

doi:10.11835/j.issn.1000-582X.2017.04.007

基于无迹卡尔曼滤波神经网络的光伏发电预测

李春来¹,张海宁¹,杨立滨¹,杨军¹,王平²

(1.国网青海省电力公司电力科学研究院(青海省光伏发电并网技术重点实验室),西宁 810008;

2.重庆大学输配电装备及系统安全与新技术国家重点实验室,重庆 400044)

摘要:针对光伏发电系统在不同天气状况下发电功率预测精度不高的问题,在分析传统方法的基础上,提出一种无迹卡尔曼滤波神经网络光伏发电预测方法。该方法利用无迹卡尔曼滤波实时更新神经网络模型的权重,以直流电压和电流作为系统的输入,以有功功率和无功功率作为系统的输出,分别建立两个独立的双输入单输出功率预测模型。实验结果表明:所提出的方法对有功功率和无功功率的预测精度分别为97.3%和94.2%,并且对天气具有良好的鲁棒性。

关键词:光伏发电预测;无迹卡尔曼滤波;神经网络;最佳拟合度

中图分类号:TM615

文献标志码:A

文章编号:1000-582X(2017)04-054-08

Photovoltaic power forecasting based on unscented Kalman filtering neural network

LI Chunlai¹, ZHANG Haining¹, YANG Libin¹, YANG Jun¹, WANG Ping²

(1. Qinghai Electric Power Research Institute(Qinghai Province Key Laboratory of Photovoltaic Grid Connected Power Generation Technology), Xining 810008, P.R.China; 2. State Key Laboratory of Power Transmission Equipment & System Security, Chongqing University, Chongqing 400044, P.R.China)

Abstract: As the existing photovoltaic power prediction methods have low robustness under different weather conditions, we proposed a new method for the prediction of photovoltaic power system based on the unscented Kalman filtering (UKF) neural network. The method uses the unscented Kalman filter to update the weight of the neural network model in real time, and establishes two independent dual-input-single-output models with taking DC voltage and current as input and active power and reactive power as output. The experimental results indicate that the proposed UKF neural network model can accurately forecast the photovoltaic power, the best fit of active and reactive power are 97.3% and 94.2% respectively, and the method is robust to weather conditions.

Keywords: photovoltaic power forecasting; unscented Kalman filter; neural network; optimal degree of fitting

收稿日期:2016-11-01

基金项目:青海省光伏发电并网技术重点实验室项目(2014-Z-Y34A)。

Supported by Project of Key Laboratory of Grid-Connected Photovoltaic Technology of Electric Power Research Institute of Qinghai Power Grid Corporation(2014-Z-Y34A).

作者简介:李春来(1980-),男,高级工程师,主要从事新能源并网技术方面的研究。

王平(联系人),男,重庆大学副教授,博士,主要从事信号处理与数字超声成像方面的研究。(E-mail)cqu_dqwp@163.com。

近年来,光伏发电作为一种清洁的可再生能源,得到了快速发展。大规模光伏并网发电分析成为近年研究的热点^[1-2]。由于光伏发电系统受天气状况,包括光照强度和环境温度等因素影响,其发电量和输出功率具有随机性强,波动大和不易控制的特点。随着越来越多兆瓦级光伏发电系统接入电网运行,对电网的稳定和调度管理带来了诸多问题。因此有必要对光伏发电系统的发电功率进行准确的预测,从而减少光伏发电随机性对电力系统的影响,提高电力系统的安全性和稳定性^[3-5]。

光伏发电功率预测方法有间接法和直接法两大类。间接预测方法首先对太阳辐射进行预测,然后根据光伏发电系统的模型得到输出功率,文献[6]采用光照度历史数据,通过神经网络对光照强度进行预测,然后通过光照强度和环境温度参数计算光伏系统的输出功率。直接法采用光伏发电系统的历史发电数据,将光伏发电系统视为一个黑箱,通过建立光伏发电系统的模型实现功率预测,文献[7]采用BP神经网络模型对光伏系统的发电量进行了短期预测。郑凌蔚等^[8]采用小波神经网络作为光伏发电系统非线性自回归模型(NARX)的非线性系统辨识函数。对晴天、多云天和雨天3种天气条件下光伏发电系统输出的有功功率进行预测,该方法的辨识拟合度在晴天为93.15%,多云天气为75.07%,雨天的时候为80.61%,可见该算法对不同的天气状况辨识精度存在差异。

针对现有光伏功率预测方法在不同天气状况预测精度不一致的问题,提出一种基于无迹卡尔曼滤波神经网络(UKFNN)的光伏发电系统功率预测方法,所预测的功率包括有功功率和无功功率。

