天气条件下获得高精度的预测效果, 在突变天气条件下也能紧跟波动拐点处的光伏出力变化, 并在出力剧变时做出反应, 相较其他常见预测模型有较高的预测准确度。但部分波动特别剧烈的情况仍会产生一

定误差,这是由于光伏出力的分类模型受历史数据影响,历史数据越完整,波动分类结果将更完善,预测结果将更准确。

## 5 结论

本文研究了光伏预测的相关方法,提出一种基于 AP 聚类和 ESN 的组合预测算法。研究表明该组合预测模型具有一定优越性,主要表现在以下方面。

**a.** 数据处理方面,简化光伏出力分解过程,避免因分离结果数过多导致误差叠加等问题;以泰尔熵值衡量天气类型间的差异度,完善天气类型的量化过程。

**b.** 算法方面,AP-ESN 算法可处理大量数据,且运算速度快,稳定性好。AP 聚类算法避免了传统聚类对聚类中心选择敏感的问题,ESN 作为新型动态递归神经网络较常用的静态神经网络更有效。

总体而言,本文提出的模型数据易获取,算法易实现,在突变天气下也能获得较好的预测效果,且同样适用于风电等其他间歇性能源的功率预测。

## 参考文献:

- [1] RIKOS E, TSELEPIS E, HOYER KLICK C, et al. Stability and power quality issues in microgrids under weather disturbances study of photovoltaic integration[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2008, 1(3): 170-180.
- [2] 李元诚,王蓓,王旭峰. 基于和声搜索-高斯过程混合算法的光伏功率预测[J]. 电力自动化设备, 2014, 34(8): 13-18.  
LI Yuancheng, WANG Bei, WANG Xufeng. Photovoltaic power forecasting based on harmony search and Gaussian process algorithms[J]. Electric Power Automation Equipment, 2014, 34(8): 13-18.
- [3] 王飞,米增强,甄钊,等. 基于天气状态模式识别的光伏电站发电功率分类预测方法[J]. 中国电机工程学报, 2013, 33(34): 75-82.  
WANG Fei, MI Zengqiang, ZHEN Zhao, et al. A classified forecasting approach of power generation for photovoltaic plants based on weather condition pattern recognition[J]. Proceedings of the CSEE, 2013, 33(34): 75-82.
- [4] 袁晓玲,施俊华,徐杰彦. 计及天气类型指数的光伏发电短期出力预测[J]. 中国电机工程学报, 2013, 33(34): 57-64.  
YUAN Xiaoling, SHI Junhua, XU Jieyan. Short-term power forecasting for photovoltaic generation considering weather type index[J]. Proceedings of the CSEE, 2013, 33(34): 57-64.
- [5] 茆美琴. 基于 EEMD-SVM 方法的光伏电站短期出力预测[J]. 中国电机工程学报, 2013, 33(34): 17-24.  
MAO Meiqin. Short-term photovoltaic generation forecasting based on EEMD-SVM combined method[J]. Proceedings of the CSEE, 2013, 33(34): 17-24.
- [6] 杨锡运,刘欢,张彬,等. 组合权重相似日选取方法及光伏输出功率预测[J]. 电力自动化设备, 2014, 34(9): 118-122.  
YANG Xiyun, LIU Huan, ZHANG Bin, et al. Similar day selection based on combined weight and photovoltaic power output forecasting[J]. Electric Power Automation Equipment, 2014, 34(9): 118-122.
- [7] 刘兴杰,岑添云,郑文书,等. 基于模糊粗糙集与改进聚类的神经网络风速预测[J]. 中国电机工程学报, 2014, 34(19): 3162-3169.  
LIU Xingjie, CEN Tianyun, ZHENG Wenshu, et al. Neural network wind speed prediction based on fuzzy rough set and improved clustering[J]. Proceedings of the CSEE, 2014, 34(19): 3162-3169.
- [8] 代倩,段善旭,蔡涛,等. 基于天气类型聚类识别的光伏系统短期无辐照度发电预测模型研究[J]. 中国电机工程学报, 2011, 31(34): 28-35.  
DAI Qian, DUAN Shanxu, CAI Tao, et al. Short-term PV generation system forecasting model without irradiation based on weather type clustering[J]. Proceedings of the CSEE, 2011, 31(34): 28-35.
- [9] 王守相,王亚曼,刘岩,等. 基于经验模态分解和 ELM 神经网络的逐时太阳能辐照量预测[J]. 电力自动化设备, 2014, 34(8): 7-12.  
WANG Shouxiang, WANG Yaman, LIU Yan, et al. Hourly solar radiation forecasting based on EMD and ELM neural network[J]. Electric Power Automation Equipment, 2014, 34(8): 7-12.
- [10] KIRBY B, HIRST E. Generator response to intrahour load fluctuations[J]. IEEE Transactions on Power Systems, 1998, 13(4): 1373-1378.
- [11] HIRST E, KIRBY B. Defining intra-and inter-hour load swings[J]. IEEE Transactions on Power Systems, 1998, 13(4): 1379-1385.
- [12] HIRST E, KIRBY B. Separating and measuring the regulation and load-following ancillary services[J]. Utilities Policy, 1999, 8(2): 75-81.
- [13] 康晓娟,杨冬民. 基于泰尔指数法的中国能源消费区域差异分析[J]. 资源科学, 2010, 32(3): 485-490.  
KANG Xiaojuan, YANG Dongmin. An analysis on the difference of regional energy consumption in China based on the method of the Theil index[J]. Resources Science, 2010, 32(3): 485-490.
- [14] FREY B J, DUECK D. Clustering by passing messages between data points[J]. University of Toronto, Science, 2007, 315: 972-976.
- [15] GIVONI I E, FREY B J. A binary variable model for affinity propagation[J]. Neural Computation, 2009, 21(6): 1589-1600.
- [16] 张学清,梁军. 基于 EEMD-近似熵和储备池的风电功率混沌时间序列预测模型[J]. 物理学报, 2013, 62(5): 1-6.  
ZHANG Xueqing, LIANG Jun. Chaotic time series prediction model of wind power based on ensemble empirical mode decomposition-approximate entropy and reservoir[J]. Acta Physica Sinica, 2013, 62(5): 1-6.
- [17] SONG Ruizhuo, XIAO Wendong, SUN Changyin. A new self-learning optimal control laws for a class of discrete-time nonlinear systems based on ESN architecture[J]. Science China (Information Sciences), 2014, 57(068202): 1-10.

