基于相似日和径向基函数神经网络的 光伏阵列输出功率预测

王晓兰1,2 萬鹏江1

(1. 兰州理工大学 电气与信息工程学院, 甘肃 兰州 730050;

2. 甘肃省工业过程先进控制重点实验室,甘肃 兰州 730050)

摘要:选取太阳辐照时间、辐照强度以及气温等影响光伏阵列输出功率的主要气象因素,根据相似日的输出功率具有较强的关联度,提出选择相似日的方法,设计基于相似日和径向基函数(RBF)神经网络的光伏阵列输出功率预测模型。选取最邻近的一个相似日与待预测日气象特征向量的差值作为 RBF 神经网络的输入变量,神经网络的输出值即为待预测日光伏阵列输出功率。以我国西北某地光伏阵列的实测功率数据对所提模型进行训练和验证,得到预测模型的平均绝对百分误差为 13.82%,均方根误差为 0.4054,验证了所提模型具有较好的精度。

关键词:光伏阵列:输出功率:径向基函数网络:相似日:预测:模型:神经网络

中图分类号: TM 615

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2013.01.019

0 引言

光伏发电技术是当前利用太阳能[1-2]的主要方式之一,由于光伏发电系统的输出功率受到太阳辐照强度、温度、辐照时间等众多因素的影响,具有很大的时变性和随机性,并网时对电网的调度、保护诸多方面有很大的影响,所以对光伏发电系统的输出功率进行预测变得越来越重要。尤其是短期、实时的精确预测对电力系统运行及生产费用都有非常重要的经济意义,也有利于光伏电站中组件维护和检修。

目前,国内外对于光伏发电系统输出功率的研究 越来越深入,根据预测物理量的不同,主要分为直接 预测和间接预测 2 种,直接预测是直接对光伏发电系 统的输出功率进行预测,间接预测方式首先对地表太 阳辐照强度进行预测,然后根据光伏发电系统出力 模型得到系统的输出功率^[3]。而从预测方法上可以 分为物理方法和统计方法 2 类。基于物理方法上可以 分为物理方法和统计方法 2 类。基于物理方法自以 伏电站功率预测,根据数值天气预报(NWP)信息得 到太阳照射时间、辐照强度、气温等气象数据,然后 组为本曲线计算得到光伏电站的输出功率 综合考虑影响光伏电站所在地的各种地理信息,根 据输出功率曲线计算得到光伏电站的输出功率。统 计方法对历史数据进行统计分析,找出其内在规律 建立一个影射关系用于预测,统计方法不考虑太阳 辐照强度变化的物理过程,而根据历史统计数据找 出天气状况与光伏电站出力的关系,然后根据实测

收稿日期:2011-05-10;修回日期:2012-10-29

基金项目:国家自然科学基金资助项目(50967001);人力资源 与社会保障部留学人员科技活动项目(1003ZSB112)

Project supported by the National Natural Science Foundation of China(50967001) and Program for Returned Talents after Studying Abroad by the Ministry of Human Resources and Social Security(1003ZSB112)

数据和数值天气预报数对风电场输出功率进行预测,常用的预测方法有时间序列法、人工神经网络(ANN)方法、支持向量机(SVM)等。文献[4-7]综合考虑各种气象因素,基于神经网络建立了提前一天的光伏发电系统输出功率预测模型,具有较好的实用性和可行性。文献[8-10]基于马尔可夫链建立状态转移矩阵来预测一天之内光伏发电系统输出功率的方法,具有一定的代表性。文献[11]根据光伏阵列的数学模型和支持向量机原理,分别建立预测模型进行比较,预测结果显示所提预测方法能够得到较准确的光伏出力的预测值。这些预测方法能够得到较准确的光伏出力的预测值。这些预测方法就够得到较准确的光伏出力的预测值。这些预测方法对气候因素的处理还不够精细,当气候条件发生剧烈变化时,模型预测精度还有待提高。