1 UKF神经网络建模

光伏发电系统是一个非线性系统,根据神经元激励函数的非线性特点,利用UKF实现神经网络权值系数的自适应调整,从而自适应模拟复杂的非线性系统。

1.1 神经网络的状态空间表示

对于 N 层BP网络,每层神经元有 $S_k(k=1,2,\dots,N)$ 输入,第 k 层神经元的连接权值为

$$\omega_{ij}^k (i=1,2,\dots,S_{k-1}; j=1,2,\dots,S_k)。 \quad (1)$$

为了将 ω_{ij}^k 的计算转化为UKF滤波的形式,将网络中的权值 ω_{ij}^k 和阈值 b 写成增广状态向量,如式(2)所示。

$$\mathbf{w} = [\omega_{11}^1, \dots, \omega_{s_1 s_2}^1, b_1^1, \dots, b_{s_1}^1, \dots, \omega_{11}^N, \dots, \omega_{s_{N-1} s_N}^N, b_1^N, \dots, b_{s_N}^N]^T。 \quad (2)$$

对不同的神经网络进行训练,就是对网络的连接权值 ω_{ij}^k 和阈值 b 进行最优估计。因此,可将网络连接权值作为网络的状态变量,将输出作为网络的测量变量,则神经网络状态空间模型^[9]可以表示为

$$\begin{cases} \mathbf{w}_k = \mathbf{w}_{k-1}, \\ \mathbf{y}_{ek} = h(\mathbf{w}_k, \mathbf{x}_k) + \mathbf{v}_k, \end{cases} \quad (3)$$

式中: \mathbf{w}_k 是权值向量, \mathbf{x}_k 是网络输入向量, \mathbf{y}_{ek} 是网络的期望输出, h 是神经网络激励函数, \mathbf{v}_k 是观测噪声,在UKF神经网络中取为0。

1.2 无迹卡尔曼滤波算法

无迹卡尔曼滤波(Unscented Kalman Filter, UKF)是一种递归贝叶斯估计方法,分为预测(时间更新)和更新(测量更新)两个步骤^[10-13,14,15]。UKF采用无迹变换(Unscented transform, UT)实现均值和协方差的非线性传递,其更新过程采用卡尔曼滤波的测量过程^[8]。

定义非线性系统

$$\begin{cases} \mathbf{x}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{w}_k, \\ \mathbf{y}_k = h(\mathbf{x}_k) + \mathbf{v}_k, \end{cases} \quad (4)$$

式中: \mathbf{x}_k 是 n 维状态变量,当与神经网络算法融合时 \mathbf{x}_k 对应(3)式中的 \mathbf{w}_k ; \mathbf{u}_k 是 r 维已知输入变量,本文中对应的是直流输入电压和电流; \mathbf{y}_k 是 k 时刻的实际输出变量,当与神经网络算法融合时 \mathbf{x}_k 对应(3)式中的 \mathbf{y}_{ek} ; \mathbf{w}_k 是过程噪声向量, \mathbf{v}_k 是测量噪声,本文中的 \mathbf{w}_k 和 \mathbf{v}_k 均采用高斯白噪声。 f 是线性函数; h 是神经网络函数。

UT算法首先根据先验分布特性确定一组Sigma采样点,再将每个Sigma点带入非线性变换,得到一组变换点,通过非线性系统函数计算得到接近真实均值和方差值的后验均值和方差。UKF具体实现步骤

如下:

1) 初始化

$$\begin{cases} \bar{\mathbf{x}}_0 = E(\mathbf{x}_0), \\ \mathbf{P}_0 = E[(\mathbf{x}_0 - \bar{\mathbf{x}}_0)(\mathbf{x}_0 - \bar{\mathbf{x}}_0)^T], \end{cases} \quad (5)$$

式中: \mathbf{x}_0 是状态量初始值, E 表示期望运算, $(\cdot)^T$ 是转置运算. $\bar{\mathbf{x}}_0$ 是状态均值, \mathbf{P}_0 是状态方差.

2) 时间更新

一个 n 维随机变量 \mathbf{x}_k 的均值和方差矩阵分别为 $\bar{\mathbf{x}}$ 和 \mathbf{P}_x , 其一二阶矩可以通过构造 $2n+1$ 个 Sigma 点 \mathbf{x}_{k-1} 获得, 如式(6)所示.

$$\mathbf{x}_{k-1} = \begin{cases} \bar{\mathbf{x}}_{k-1}, i=0, \\ \bar{\mathbf{x}}_{k-1} + (\sqrt{(n+\lambda)\mathbf{P}_{k-1}})_i, i=1, 2, \dots, n, \\ \bar{\mathbf{x}}_{k-1} - (\sqrt{(n+\lambda)\mathbf{P}_{k-1}})_i, i=n+1, n+2, \dots, 2n, \end{cases} \quad (6)$$

式中: λ 是常数, $(\sqrt{(n+\lambda)\mathbf{P}_{k-1}})_i$ 是矩阵 $(n+\lambda)\mathbf{P}_{k-1}$ 的方根矩阵的第 i 行.