- [18] CUI Hongyan, FENG Chen, LIU Yunjie. Analysis of prediction performance in wavelet minimum complexity echostate network [J]. The Journal of China Universities of Posts and Telecommunications, 2013, 20(4):59-66.

作者简介:

李 乐(1990—),女,四川乐山人,硕士研究生,研究方向



李 乐

为微电网通信技术、风电功率预测(E-mail: sculile@163.com);

刘天琪(1962—),女,四川成都人,教授,博士研究生导师,博士,主要研究方向为电力系统分析计算与稳定控制、调度自动化、高压直流输电智能网(E-mail: tqliu@sohu.com)。

## PV power forecasting based on AP-ESN

LI Le, LIU Tianqi

(School of Electrical Engineering and Information, Sichuan University, Chengdu 610065, China)

**Abstract:** The influence of weather on the PV(PhotoVoltaic) output power is analyzed. The weather information by the mature forecasting technologies and the PV fluctuant components reflecting the variation tendency of PV output power are selected as the classification properties. As the accuracy of traditional forecasting algorithm is low when weather changes suddenly, an algorithm based on AP(Affinity Propagation) and ESN(Echo State Network) is proposed, which applies AP to classify PV output power and sets the ESN according to its class of the day concerned for forecasting its PV output power. Simulation shows that, with higher accuracy and universality, the proposed algorithm meets the requirements of PV output power forecasting for normal weathers and traces quite well the variation of PV output power for abnormal weathers.

**Key words:** PV power generation; forecasting; fluctuant components; affinity propagation; echo state network; clustering algorithms

(上接第 33 页 continued from page 33)

fast control scheme for a PWM rectifier-inverter system[J]. IEEE Transactions on Industry Applications, 2014, 50(1):462-473.

作者简介:

王 冕(1990—),男,贵州印江人,博士研究生,主要研究方向为新能源并网发电中的电力电子技术(E-mail: wzcj@zju.edu.cn);



王 冕

陈国柱(1967—),男,湖北鄂州人,教授,博士研究生导师,研究方向为电能质量控制技术、新能源并网发电技术、电力电子在电力系统中的应用技术等。

## DC energy balance scheme for back-to-back PWM converters of wind power system

WANG Mian, CHEN Guozhu

(College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China)

**Abstract:** Wind energy fluctuation and grid voltage fluctuation are main factors causing the DC-side power fluctuation of PMSG(Permanent Magnetic Synchronous Generator) wind power system based on the back-to-back PWM converters, which are analyzed in terms of energy balance. Based on the small signal model, a control scheme of output current compensation for the grid-side converter is proposed according to the power balance relationship. Simulative and experimental results validate that, the proposed scheme not only stabilizes the DC-side voltage during wind energy fluctuation, but also makes full use of the converter capacitor during grid voltage fault to achieve the fault ride through of wind power system and reduce the capacity of DC-side capacitor.

**Key words:** wind power; PMSG; back-to-back PWM converter; DC-bus voltage stabilization; electric current control; compensation; fault ride through