由于影响光伏系统输出功率的气象因素非常多,对复杂的气象条件进行优化选取,进行规范化处理对预测过程非常重要。本文提出了光伏发电系统相似日的选择方法,由于相似日的输出功率曲线具有很高的关联度,将具有相似气象条件的预测日作为预测样本,建立径向基函数 RBF(Radial Basis Function)神经网络预测模型。根据我国北方某地独立光伏阵列的实测数据,对预测模型进行训练和预测,结果表明预测模型有较好精度,具有一定的实用性及可行性。

L 相似日选取处理

1.1 影响阵列功率输出的因素分析

文献[5]中单位面积的光伏阵列输出功率为:

 $P_{\text{PV}} = \eta_{\text{PV}} SI \left[1 - 0.005 (t_0 + 25) \right] \tag{1}$

其中, η_{PV} 为光伏阵列的转换效率,S 为阵列的面积,I 为太阳辐照强度, t_0 为大气温度。在光伏发电系统中,阵列的面积是不变的。而短期的输出功率预测

1

中,也可以近似认为阵列的转换效率是恒定的。

光伏阵列是把光伏电池串联后,再并联在一点的整体,所以光伏阵列的输出可以由光伏电池的特性来反映。当日照强度增加时,光伏电池的开路电压变化不大,短路电流增加明显,导致阵列输出功率增加。在一定范围内,当气温增加时,光伏电池内部温度随之增加,光伏电池的开路电压下降,短路电流略有增加,光伏电池输出功率会有所减小,阵列输出功率随之减小。日照时间的长短则主要反映了季节性因素对阵列输出的影响,在日照时间较长的夏季,光伏阵列的输出功率值与冬季有较为明显的差异[12]。所以本文选取太阳辐照时间的长度、辐照强度、气温作为光伏阵列输出功率的主要影响因素。

1.2 相似日选取原理[13-15]

根据以上分析,选取每日气象特征向量为:

$$\mathbf{x}_{i} = [T_{i}, I_{hi}, I_{li}, t_{1}, t_{2}, t_{hi}, t_{li}, t_{3}, t_{4}]$$

其中, T_i 为第i日辐照时间长度(h), I_{hi} 、 I_{hi} 为第i日最大和最小太阳辐照强度(W·h/m²), t_1 、 t_2 分别为最大和最小太阳辐照值出现的时刻, t_{hi} 、 t_{hi} 分别为第i日的日最高气温、最低气温($^{\circ}$ C), t_3 、 t_4 分别为日最高气温和最低气温出现的时刻。

若记预测日的气象特征向量为 $\mathbf{x} = [x(1), x(2), \cdots, x(m)]^T$,则第 i 个历史日的气象因素特征向量记为 $\mathbf{x}_i = [x_i(1), x_i(2), \cdots, x_i(m)]^T$,其中,m 为特征向量分量的个数。

对第i个历史日,第k个气象特征向量分量归一化处理为.

 $x_i'(k) = [x_i(k) - x_{imin}(k)]/[x_{imax}(k) - x_{imin}(k)]$ (2) 其中, $x_i(k)$ 为第 k 个气象特征向量分量; $x_{imax}(k)$ 和 $x_{imin}(k)$ 分别为第 k 个特征向量的最大值和最小值。

利用灰色关联系数法,则预测日和第i日第k个特征向量的关联系数为.

$$\varepsilon_{i}(k) = (\min_{i} \min_{k} |x(k) - x_{i}(k)| + \rho \max_{i} \min_{k} |x(k) - x_{i}(k)|) / (|x(k) - x_{i}(k)| + \rho \max_{i} \max_{k} |x(k) - x_{i}(k)|)$$

$$(3)$$

其中,ρ为常数,一般取为0.5。

综合各个气象特征向量分量的关联系数,得到预测日与第*i*日的总关联度为:

$$r_i = \prod_{i=1}^{m} \varepsilon_i(k) \tag{4}$$

预测时,从计算预测日和最临近的第i个历史日的关联度开始,逐日计算关联度值 r_i ,选取相似度 $r_i > 0.80$ 的多天作为预测日的相似日。

2 RBF 神经网络

RBF 神经网络[16-17]是一种局部逼近的神经网络,

其具有 3 层结构如图 1 所示,图中Φ(·)为 RBF。第 1 层由数个感知单元组成,将网络与外界环境连接起来;第 2 层是隐含层,其执行的是一种用于特征提取的非线性变换,然后作用函数对输入信号在局部产生响应;网络的输出是线性的。与传统的 BP 神经网络相比,RBF 神经网络的隐含层节点的数目可以根据需要确定,不用专门去选取,也克服了 BP 神经网络收敛速度慢和局部最小等缺点,所以更适用于实时监控的场合。