Sigma 点的均值和方差按式(7)计算.

$$\begin{cases} \omega_0^m = \frac{\lambda}{n+\lambda}, i=0, \\ \omega_0^c = \frac{\lambda}{n+\lambda} + (1-\alpha^2 + \beta), i=0, \\ \omega_i^m = \omega_i^c = \frac{\lambda}{2(n+\lambda)}, i=1, 2, \dots, 2n, \\ \lambda = \alpha^2(n+\kappa) - n, \end{cases} \quad (7)$$

式中: ω_i^m 是均值权值, ω_i^c 是方差权值, α 用于调节 Sigma 点和均值的距离, 取 $0 < \alpha < 1$ 数, κ 包含了 Sigma 点分布信息的加权系数, 在光伏功率预测模型中, 取 $\alpha=0.08, \kappa=0, \beta=2.73$.

UKF 时间更新按式(8)进行.

$$\begin{cases} \mathbf{x}_{k-1|k} = \mathbf{x}_k, \\ \mathbf{x}_{k|k-1}^* = f(\mathbf{x}_{k-1}), \\ \bar{\mathbf{x}}_{k|k-1} = \sum_{i=0}^{2n} \omega_i^m \mathbf{x}_{i,k|k-1}^*, \\ \mathbf{P}_{k|k-1} = \sum_{i=0}^{2n} \omega_i^c (\mathbf{x}_{i,k|k-1}^* - \bar{\mathbf{x}}_{k|k-1})(\mathbf{x}_{i,k|k-1}^* - \bar{\mathbf{x}}_{k|k-1})^T, \\ \boldsymbol{\gamma}_{k|k-1} = h(\mathbf{x}_{k|k-1}), \\ \bar{\mathbf{y}}_{k|k-1} = \sum_{i=0}^{2n} \omega_i^m \boldsymbol{\gamma}_{i,k|k-1}. \end{cases} \quad (8)$$

3) 测量更新

当获得新的测量值 y_k 后, 可以对状态变量均值和观测变量方差进行更新, 如式(9)所示.

$$\begin{cases} P_{\bar{\mathbf{y}}_k, \bar{\mathbf{y}}_k} = \sum_{i=0}^{2n} \omega_i^c (\boldsymbol{\gamma}_{i,k|k-1} - \bar{\mathbf{y}}_{k|k-1})(\boldsymbol{\gamma}_{i,k|k-1} - \bar{\mathbf{y}}_{k|k-1})^T, \\ P_{\bar{\mathbf{x}}_k, \bar{\mathbf{y}}_k} = \sum_{i=0}^{2n} \omega_i^c (\mathbf{x}_{i,k|k-1} - \bar{\mathbf{x}}_{k|k-1})(\boldsymbol{\gamma}_{i,k|k-1} - \bar{\mathbf{y}}_{k|k-1})^T, \\ K_k = P_{\bar{\mathbf{x}}_k, \bar{\mathbf{y}}_k} P_{\bar{\mathbf{y}}_k, \bar{\mathbf{y}}_k}^{-1}, \\ \bar{\mathbf{x}}_k = \bar{\mathbf{x}}_{k|k-1} + K_k (y_k - \bar{\mathbf{y}}_{k|k-1}), \\ P_k = P_{k|k-1} - K_k P_{\bar{\mathbf{y}}_k, \bar{\mathbf{y}}_k} K_k^T, \end{cases} \quad (9)$$

式中: $\bar{\mathbf{x}}_{k|k-1}$ 和 $\bar{\mathbf{y}}_{k|k-1}$ 分别是一阶矩, $P_{\bar{\mathbf{x}}_k, \bar{\mathbf{y}}_k}$ 是状态变量与测量变量的协方差, K_k 是 UKF 的增益矩阵, $\bar{\mathbf{x}}_k$ 是更新状态估计值, P_k 是更新状态方差矩阵.

