

DOI:10.12158/j.2096-3203.2020.02.005

# 计及出力波动的光伏电站无功支撑能力评估

王强<sup>1</sup>, 顾乔根<sup>2,3</sup>, 孙仲民<sup>2,3</sup>, 耿少博<sup>1</sup>, 任江波<sup>1</sup>

(1. 国网河北省电力有限公司, 河北 石家庄 050021; 2. 南京南瑞继保电气有限公司, 江苏 南京 211102; 3. 南瑞集团(国网电力科学研究院)有限公司, 江苏 南京 211106)

**摘要:**在满足配电网稳定运行的前提下,充分利用光伏电站并网逆变器的额定容量,挖掘光伏的无功支撑能力,能够促使配电网经济运行,因此开展光伏电站无功支撑能力评估具有重要的现实意义。首先,提出了基于动态时间弯曲算法的无功支撑能力评估方法和评估指标体系,实现实时态的无功支撑能力评估;然后,提出了基于深度置信网络模型的光伏出力预测方法和预测指标体系,结合预测数据实现未来态的无功支撑能力预测。算例分析表明,预测的光伏电站未来态无功支撑能力与实际未来态评估结果相吻合,验证了所提评估、预测方法的有效性。

**关键词:**光伏电站;无功支撑能力;动态时间弯曲算法;深度置信网络

**中图分类号:** TM732

**文献标志码:** A

**文章编号:** 2096-3203(2020)02-0029-06

## 0 引言

光伏电站的大量建设减轻了化石能源带给环境的巨大压力并带动了地方经济的快速发展,然而,光伏出力的随机性和波动性带来的有功功率不确定性、电压波动等问题,给智能配电网(smart distribution network, SDN)的运行管理带来巨大挑战<sup>[1]</sup>。态势感知<sup>[2-3]</sup>通过对海量数据的挖掘与处理实现运行状态的评估和预测,评价系统的运行状态并预测分析未来发展趋势。受到态势感知技术的启发,开展光伏电站无功支撑能力的实时态和未来态评估,对于配电网的稳定运行具有重要的现实依据。

国内外专家学者对于配电网运行状态评估和光伏出力预测进行了相关研究。文献[4]综合分析了宏观需求指标集和微观评估指标集,提出了基于决策实验室分析(decision-making trial and evaluation laboratory, DEMATEL)-网络分析法-反熵权法和改进灰色关联度法的组合权重分层优选模型,从而感知电网的运行状态和薄弱环节。文献[5]分析了光伏逆变器无功输出特性和各种无功控制策略的无功支撑能力,通过仿真结果评价不同无功控制策略的配电网无功支撑能力,并根据评价结果提出无功控制改进意见。文献[6]分析了云量模糊性和云遮系数的双重随机性,以无云天气计算太阳辐射值的REST模型为基础,建立了基于不确定理论的太阳辐射值预测模型,所述方法可以得到光伏出力在不同云量下的预测期望值和满足不同置信水平的预

测区间。文献[7]提出了一种多链马尔科夫-蒙特卡洛方法对多个光伏电站出力序列进行组合预测,该方法建立了多条相互服从完全条件分布的马尔科夫链,以模拟光伏电站上空随机变化的大气状态,该方法能够体现多个光伏电站出力之间相互影响的特点。上述文献分别对配电网运行状态评估和光伏出力预测展开相应研究,但并未结合预测数据对电网未来运行状态、发展趋势进行深入分析。

文中通过真实电网数据开展应用实践,将评估及预测技术全面融入电网的运行状态分析中,针对光伏电站无功支撑能力实时态和未来态评估展开研究。首先,提出了基于动态时间弯曲(dynamic time warping, DTW)的无功支撑能力评估模型和对应的指标体系,实现实时态的无功支撑能力评估;然后,提出了基于深度置信网络(deep belief network, DBN)的光伏出力预测模型和对应指标体系,实现未来态的无功支撑能力评估;最后,结合实际电网分析所述方法的有效性。