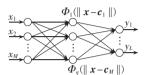


图 1 径向基函数网络模型结构

Fig.1 Structure of RBFN model

设网络输入x为M维向量,输出y为L维向量,网络的输入层到隐含层实现 $x \rightarrow u_i(x)$ 的非线性映射,而 RBF 神经网络隐含层节点的作用函数采用高斯激活函数,则隐含层第i个节点的输出可由下式表示:

$$u_i = \exp\left[-\frac{(\boldsymbol{x} - \boldsymbol{c}_i)^{\mathrm{T}}(\boldsymbol{x} - \boldsymbol{c}_i)}{2\sigma_i^2}\right] \quad i = 1, 2, \dots, L$$
 (5)

隐含层到输出层实现 $u_i(x) \rightarrow y_k$ 的线性映射为:

$$y_k = \sum_{i=1}^{q} (w_{ki}u_i) - \theta_k \quad i = 1, 2, \dots, L$$
 (6)

其中, $\mathbf{x} = (x_1, x_2, \dots, x_M)^{\mathrm{T}}$ 为输入样本;q为隐含层节点数; u_i 为第 i个隐含层节点的输出; σ_i 为第 i个隐含层节点的标准化常数; y_k 为输出层第 k个节点的输出; w_{ki} 为隐含层到输出层的加权系数; θ_k 为输出层节点阈值; c_i 为第 i个隐含层节点高斯函数的中心向量,该向量是一个与输入样本 \mathbf{x} 维数相同的列向量,即 $\mathbf{c} = (c_{i1}, c_{i2}, \dots, c_{iM})^{\mathrm{T}}$ 。

若有 N 个训练样本,则网络对 N 个训练样本总误差函数为.

$$J = \sum_{p=1}^{N} J_p = \frac{1}{2} \sum_{p=1}^{N} \sum_{k=1}^{L} (t_k^p - y_k^p)^2 = \frac{1}{2} \sum_{p=1}^{N} \sum_{k=1}^{L} e_k^2$$
 (7)

其中,L 为网络输出节点数; t_k^p 为在样本p 作用下的第k 个神经元的期望输出; y_k^p 为样本p 作用下的第k 个神经元的实际输出。

RBF 神经网络的训练通常采用 K 均值聚类算法调整中心向量和确定标准化常数,用最小二乘法来确定连接权 w_{ki} ,具体算法参见文献[18]。

3 预测模型

3.1 神经网络预测模型节点的选取

采用 RBF 神经网络进行光伏阵列输出功率预测模型的设计,RBF 神经网络函数包含了输入、隐含层、输出节点数及传递函数等多个参数,因此在确定了这些网络参数后才能构建预测模型。



- **a.** 输入节点的选取:输入层节点对应于预测模型的输入变量,在选取输入节点时,如果节点数选取过多,由于神经网络中寻优参数较多,会造成网络收敛速度过慢;而输入节点较少时,不能较好地反映输出功率和气象数据的关联性,所以本文中选取与预测日最邻近的一个相似日和预测日气象数据的差值作为网络模型的输入变量。
- **b.** 隐含层节点的选取:由于 RBF 神经网络是单 隐含层结构,隐含层神经元的个数根据实际情况增减。
- **c.** 输出层节点的选取:输出层的输出值是预测日光伏阵列的输出功率。预测模型结构如图 2 所示。