2 实验测试与结果分析

2.1 光伏发电系统 UKFNN 建模

利用神经网络对光伏发电系统进行建模,采用 UKF 对系统的输出和神经网络权值同时进行估计。将神经网络的权值向量 w_k 作为 UKF 的状态变量 x_k ,神经网络的期望输出 y_{ek} 作为 UKF 的观测变量 y_k 。基于 UKF 的神经网络预测算法流程如图 1 所示。

以直流电压和直流作为系统的输入,分别以有功功率和无功功率作为输出,建立基于 UKF 的神经网络模型。本文中,选取 3 层 BP 神经网络,隐含层的传递函数采用 Sigmoid 函数, $f(x) = 1/(1 + e^{-x})$,输出层采用 Purelin 线性激励函数 $h(x) = x$,网络隐含层神经元个数取 3 个。

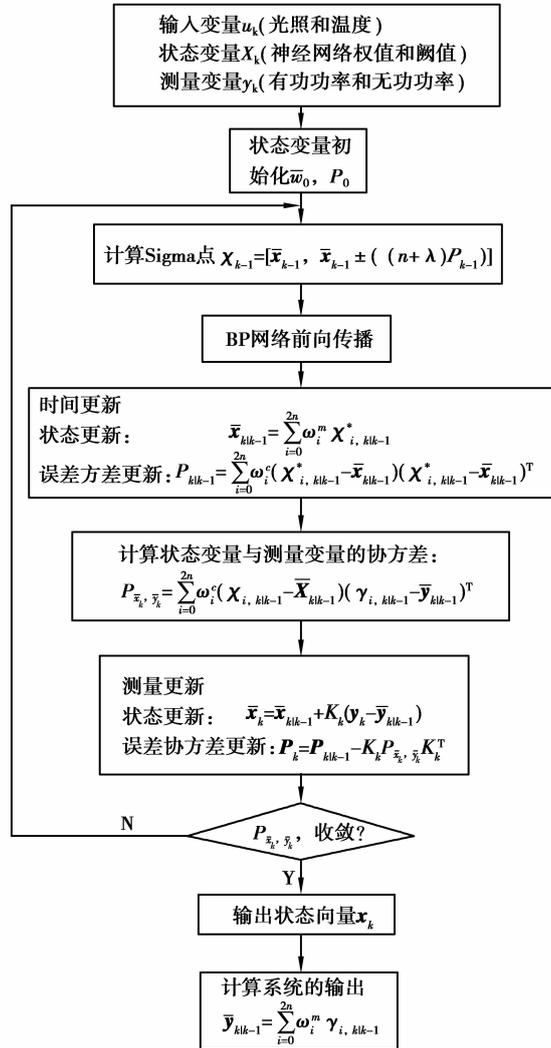


图 1 基于 UKF 的神经网络算法流程图

Fig.1 Flowchart of UKF neural network algorithm

2.2 实验数据采集与处理

以青海某光伏电站系统为研究对象,分别采集晴天、多云、阴雨 3 种不同天气条件下的直流电压、直流电流及输出有功功率和无功功率数据。采样时间间隔为 15 min,每种天气类型各采集 10 d 数据,将 10 d 的数据分成两部分,前 7 d 作为训练组,实现模型相关参数的估计,后 3 d 作为模型的验证数据。对数据进行预处理,去掉了日出前和日落后的无效数据。经过处理后的晴天、多云和雨天 3 种典型天气条件下光伏逆变器输入电压电流及输出有功和无功功率信号如图 2 所示。