## 1 无功支撑能力评估方法

### 1.1 基于DTW的评估模型

为了深入理解数据与光伏电站无功支撑能力之间的关系,提出基于DTW算法<sup>[8]</sup>的光伏电站无功支撑能力评估方法。通过比较标准样本序列和参考、待评估样本序列的最小失真弯曲距离衡量待评估样本序列的光伏无功支撑能力。

DTW算法在模式识别、关联度分析等领域得到了广泛的应用,其将相似度问题转化为比较2个样本序列的最小弯曲失真距离。DTW算法步骤如下:

(1) 首先计算2个样本序列对应元素的欧式空

收稿日期:2019-09-15;修回日期:2019-10-20

基金项目:国家重点研发计划资助项目(2017YFB0902605)

间距离,并按照既定原则进行排列,得到欧式距离矩阵如式(1)所示。其中  $\mathbf{X}, \mathbf{Y}$  为 2 个样本序列;  $m, n$  为样本序列中的样本个数。

$$\mathbf{A} = \begin{bmatrix} |x_1 - y_1| & |x_1 - y_2| & \cdots & |x_1 - y_n| \\ |x_2 - y_1| & |x_2 - y_2| & \cdots & |x_2 - y_n| \\ \vdots & \vdots & & \vdots \\ |x_m - y_1| & |x_m - y_2| & \cdots & |x_m - y_n| \end{bmatrix} \quad (1)$$

(2) 通过式(2)的递推原则即可得到样本  $\mathbf{X}$  和  $\mathbf{Y}$  的最小失真弯曲距离  $D(m, n)$ 。

$$\begin{cases} D(i, 0) = D(0, j) = D(0, 0) = \infty \\ M = \min\{D(i-1, j-1), D(i, j-1), D(i-1, j)\} \\ D(i, j) = |x_i - y_j| + M \end{cases} \quad (2)$$

式中:  $1 \leq i \leq m; 1 \leq j \leq n$ 。

通过上述算法即可得到标准样本与参考、待评估样本的最小失真弯曲距离,通过距离大小即可评估样本序列的近似度。最小失真弯曲距离越小,2 个样本序列之间的近似度越高。最后以参考样本的最小失真弯曲距离为基准,建立分段评分函数,量化无功支撑能力评估结果。

## 1.2 无功支撑能力评估指标体系

根据光伏电站的功率输出特性和并网逆变器控制机理可知,影响光伏电站无功支撑能力的主要因素包括光伏电站的有功出力、并网点功率因数和并网点的电压偏移等。建立配电网光伏电站无功支撑能力的评估指标体系  $S$ 。

### 1.2.1 光伏逆变器剩余效率指标

光伏电站大多采用最大功率点跟踪控制策略,即最大限度发出有功功率,此时制约光伏电站无功出力的关键因素是并网逆变器的额定容量。光伏逆变器剩余效率  $s_1$  如下:

$$s_1 = 1 - \frac{S_{PV}}{S_N} = 1 - \frac{\sqrt{P_{PV}^2 + Q_{PV}^2}}{S_N} \quad (3)$$

式中:  $P_{PV}, Q_{PV}$  分别为光伏电站的有功和无功输出;  $S_{PV}$  为光伏电站输出的视在功率;  $S_N$  为并网逆变器的额定容量。

### 1.2.2 并网点功率因数指标

光伏电站的无功支撑能力受限于关口功率因数。接入 10 kV 电压等级的光伏电站,通过变流器并网时在满足并网电压需求的同时应满足功率因数不低于 0.95<sup>[9]</sup>。并网点功率因数指标  $s_2$  如下:

$$s_2 = 1 - \frac{\sin\varphi}{\sin\varphi_{\text{gate}}} = 1 - \frac{Q_{PV}}{S_{PV}\sin\varphi_{\text{gate}}} \quad (4)$$