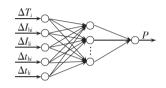


图 2 径向基函数神经网络预测模型

Fig.2 Forecasting model based on RBFNN

3.2 预测模型网络训练和预测过程

RBF 神经网络预测模型的结构设计好后,需要对网络进行训练,神经网络的泛化能力是主要的性能指标,要采用样本对网络进行训练。主要做法是将输入变量数据一部分作为训练集,另一部分作为测试集。而且经过前面的分析,在确定了网络的结构后,样本的数量与质量对于模型的预测精度至关重要。网络模型的训练和预测步骤如下。

- **a.** 对输入气象数据进行预处理:剔除其中奇异的观测数据,为避免神经元的饱和,对各输入数据进行归一化处理。根据预测地的历史气象数据得到各气象数据的范围。
- **b.** 进行预测时,对数据进行归一化处理后,选取关联度值 $r_i \ge 0.80$ 的最邻近的一个相似日。预测日与相似日气象数据的差值作为预测模型输入变量,对预测日的阵列输出功率进行预测,称为预测模型 II。为了便于直观比较分析,预测日前一日的气象数据和预测日的气象数据差值作为网络模型输入,利用构建的RBF 神经网络模型进行预测,称为预测模型 II。
- **c.** 最终得到预测日光伏阵列的输出功率值,通过对基于相似日原理选取的预测模型进行比较分析,验证模型的有效性和实用性。

4 实例分析

4.1 实验数据

本文以我国西北某地光伏阵列的输出功率值和 当地气象数据为例,输出功率数据每1小时采样一次,对应时间点的气象数据作为模型输入变量。将全 部气象和功率数据划分为2组,分别由预测日前一 个月的观测数据组成的训练集,对预测日的阵列输 出功率进行预测。

4.2 预测结果与误差分析

预测日前1日的气象数据和预测日气象数据的差值作为输入,根据本文中 RBF 神经网络结构构建预测模型Ⅰ;根据相似日选取原理构建预测模型Ⅱ,分别对第一季度选取的连续7个预测日阵列输出功率预测结果如图3和图4所示。

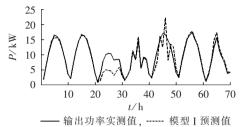


图 3 模型 | 预测结果

Fig.3 Result of forecasting model I

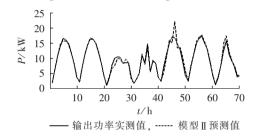


图 4 模型Ⅱ预测结果

Fig.4 Result of forecasting model II

2 种模型的误差曲线如图 5 和图 6 所示,从图中可以看出:模型Ⅱ与模型Ⅰ相比,预测精度有所提高,预测结果稳定性也有了较好的改善。

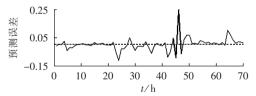


图 5 模型 [预测误差曲线

Fig.5 Error curve of forecasting model I

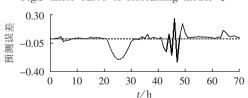


图 6 模型 || 预测误差曲线

Fig.6 Error curve of forecasting model II

选取合理的、科学的误差指标,对评定预测效果有着十分重要的意义。本文构造的预测模型分别选用平均绝对百分误差 e_{MAPE} 和均方根误差 e_{RMSE} 对其进行可行性分析,如式(8)和式(9)所示。

$$e_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^{N} \left| \frac{P_i - \hat{P}_i}{P_i} \right| \times 100\%$$
 (8)



$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (P_i - \hat{P}_i)^2}$$
 (9)

其中, P_i 为光伏阵列输出功率实测值, \hat{P}_i 为输出功率预测值。N为预测样本个数。

预测模型 Ⅰ、Ⅱ预测误差如表 1 所示。

表 1 预测误差比较

Tab.1 Comparison of forecasting errors

预测模型	e_{MAPE} / %	$e_{ m RMSE}$
I	26.38	0.8245
II	13.82	0.4054

由表 1 可以看出,相似日预测模型Ⅱ可以有效提高模型预测精度。由于收集气象和输出功率数据的有限性,光伏阵列的输出功率影响因素还有待考证,适当地选取输出变量中影响因素的个数,预测精度还有提高的可能性,而仿真实验也表明增大训练样本数量可适当提高预测模型的准确度。因此,结合本文所提出的预测模型Ⅱ,在实际应用当中可以从上述 2 个方面来提高模型的预测准确性。