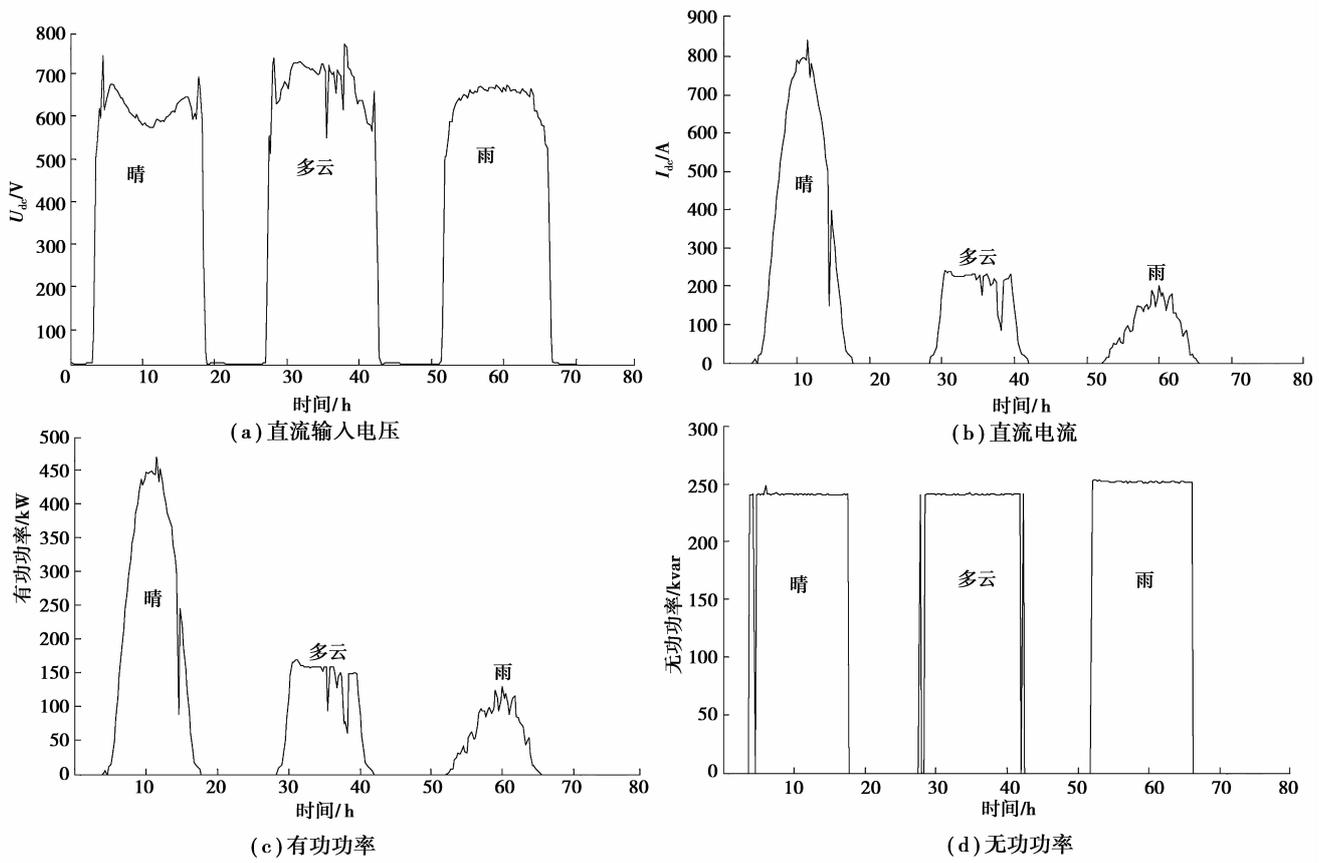
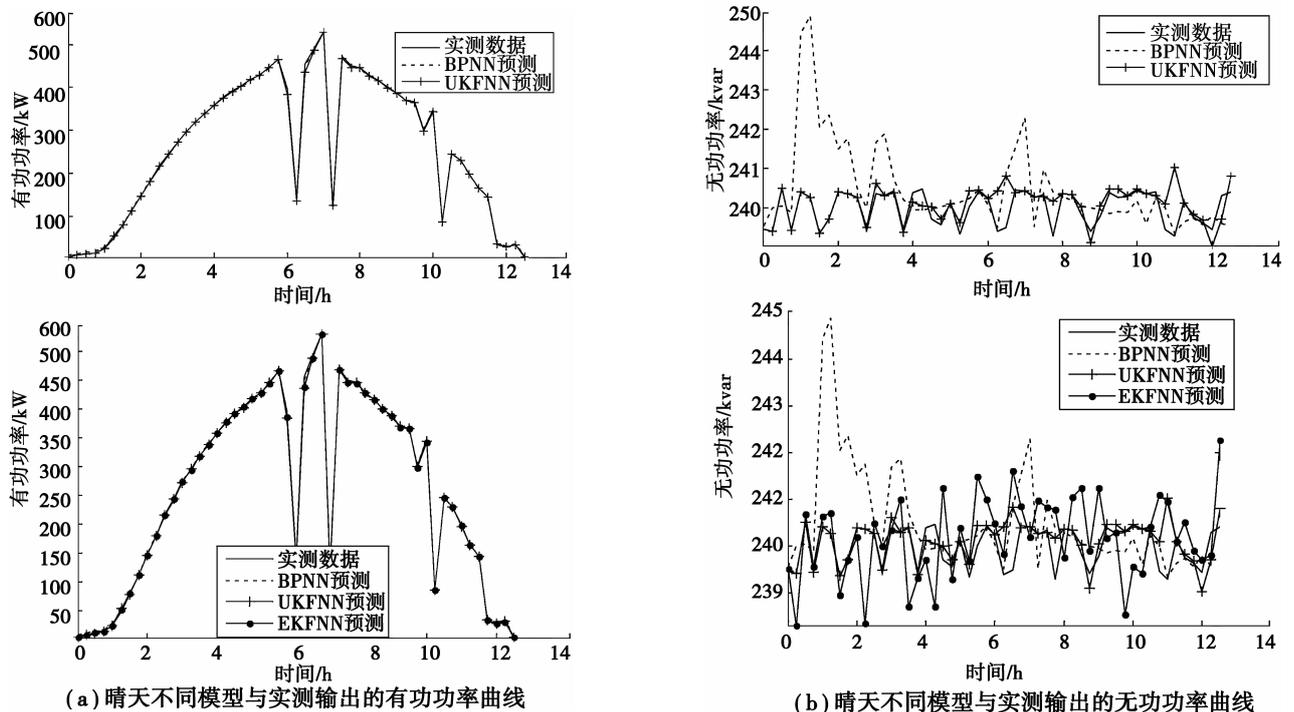