式中:  $\varphi_{\text{gate}}$  为功率因数角阈值。

### 1.2.3 光伏电站并网方式指标

光伏电站的接入方式、接入点个数和接入电压等级都对光伏电站的无功支撑产生影响。对于统购统销型(T型)和自发自用、余量上网型(Z型)光伏无功支撑能力具有显著差异;对于多接入点并网的光伏,其单点无功支撑能力较弱;接入电压等级的不同虽不会影响无功支撑能力,但电压等级越高,无功功率的电压影响能力越小。光伏电站并网方式指标  $s_3$  如下:

$$s_3 = \xi_1 \frac{L}{L + \Delta L} + \xi_2 \frac{1}{k} + \xi_3 \frac{U_s}{U_m} \quad (5)$$

式中:  $L$  为光伏电站内部负荷量;  $\Delta L$  为内部负荷的增加量;  $k$  为接入点个数;  $U_m, U_s$  分别为接入电压的测量值和标准值;  $\xi_1 + \xi_2 + \xi_3 = 1$ 。

### 1.2.4 并网点电压偏移指标

并网点电压需满足  $0.85U_N \sim 1.1U_N$  ( $U_N$  为分布式光伏并网点额定电压)方可正常连续运行,电压偏移反映了光伏电站对于公共连接点(point of common coupling, PCC)的电压调节能力。鉴于节点电压难以直接预测,通过式(6)可以计算 PCC 电压  $U_{PCC}$ ,并网点电压偏移指标  $s_4$  如式(7)所示。

$$U_{PCC} \approx U_s + \frac{R(P_{PV} - P_L)}{U_{PCC}} + \frac{X(Q_{PV} + Q_C - Q_L)}{U_{PCC}} \quad (6)$$

$$s_4 = \frac{1}{e^{3|U_s - U_{PCC}|}} \quad (7)$$

式中:  $U_s$  为中压配电网母线电压标幺值(并网时假设保持恒定);  $Q_C$  为就地无功补偿装置的无功输出量;  $R, X$  分别为线路的电阻、电抗。

## 2 光伏出力预测方法

### 2.1 基于 DBN 的预测模型

深度学习在模式识别、数据分类、数据预测领域得到广泛应用<sup>[10-11]</sup>。深度学习中的 DBN 能够利用大量历史数据自适应的学习数据的特征规律,使得模型与数据自身结构相适应。

DBN 由受限玻尔兹曼机(restricted Boltzmann machine, RBM)堆叠而成,通过最后的 BP 神经网络层确定算法用途,图 1 展示了 DBN 模型的结构。DBN 的训练过程可分为 2 个阶段,无监督的预训练过程即信号的正向传播,有监督的微调即误差信号的反向传递<sup>[12]</sup>。

RBM 由  $m$  个可视单元的可视层  $v$  和  $n$  个隐藏单元的隐藏层  $h$  组成。  $a$  和  $b$  分别为可见层单元和

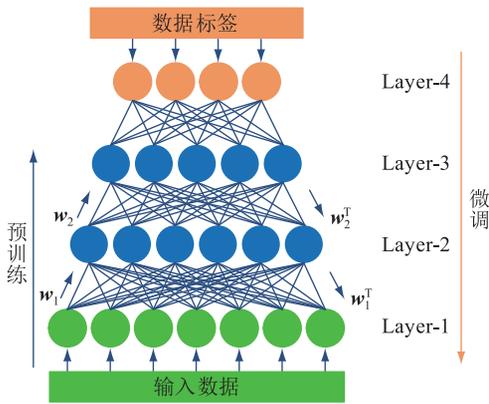


图1 DBN 结构

Fig.1 The structure of DBN

隐藏层单元的偏置值,  $w$  为可见层与隐藏层的连接权重。参数  $a, b, w$  通过对比散度算法 (contrastive divergence, CD) 训练得到<sup>[13]</sup>, 并选取 sigmoid 函数作为激活方式。