5 结语

对影响光伏系统输出功率的复杂气象因素进行优选,并进行规范化处理。本文提出了光伏发电系统相似日的选择方法,由于相似日的输出功率曲线有很强的相似度,将具有相似气象条件的预测日作为预测样本,基于 RBF 神经网络建立预测模型。结果表明预测模型精度较好,具有一定的实用性及可行性。

参考文献:

- [1] 吴理博,赵争鸣,刘建政,等. 单级式光伏并网逆变系统中的最大 功率点跟踪算法稳定性研究[J]. 中国电机工程学报,2006,26(6): 73-77
 - WU Libo, ZHAO Zhengming, LIU Jianzheng, et al. Research on the stability of MPPT strategy applied in single-stage gridconnected photovoltaic system[J]. Proceedings of the CSEE, 2006, 26(6):73-77.
- [2] 赵争鸣,刘建政,孙晓瑛,等. 太阳能光伏发电及其应用[M]. 北京;科学出版社,2005:1-15.
- [3] 卢静,翟海青,刘纯,等. 光伏发电功率预测统计方法研究[J]. 华东电力,2010,38(4);563-567.
 - LU Jing,DI Haiqing,LIU Chun,et al. Study on statistical method for predicting photovoltaic generation power [J]. East China Electric Power, 2010, 38(4):563-567.
- [4] 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 neutral network [J]. Transactions of China Electrotechnical Society, 2009, 24(9): 153-158.
- [5] YONA A, SENJYU T, FUNABASHI T. Application of recurrent neural network to short-term-ahead generating power forecasting for photovoltaic system [C] // IEEE Power Engineering Society General Meeting. Tampa, FL, USA: [s.n.], 2007:1-6.
- [6] 张岚,张艳霞,郭嫦敏,等. 基于神经网络的光伏系统发电功率预

- 测[J]. 中国电力,2010,43(9):75-78.
- ZHANG Lan, ZHANG Yanxia, GUO Changmin, et al. Photovoltaic system power forecasting based on neural networks [J]. Electric Power, 2010, 43(9):75-78.
- [7] ADEL M, ALESSANDRO M P. Performance prediction of 20 kW grid-connected photovoltaic plant at Trieste(Italy) using artificial neural network [J]. Energy Conversion and Management, 2010 (51):2431-2441.
- [8] LI Yingzi, NIU Jingcang. Forecast of power generation for grid-connected photovoltaic system based on Markov chain [C]//Asia-Pacific Power and Energy Engineering Conference (APPEEC). Wuhan, China; [s.n.], 2009; 1-4.
- [9] LI Yingzi, NIU Jingcang. Forecast of power generation for grid-connected photovoltaic system based on grey model and Markov chain [C]//3rd IEEE Conference on Industrial Electronics and Applications (ICIEA). Singapore: [s.n.], 2008; 1729-1733.
- [10] 丁明,徐宁舟. 基于马尔科夫链的光伏发电系统输出功率短期预测方法[J]. 电网技术,2011,35(1):152-157.

 DING Ming,XU Ningzhou. A method to forecast short-term output power of photovoltaic generation system based on Markov chain[J]. Power System Technology,2011,35(1):152-157.
- [11] 栗然,李广敏. 基于支持向量机回归的光伏发电出力预测[J]. 中国电力,2008,41(2):74-78.

 LI Ran,LI Guangmin. Photovoltaic power generation output forecasting based on support vector machine regression technique[J]. Electric Power,2008,41(2):74-78.
- [12] 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]//International Conference on Intelligent Systems Applications to Power Systems, 2007. ISAP 2007. Toki Messe, Niigata, Japan: [s.n.], 2007:1-6.
- [13] 康重庆,程旭,夏清,等. 一种规范化的处理相关因素的短期负荷预测新策略[J]. 电力系统自动化,1999,23(18);32-35. KANG Chongqing,CHENG Xu,XIA Qing,et al. A new unified approach to short-term load forecasting considering correlated factors[J]. Automation of Electric Power Systems,1999,23(18); 32-35.
- [14] 林辉,刘晶,郝志峰,等. 基于相似日负荷修正的节假日短期负荷预测[J]. 电力系统保护与控制,2010,38(7):47-51.