图 2 不同天气状况下模型辨识样本数据曲线

Fig.2 The waveforms of the collected data under different weather conditions

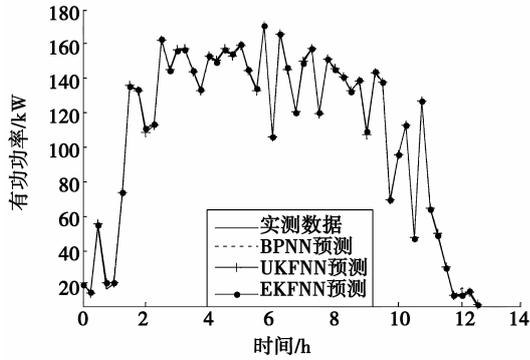
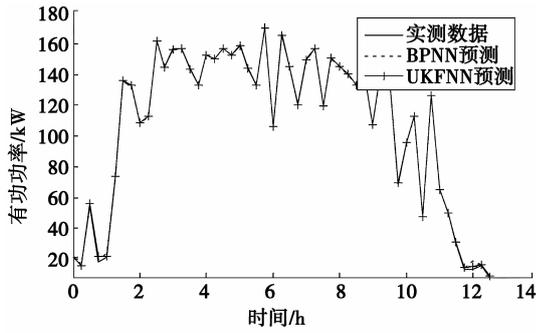
2.3 光伏发电预测方法测试

将所提出的基于无迹卡尔曼滤波的神经网络模型(UKFNN)与BP神经网络模型(BPNN)及扩展卡尔曼神经网络(EKFNN)的预测结果进行比较。在不同天气状况下,有功功率和无功功率的预测曲线如图3所示。

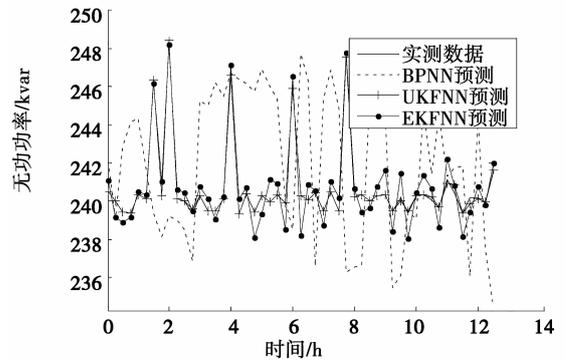
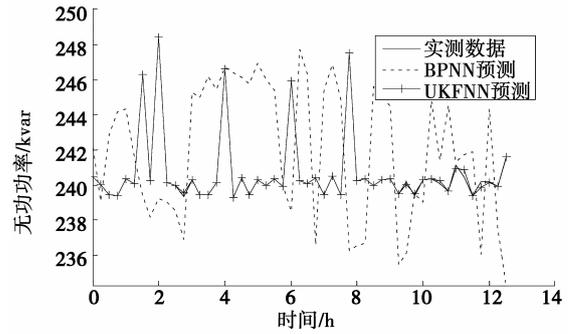


(a) 晴天不同模型与实测输出的有功功率曲线

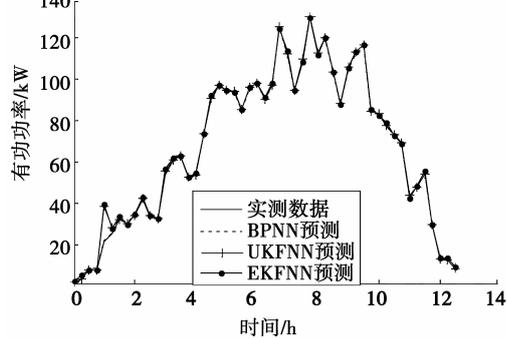
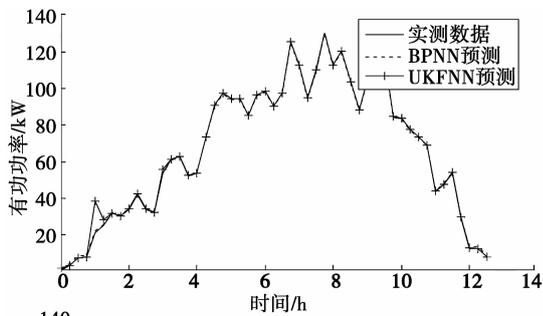
(b) 晴天不同模型与实测输出的无功功率曲线