对于给定的可视层  $v$ , 隐藏层单元  $h_j$  被激活的概率如式(8)所示, 对于给定的隐藏层  $h$ , 可视层单元  $v_i$  被激活的概率如式(9)所示。

$$P(h_j | v) = \sigma \left( b_j + \sum_i v_i w_{ij} \right) \quad (8)$$

$$P(v_i | h) = \sigma \left( a_i + \sum_j h_j w_{ji} \right) \quad (9)$$

式中:  $1 \leq i \leq m; 1 \leq j \leq n$ 。

为了提高 RBM 的训练效率, 采用 Gaussian 型 CD 算法对各层 RBM 进行训练<sup>[14]</sup>。可视层  $v^0$  通过式(8)可得隐藏层  $h^0$ ,  $h^0$  通过式(9)可得可见层  $v^1$ ,  $v^1$  再通过式(8)可得到  $h^1$ , 通过上述步骤即可完成重构, 且一步吉布斯采样能够满足精度要求。  $\eta$  为学习效率, 参数的更新方式如下:

$$\begin{cases} w_{ij} \leftarrow w_{ij} + \eta(v^0 h^0 - v^1 h^1) \\ a_i \leftarrow a_i + \eta(v_i^0 - v_i^1) \\ b_j \leftarrow b_j + \eta(h_j^0 - h_j^1) \end{cases} \quad (10)$$

通过预训练过程, 取值参数空间得到了有效的压缩, 下一步通过 BP 算法即可对压缩的参数空间进行寻优计算, 完成误差的反向传播。

光伏出力预测即选取气象数据作为输入数据, 6:00—18:00 的 13 个整点时刻有功功率作为数据标签, 通过预训练和微调 2 个步骤, 得到 DBN 预测模型中的参数, 即可预测光伏电站的有功出力。

## 2.2 光伏出力预测指标体系

光伏电站出力受到地理、气象等诸多非确定性因素的影响, 从而导致了光伏出力的随机性<sup>[15-16]</sup>。文中使用直接预测法进行光伏电站的出力预测, 形成光伏电站出力预测指标体系  $T$ 。

### 2.2.1 地表温度

文献[17]表明光伏电站出力与辐照强度、电池工作绝对温度密切相关。地表温度间接反映了太阳辐射经过大气层和空气雾霾的削弱最终到达太阳能电池板的净辐照, 同时也能一定程度表征电池的工作温度。形成地表温度指标  $t_1$  如下:

$$t_1 = \frac{T_{g,j} - T_{g,\min}}{T_{g,\max} - T_{g,\min}} \quad (11)$$

式中:  $T_{g,j}$  为第  $j$  小时地表温度;  $T_{g,\max}$ ,  $T_{g,\min}$  分别为地区的最高、最低地表温度。

### 2.2.2 总云量

地面净辐射与云量大小、云层厚度以及云与地面的二次折射均有不同层次的影响, 云可以分类为低云族、中云族、高云族, 不同高度的云对于太阳辐照的折射与反射表现出巨大差异。云量分布采用标记法, 取值为 0~10。形成总云量指标  $t_2$  如下:

$$t_2 = \frac{\alpha_l C_l + \alpha_m C_m + \alpha_h C_h}{10(\alpha_l + \alpha_m + \alpha_h)} \quad (12)$$

式中:  $\alpha_l, \alpha_m, \alpha_h$  分别为低云族、中云族、高云族对于太阳辐照的透过率;  $C_l, C_m, C_h$  分别为每小时低云族、中云族、高云族的云量分布。

根据第 1 节的评估方法和光伏出力预测数据, 即可实现未来态光伏电站无功支撑能力的评估。

## 3 实例验证

以我国东部沿海某地区含光伏电站的配电网为例, 采集其 1 a 的电网内部数据和天气预报、气象观测数据。其中并网逆变器额定容量为 10 MV·A, 光伏逆变器功率因数阈值 0.95, 无功补偿装置容量为 2 Mvar。选取数据集中 6 月 9 日的电网数据及气象数据开展光伏电站未来态的无功支撑能力评估。

### 3.1 数据处理

#### 3.1.1 预测数据处理

光伏出力是无功支撑能力评估的关键影响因素, 对于配电网光伏电站未来态无功支撑能力评估而言, 评估影响因素包括光伏电站出力和负荷。文中主要考虑光伏电站的无功支撑能力, 且电网对于负荷的预测已然十分成熟, 选取真实负荷数据进行评估与预测分析。