 LIN Hui,LIU Jing,HAO Zhifeng,et al. Short-term load fore-casting for holidays based on the similar days' load modification[J]. Power System Protection and Control,2010,38(7): 47-51.
- [15] 莫维仁,张伯明,孙宏斌,等. 短期负荷预测中选择相似目的探讨[J]. 清华大学学报:自然科学版,2004,44(1):106-109. MO Weiren,ZHANG Boming,SUN Hongbin,et al. Method to select similar days for short-term load forecasting[J]. Journal of Tsinghua University:Science and Technology,2004,44(1): 106-109.
- [16] 刘金琨. 智能控制[M]. 北京:电子工业出版社,2005:132-134.
- [17] 飞思科技产品研发中心. 神经网络理论与 MATLAB7 实现[M]. 北京:电子工业出版社,2005;110-116.
- [18] MOODY J, DARKEN C J. Fast learning in networks of locally tuned processing units[J]. Neural Computation, 1989, 1(2):281-294.

作者简介:

王晓兰(1963-),女,甘肃秦安人,教授,主要从事计算机控制、复杂系统建模等方面的教学和科研工作;

葛鹏江(1986-),男,陕西兴平人,硕士,主要从事电力系统的设计和规划工作(E-mail:gepj1025@126.com)。

(下转第 109 页 continued on page 109)



作者简介:

周 林(1961-),男,四川内江人,教授,博士研究生导师,

主要从事可再生能源理论、电能质量分析与控制研究; 廖 波(1986-),男,四川成都人,硕士研究生,主要从事 光伏并网发电系统方面的研究(**E-mail**:liaobo2006@163.com)。

Grid-connected photovoltaic power conditioner system based on amplitude integral

ZHOU Lin, LIAO Bo, LONG Yanping, ZHANG Linqiang, LI Huaihua, DU Jinqi (State Key Laboratory of Power Transmission Equipment & System Security and New Technology, Chongqing University, Chongqing 400030, China)

Abstract: The accurate detection of harmonics and reactive currents and the generation of photovoltaic active current reference are essential for the control of three-phase grid-connected photovoltaic power conditioner system. In order to get the photovoltaic active current with same frequency and phase as the positive-sequence fundamental voltage of grid, the influence of parameter K in the amplitude integral positive-sequence fundamental extraction on the phase deviation of output positive-sequence fundamental voltage is analyzed and the relationship between K and frequency/phase deviation of positive-sequence fundamental voltage is derived. The positive-sequence fundamental voltage can be accurately extracted when K is set properly. Synchronous sine or cosine signals can be obtained without PLL. Based on i_p - i_q method, two standard selectors are applied, which combine randomly the photovoltaic active current with the harmonic or reactive current to form the grid-connection reference current for realizing the random functional combination of active power injection, harmonic restraint and reactive power compensation. Results of the simulation with MATLAB/Simulink and the experiment based on RT-LAB verify the correctness of theoretical analysis.

Key words: photovoltaic power conditioner system; amplitude integral; reference current calculation; selector; power quality; solar energy

(上接第 103 页 continued from page 103)

PV array output power forecasting based on similar day and RBFNN

WANG Xiaolan^{1,2}, GE Pengjiang¹

- (1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
 - 2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou 730050, China)

Abstract: As the solar radiation time, solar radiation intensity and air temperature are the main influencing factors of PV array output power and there is strong correlation in output power among the similar days, a forecasting model of PV array output power is designed based on similar days and RBFNN (Radial Basis Function Neural Network), which takes the difference of meteorological feature vector between the nearest similar day and the day to be forecasted as the input variable of RBFNN and its output as the forecasted PV array output power. The proposed model is trained and verified with the measured power dada of a PV array in Northwest China. Its mean absolute percentage error obtained is 13.82% and its root mean square error is 0.4054, showing its high accuracy.

Key words: PV array; output power; radial basis function networks; similar day; forecasting; models; neural networks