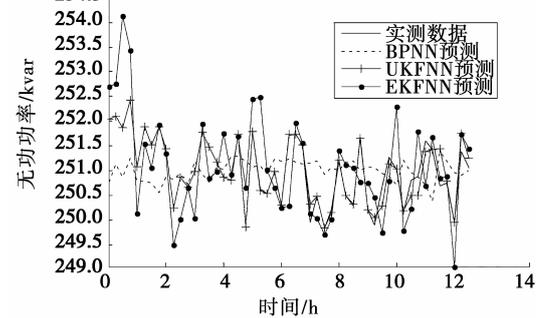
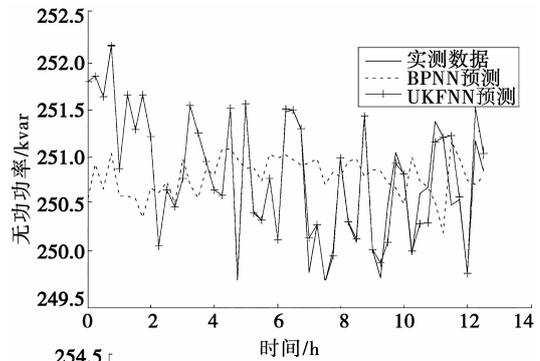
(c) 多云不同模型与实测输出有功功率曲线



(d) 多云不同模型与实测输出的无功功率曲线



(e) 雨天不同模型与实测输出的有功功率曲线



(f) 雨天不同模型与实测输出的无功功率曲线

图 3 不同模型的预测输出功率比较

Fig.3 Prediction results comparison between different model

从图 3 可见,UKFNN,BPNN 以及 EKFNN 对有功功率的都具有良好的预测性能,预测输出接近实际的输出值,并且对天气具有良好的鲁棒性。而对无功功率的预测,UKFNN 的预测精度优于 EKFNN, UKFNN 和 EKFNN 预测效果明显优于 BPNN 方法。EKFNN 和 UKFNN 在不同天气状态在对有功功率和无功功率都能很好的预测,而 UKFNN 对天气的鲁棒性更好。为了进一步验证 UKFNN 的有效性,采用最佳拟合度来衡量模型输出与实际输出的拟合程度,如式(10)所示。

$$f_{\text{BestFit}} = \left(1 - \frac{|\mathbf{y} - \mathbf{y}^*|}{|\mathbf{y} - \bar{\mathbf{y}}|}\right) \times 100, \quad (10)$$

式中： \mathbf{y} 为实测输出信号， \mathbf{y}^* 为模型输出信号， $\bar{\mathbf{y}}$ 是实测输出信号 \mathbf{y} 的平均值。

不同天气状况下 UKFNN 和 BPNN 对有功功率和无功功率预测的最佳拟合度如表 1 所示。

表 1 UKFNN、BPNN 及 EKFNN 三种方法最佳拟合度比较

Table 1 The best fits of UKFNN, BPNN and EKFNN

天气条件	UKFNN/%		BP 神经网络/%		EKFNN/%	
	有功功率	无功功率	有功功率	无功功率	有功功率	无功功率
晴天	97.7	90.5	98.1	29.1	97.5	87.5
多云	96.6	97.8	96.1	34.4	96.8	95.7
雨天	97.7	94.4	97.2	28.7	97.1	90.2
均值	97.3	94.2	97.1	30.7	97.1	91.3

从表 1 可见：在不同天气条件下，UKFNN、BPNN 以及 EKFNN 3 种方法对有功功率预测的最佳拟合度均大于 97%，3 种方法在多云天时有功功率预测的拟合度最低分别为 96.6%，96.1% 和 96.8%。3 种方法对无功功率的预测性能则有很大的差距。UKFNN 和 EKFNN 方法对无功功率的预测拟合度在不同天气情况下均值分别为 94.2% 和 91.3%，而 BPNN 方法对无功功率的预测拟合度只有 30.7%，几乎不能实现对无功功率的预测。这主要是因为有功功率变化相对缓慢，而无功功率波动较快，静态 BPNN 不能有效地对动态时变信号进行跟踪。UKFNN 以及 EKFNN 均具有动态演化能力，由于 UKFNN 方法克服了 EKFNN 算法截断误差项引起的缺陷，并且 UKFNN 在进行自适应调整时，可以捕捉系统状态的二阶矩，因此数值稳定性好。综上所述，对于光伏发电有功功率和无功功率的预测采用 UKFNN 方法能更好的进行动态调整，从而更准确地描述光伏电站的工作情况。