针对光伏电站的出力预测问题, 根据模型的复杂程度, 建立包含 4 层 RBM 和 1 层 BP 网络的深度神经网络模型。模型的输入样本即光伏电站出力预测指标体系  $T$ , 输入层单元数共计 26 个; 隐藏层单元数依次为 48-48-24-24; 考虑到光伏电站的功率输出特性, 数据标签即对应当天 6:00—18:00 的 13

个整点时刻有功功率输出值,即输出层单元数为13。通过对已有气象数据的训练,得到 DBN 预测模型,再通过气象站的气象数据得到光伏出力预测指标数据,即可预测光伏电站的有功出力。温度和云量数据通过 2.2 节归一化处理,得到光伏电站 6 月 9 日的温度和云量如图 2 所示。通过上述处理,形成配电网 6 月 9 日评估数据如图 3 所示。

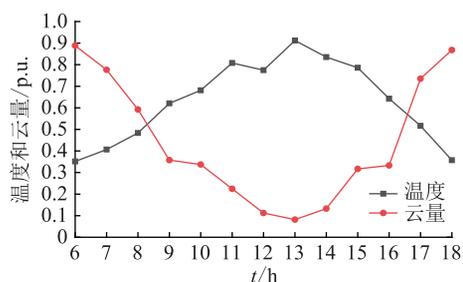


图 2 温度和云量曲线

Fig.2 The temperature and cloudage curves

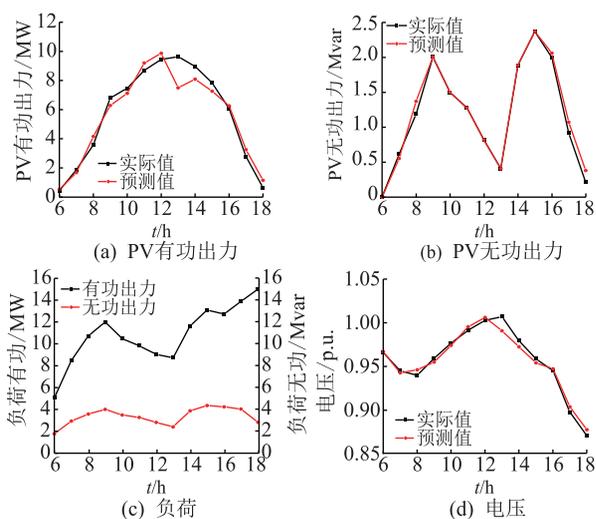


图 3 配电网 6 月 9 日评估数据

Fig.3 Evaluation data of distribution network on June 9

### 3.1.2 评估数据处理

基于 DTW 的无功支撑能力评估即评价标准样本与待评估样本之间的相似程度。首先使用指数层次分析法构建评估比较矩阵  $B_c$  如式 (13) 所示,其中  $k$  为重要性比率,  $k = \sqrt[3]{4}$ 。鉴于指数标度的一致性原则,无需一致性校验,通过指标归一化处理,即可确定评估指标体系中样本的权重向量,见式 (14)。

$$B_c = \begin{bmatrix} k^0 & k^{-2} & k^{-1} & k^{-3} \\ k^2 & k^0 & k^1 & k^{-1} \\ k^1 & k^{-1} & k^0 & k^{-2} \\ k^3 & k^1 & k^2 & k^0 \end{bmatrix} \quad (13)$$

$$W = [0.109\ 8 \quad 0.276\ 7 \quad 0.174\ 3 \quad 0.439\ 2] \quad (14)$$

为了量化分析光伏电站无功支撑的能力,需针对指标序列选取能够划分无功支撑能力的参考样本序列,并作为量化评估结果的基准。选取参考样本如表 1 所示。

表 1 参考样本及范围

Table 1 The range of reference samples

指标	参考样本 I	参考样本 II	参考样本 III
$s_1$	0.9	0.4	0.1
$s_2$	0.8	0.5	0.1
$s_3$	0.8	0.6	0.4
$s_4$	0.9	0.8	0.7