3 结 论

提出了一种基于无迹卡尔曼滤波神经网络的光伏发电站预测方法。该方法将光伏电站看成两输入单输出的非线性黑箱模型，建立了晴天、多云天、雨天 3 种天气条件下的无迹卡尔曼神经网络模型。通过实测的光伏电站系统数据进行模型训练和模型验证表明：所提出的 UKFNN 方法具有较强的动态演化能力及自适应性，对不同天气情况下的发电情况都可以进行高精度的预测，即采用 UKFNN 方法对光伏发电功率预测具有良好的鲁棒性。

参考文献：

- [1] 周德佳, 赵争鸣, 袁立强, 等. 具有改进最大功率跟踪算法的光伏并网控制系统及其实现[J]. 中国电机工程学报, 2008, 28(31): 94-100.
- ZHOU Dejia, ZHAO Zhengming, YUAN Liqiang, et al. Implementation of a photovoltaic grid-connected system based on improved maximum power point tracking[J]. Proceedings of the CSEE, 2008, 28(31): 94-100. (in Chinese)
- [2] 胡波, 野中佑斗, 横山隆一. 大规模光伏系统并网对配电网的影响[J]. 电力系统自动化, 2012, 36(3): 34-38.
- HU Bo, YUTO Nonaka, RYUICHI Yokoyama. Influence of large-scale grid-connected photovoltaic system on distribution networks[J]. Automation of Electric Power Systems, 2012, 36(3): 34-38. (in Chinese)

- [3] Teng X L, Gao Z H, Zhang Y Y, et al. Key technologies and the implementation of wind, PV and storage cogeneration monitoring system[J]. *Journal of Modern Power Systems and Clean Energy*, 2014, 2(2): 104-113.
- [4] 叶林,陈政,赵永宁.考虑电池荷电状态的光伏功率分段平滑控制方法[J].*电网技术*,2014,38(7):1812-1818.
YE Lin, CHEN Zheng, ZHAO Yongning. A segmented smoothing control method for photovoltaic power considering battery's state of charge[J]. *Power System Technology*, 2014, 38(7): 1812-1818. (in Chinese)
- [5] 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. (in Chinese)
- [6] Yona A, Senjyu T, Funabashi T, et al. Application of neural network to one-day-ahead 24 hours generating power forecasting for photovoltaic system[C]// *The 14th International Conference on Intelligent System Applications to Power Systems, ISAP 2007*, November 4-8, 2007, Kaohsiung, Taiwan. [S.l]: IEEE, 2007: 1-6.
- [7] 陈昌松,段善旭,殷进军.基于神经网络的光伏阵列发电预测模型的设计[J].*电工技术学报*,2009,24(9):153-158.
CHEN Changsong, DUAN Shanxu, YIN Jinjun. Design of photovoltaic array power forecasting model based on neural network[J]. *Transactions of China Electrotechnical Society*, 2009, 24(9): 153- 158. (in Chinese)
- [8] 郑凌蔚.光伏微电网控制与优化的若干问题研究[D].上海:华东理工大学,2014.
ZHENG Lingwei. Study on some issues in PV microgrid control and optimization[D]. Shanghai: East China University of Science and Technology, 2014. (in Chinese)
- [9] Julier S J, Uhlmann J K, Durrant-Whyte H F. A new approach for filtering nonlinear system[C]// *American Control Conference, Proceedings of the 1995*, June 21-23, 1995. [S.l]: IEEE, 1995, 3: 1628 -1632.
- [10] 罗兵,黄万杰,杨帅.基于 Tan-Sigmoid 函数参数调整的 BP 神经网络改进算法[J].*重庆大学学报(自然科学版)*, 2006, 29(1):150-153.
LUO Bing, HUANG Wanjie, YANG Shuai. Improved algorithm of BP neural networks based on parameters adjustment of Tan-Sigmoid transfer function[J]. *Journal of Chongqing University(Natural Science Edition)*, 2006, 29(1): 150-153. (in Chinese)
- [11] Haykin S. *Kalman filtering and neural networks*[M]. John Wiley & Sons, Inc, 2001.
- [12] Wang S, Gao W, Meliopoulos A P S. An alternative method for power system dynamic state estimation based on unscented transform[J]. *IEEE Transactions on Power Systems*, 2012, 27(2): 942-950.
- [13] Menegaz H M T, Ishihara J Y, Borges G A, et al. A systematization of the unscented Kalman filter theory[J]. *IEEE Transactions on Automatic Control*, 2015, 60(10): 2583-2598.

(编辑 郑洁)