通过参考样本与标准样本计算最小失真弯曲距离,匹配对应百分制的评价分数,并作为评分函数的基准点,构建分段评分函数如式 (15) 所示,  $S$  为评估结果得分,  $x$  为最小失真弯曲距离。由公式可知,评估得分越高,无功支撑能力越强。

$$S = \begin{cases} \frac{10}{e^{4.7(x-0.1451)}} + 80 & 0 \leq x < 0.1451 \\ \frac{10}{0.2167}(0.1451 - x) + 90 & 0.1451 \leq x < 0.3618 \\ \frac{20}{0.1549}(0.3618 - x) + 80 & 0.3618 \leq x < 0.5167 \\ \frac{80}{e^{2.8(x-0.5167)}} - 20 & 0.5167 \leq x \leq 1 \end{cases} \quad (15)$$

根据式 (3) 一式 (7) 计算配电网 6 月 9 日实际、预测的未来态评估指标,再通过式 (1) 和式 (2) 计算样本序列的最小失真弯曲距离,并通过评分函数计算每个时刻的评估得分。

### 3.2 评估结果分析

配电网 6 月 9 日的实际无功支撑能力评估结果和预测的无功支撑能力评估结果如图 4 所示。通过曲线可知,预测评估结果的误差较小,仅在 9:00 和 15:00 误差较大,但绝对误差百分比均在 5% 以内,预测评估结果能够较准确的反映光伏电站的无功支撑能力。

为了验证建立的配电网光伏电站无功支撑能力评估方法和光伏出力预测方法的有效性,选取均方根误差、平均绝对误差量化分析实际和预测的评估结果。

均方根误差表现了预测评估结果与实际评估结果的离散程度。均方根误差  $R_{MSE}$  如下:

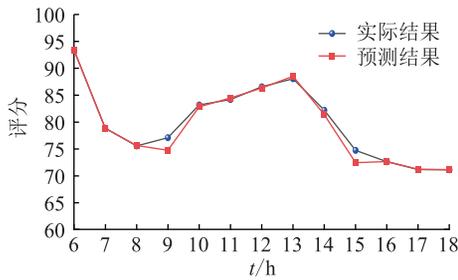


图4 配电网无功支撑能力评估结果

Fig.4 Evaluation results of reactive power support

$$R_{MSE} = \sqrt{\frac{1}{13} \sum_{i=1}^{13} (S_{\text{predict},i} - S_{\text{reality},i})^2} \quad (16)$$

式中: $S_{\text{predict},i}$ ,  $S_{\text{reality},i}$  分别为第  $i$  小时的预测评估评分和真实评估评分。

平均绝对误差反映了误差对于整体评估结果的影响程度。平均绝对误差指标  $M_{MAPE}$  如下:

$$M_{MAPE} = \frac{1}{13} \sum_{i=1}^{13} \left| \frac{S_{\text{predict},i} - S_{\text{reality},i}}{S_{\text{reality},i}} \right| \times 100\% \quad (17)$$

均方根误差为 0.958 0, 表明了预测评估曲线与实际评估曲线的离散化程度较小。平均绝对误差为 0.692 3, 表明误差对于整体评估结果的影响程度较小。对于本案例 6 月 9 日含光伏电站的配电网而言, 6:00 和 13:00 无功支撑能力均较高, 但两者原因却迥然不同, 6:00 是由于无功负荷较少, 13:00 是由于光伏电站的无功功率输出高且无功负荷较同时段较少; 由于 7:00, 8:00, 15:00, 16:00, 17:00, 18:00 光伏有功输出较少, 受限于功率因数阈值, 无功支撑能力均较低; 其余时刻光伏无功输出与无功负荷变化情况较一致, 无剧烈波动, 无功支撑能力评估结果在 80~85 分之间波动。

## 4 结论

文中提出基于 DTW 算法的光伏电站无功支撑能力评估方法, 分析了配电网光伏电站无功支撑能力的影响因素; 提出了基于深度置信网络的光伏出力预测方法, 预测未来 13 h 的光伏电站功率输出情况, 为预测未来态的无功支撑能力提供预测数据。通过算例分析, 验证了所提出评估和预测方法的有效性。主要结论如下:

(1) 根据所提出的评估与预测方法, 可以感知配电网未来态的无功缺额, 预先评价光伏电站的无功支撑能力;

(2) 评估结果能够指导配电网的调度计划、促使光伏出力对电网产生积极有利的影响, 提前对可能发生的无功电压问题采取相应措施。

所述评估及预测方法的成熟应用对于解决配

电网长期存在的无功电压问题具有跨阶段意义。

本文得到国网河北省电力有限公司科技项目 (5204BB170008) 资助, 谨此致谢!

## 参考文献:

- [1] 赵伟然, 汪海蛟, 李光辉, 等. 分布式光伏并网电压和功率因数协调控制策略[J]. 电力工程技术, 2017, 36(6): 26-32.  
ZHAO Weiran, WANG Haijiao, LI Guanghui, et al. Voltage and power factor coordination control for distributed photovoltaic integration[J]. Electric Power Engineering Technology, 2017, 36(6): 26-32.
- [2] 王守相, 梁栋, 葛磊蛟. 智能配电网态势感知和态势利导关键技术[J]. 电力系统自动化, 2016, 40(12): 2-8.  
WANG Shouxiang, LIANG Dong, GE Leijiao. Key technologies of situation awareness and orientation for smart distribution systems[J]. Automation of Electric Power Systems, 2016, 40(12): 2-8.
- [3] 章坚民, 陈昊, 陈建, 等. 智能电网态势图建模及态势感知可视化的概念设计[J]. 电力系统自动化, 2014, 38(9): 168-176.  
ZHANG Jianming, CHEN Hao, CHEN Jian, et al. Smart grid situation awareness diagram modeling and conceptual design of situation awareness visualization [J]. Automation of Electric Power Systems, 2014, 38(9): 168-176.
- [4] 张心洁, 葛少云, 刘洪, 等. 智能配电网综合评估体系与方法[J]. 电网技术, 2014, 38(1): 40-46.  
ZHANG Xinjie, GE Shaoyun, LIU Hong, et al. Comprehensive assessment system and method of smart distribution grid [J]. Power System Technology, 2014, 38(1): 40-46.
- [5] 司传涛, 肖静, 张阁, 等. 光伏发电系统无功支撑能力评估分析[J]. 广西电力, 2015, 38(6): 28-34.  
SI Chuantao, XIAO Jing, ZHANG Ge, et al. Evaluation and analysis of reactive power support capability of photovoltaic generation system[J]. Guangxi Electric Power, 2015, 38(6): 28-34.
- [6] 赵书强, 王明雨, 胡永强, 等. 基于不确定理论的光伏出力预测研究[J]. 电工技术学报, 2015, 30(16): 213-220.  
ZHAO Shuqiang, WANG Mingyu, HU Yongqiang, et al. Research on the prediction of PV output based on uncertainty theory [J]. Transactions of China Electrotechnical Society, 2015, 30(16): 213-220.
- [7] 樊安洁, 高山, 方济城, 等. 基于多链 MCMC 方法的光伏出力序列预测研究[J]. 电力工程技术, 2018, 37(6): 55-61.  
FAN Anjie, GAO Shan, FANG Jichen, et al. A PV power time series generating method considering correlation characteristics based on multi Markov chain Monte Carlo method[J]. Electric Power Engineering Technology, 2018, 37(6): 55-61.
- [8] 黄纯, 刘鹏辉, 江亚群, 等. 基于动态时间弯曲距离的主动配电网馈线差动保护[J]. 电工技术学报, 2017, 32(6): 240-247.  
HUANG Chun, LIU Penghui, JIANG Yaqun, et al. Feeder differential protection based on dynamic time warping distance in

- active distribution network [J]. Transactions of China Electrotechnical Society, 2017, 32(6): 240-247.
- [9] 包立公, 张瑞祥. 神经网络技术在电力系统中的应用 [J]. 电力工程技术, 2010, 29(5): 52-55.  
BAO Ligong, ZHANG Ruixiang. Application of artificial neural network in electric power system [J]. Electric Power Engineering Technology, 2010, 29(5): 52-55.
- [10] BAI Y, CHENZ Q, XIE J J, et al. Daily reservoir inflow forecasting using multiscale deep feature learning with hybrid models [J]. Journal of Hydrology, 2016, 532: 193-206.
- [11] OHZEKI, MASAYUKI. Statistical-mechanical analysis of pre-training and fine tuning in deep learning [J]. Journal of the Physical Society of Japan, 2015, 84(3): 034003.
- [12] SALAKHUTDINOV R, HINTON G. An efficient learning procedure for deep Boltzmann machines [J]. Neural Computation, 2012, 24(8): 1967-2006.
- [13] RYO K, MASATO O, SHUN-ICHI A. Dynamical analysis of contrastive divergence learning; restricted Boltzmann machines with Gaussian visible units [J]. Neural Networks, 2016, 79 (C): 78-87.
- [14] 中华人民共和国国家标准. 分布式电源并网运行控制规范: GB/T 33592—2017 [S].  
National standards of the PRC. Specification of operation and controlling for distributed resources connected to power grid: GB/T 33592—2017 [S].
- [15] SHI J, LEE W J, LIU Y Q, et al. Forecasting power output of photovoltaic system based on weather classification and support vector machine [C] // IEEE Industry Applications Society Meeting, 2011: 1-6.
- [16] 易桂平, 胡仁杰. 太阳能光伏电池建模与动态特性仿真 [J]. 电力工程技术, 2014, 33(5): 32-35.  
YI Guiping, HU Renjie. Solar photovoltaic battery modeling and dynamic characteristics simulation [J]. Electric Power Engineering Technology, 2014, 33(5): 32-35.
- [17] 王成山. 微电网分析与仿真实论 [M]. 北京: 科学出版社, 2013.  
WANG Chengshan. Analysis and simulation theory of micro-grids [M]. Beijing: Science Press, 2013.

作者简介:



王强

王强 (1972), 男, 学士, 教授级高级工程师, 从事电力系统自动化工作 (E-mail: wqiang1972@126.com);

顾乔根 (1986), 男, 硕士, 工程师, 从事电力系统继电保护工作;

孙仲民 (1989), 男, 博士, 工程师, 从事电力系统分析工作。

### The evaluation of reactive power support capacity of photovoltaic power station considering output fluctuation

WANG Qiang<sup>1</sup>, GU Qiaogen<sup>2,3</sup>, SUN Zhongming<sup>2,3</sup>, GEN Shaobo<sup>1</sup>, REN Jiangbo<sup>1</sup>

(1. State Grid Hebei Electric Power Co., Ltd., Shijiazhuang 050021, China;

2. NR Electric Co., Ltd., Nanjing 211102, China;

3. NARI Group (State Grid Electric Power Research Institute) Co., Ltd., Nanjing 211106, China)

**Abstract:** Under the premise of satisfying steady operation of distribution network, fully utilizing the rated capacity of the grid-connected inverter, and excavating the reactive power support of photovoltaic power station, which can promote economic operation of distribution network. Thus, it is of great practical significance to research the evaluation method of reactive power support for photovoltaic power station. Firstly, the evaluation method based on dynamic time warping (DTW) algorithm and the evaluation index system is proposed, so as to realize reactive power support evaluation in the real time. Then the prediction method of photovoltaic output based on deep belief network (DBN) and the predictive index system is proposed, combined with predicted data to realize reactive power support evaluation in the future state. Numerical examples show that the predicted evaluation result is highly consistent with the actual evaluation result, which verifies the effectiveness of the established evaluation and prediction method.

**Keywords:** photovoltaic power station; reactive power support; dynamic time warping algorithm; deep belief network

(编辑 陈静)