

Wind Speed Prediction Based on RBF Neural Network

Shoudao Huang, Lang Dai, Keyuan Huang, Sheng Ye

College of electrical and information engineering, Hunan university, Changsha, China, 410082

Email:shoudaohuang@tom.com, langzi3025@163.com

Abstract: Wind speed forecasting is very important to wind farms and power system operation. By use of radial basis function (RBF) neural network the short-term wind speed forecasting is researched. On the premise of without taking into account numerical weather prediction data, with wind speed sequences is used as the input variable, the model was constructed based on the nonlinear approach ability of radial basis function neural networks that was used for the short-term wind speed prediction. Using the model, we have achieved 1h ahead forecasting of the wind speed and its prediction error analysis. The results show that neural network structure and the selection of input sample have a certain impact on the prediction results. The forecasting accuracy of the method is better than BP network.

Keywords: short-term wind speed forecasting; artificial neural networks; radial basis function; wind farm

基于径向基神经网络的风电场风速预测

黄守道, 戴浪, 黄科元, 叶盛

湖南大学电气与信息工程学院, 长沙, 中国, 410082

Email:shoudaohuang@tom.com, langzi3025@163.com

摘要: 风速预测对风电场和电力系统的运行都具有重要意义。利用径向基函数 (RBF) 神经网络研究短期风速预测。在不考虑数值天气预报数据的前提下, 以风速序列作为模型输入变量, 建立了基于径向基函数神经网络的非线性逼近功能的风速短期预测模型。利用该模型实现了对风速的提前 1h 预测, 并对其预测误差进行分析。研究表明, 神经网络的结构和输入样本选择对预测结果有一定的影响, 和 BP 网络比较, 该方法具有更好的预测精度。

关键词: 短期风速预测; 人工神经网络; 径向基函数; 风电场

1 引言

风能是一种可再生能源, 利用风能发电日益受到人们的重视, 尤其是在欧美发达国家, 风力发电在电力系统中所占比重越来越大。随着近年风力发电规模的不断扩大, 当风电穿越功率超过一定值后, 风电场并网及并网后的稳定和安全问题成为亟待解决的问题, 对电力系统的功率平衡和经济调度有非常重要的意义。

风电场风速预测误差不仅与预测方法有关, 而且与预测周期以及预测地点的风速特性有关。一般来说, 预测周期越短, 预测地点的风速变化越缓和, 预测误差就越小; 反之, 预测误差就越大^[1]。根据所采用的

数学模型不同可分为持续预测法、自回归滑动平均模型法、卡尔曼滤波法和智能方法等。其中持续预测法是最简单的预测模型, 即把最近一点的风速或功率观测值作为下一点的预测值^[4]。改进的方法主要有 ARMA模型^[9]和卡尔曼滤波算法或时间序列法和卡尔曼滤波算法的结合^[7]。除此之外, 还有一些智能方法, 也是近来应用热点, 如人工神经网络方法、模糊逻辑法等。这些方法的引入使用, 使得风电场风速预测的精确度有了很大的提高。根据预测时间尺度分类, 可分为超短期预测和短期预测以及中长期预测。所谓超短期预测一般认为是不超过30min的预测; 短期预测一般可认为是30min~72h的预测; 主要用于电力系统的功率平衡和调度、暂态稳定评估等。中长期预测还存在很大困难, 因为风速、风向等天气情况是由大气运动决定的, 这使得中长期预测难以得到较好的预测

基金项目: 自然科学基金(50907020)

结果^[2]。

目前神经网络法在各种预测的应用越来越多，而在风电场风速预测上则相对较少。BP 网络又是用于风速预测最多的一种神经网络，RBF 尽管在其他预测问题，诸如负荷预测、用水预测等问题有广泛使用，但是在风速或风电功率预测上却鲜有应用。BP 神经网络法以及时间序列与神经网络相结合被运用在短期风速或风电功率预测^[1-3]。除此之外还有运用卡尔曼滤波法^[7]、向量自回归法对风速进行了预测。本文将运用 RBF 神经网络法来进行风速的短期预测。

2 RBF 神经网络预测风速

2.1 RBF 函数神经网络结构

RBF 神经网络的结构与多层前馈网络类似，它也是一种三层前馈式神经网络，其结构如图 1 所示。径向基函数网络是一个局部逼近网络，即对于输入空间的某一个局部区域只存在少数的神经元用于决定网络的输出。




Figure 1. Structure of RBF network

图 1. RBF 网络结构

输入层节点传递输入信号到隐含层，隐含层节点由径向基函数（此处为高斯核函数）描述，而输出层节点通常由简单的线性函数刻画。隐含层节点的作用函数对输入信号将在局部产生响应，即当输入信号靠近核函数的中央范围时，隐含层节点将产生较大的输出。因此，径向基函数网络是局部逼近网络，具有学习速度快的优点，其基函数常用的是高斯函数，可表示为：

$$\alpha_i(x) = \exp\left[-\frac{\|X - c_i\|^2}{2\sigma_i^2}\right] \quad (1)$$

$$i = 1, 2, \dots, m$$

式中： $\alpha_i(x)$ 为第 i 个隐含层节点的输出； X 为输入样本且 $X = (x_1, x_2, \dots, x_n)^T$ ； c_i 为第 i 个隐含层节点的高

斯核函数的中心且与 X 具有相同的维数； σ_i 为第 i 个隐含层节点的变量，称标准化常数，或基宽度； m 为隐含层的节点数； $\|X - c_i\|$ 是向量 $X - c_i$ 的范数，通常表示 X 和 c_i 之间的距离。

$\alpha_i(x)$ 在 c_i 处有唯一最大值，随着 $\|X - c_i\|$ 的增大， $\alpha_i(x)$ 迅速衰减到零。对于给定的输入 $X \in R^n$ ，只有小部分靠近 X 的中心被激活。

在 RBF 网络中，隐含层的每个节点都有一个径向基函数的中心向量 c_i ，该向量与输入样本有相同的维数， $c_i = [c_{i1}, c_{i2}, \dots, c_{in}]^T$ ， $i = 1, 2, \dots, m$ ，整个网络有 m 个这样的中心。实际上，各隐含层节点的输出表示输入样本 X 离开该隐含层节点的径向基函数中心 c_i 的程度，并不存在一个像其他网络那样联接各输入节点与各隐含层节点的隐含权矩阵。因此，隐含层的训练任务不是调节其权矩阵，而是为了每个隐含节点选择其中心向量。

RBF 网络中的输出层是一组线性组合器。输入层实现从 $X \rightarrow \alpha_i(x)$ 的非线性映射，输出层实现从 $\alpha_i(x) \rightarrow y_k$ 的线性映射，即 RBF 网络的输出为隐含层节点输出的线性组合，有

$$\alpha_i(x) y_k = \sum_{i=1}^m w_{ik} \alpha_i(x) \quad (2)$$

$$k = 1, 2, \dots, p$$

式中： y_k 为输出节点 k 的输出； w_{ik} 为隐含节点 i 与输出节点 k 的连接权值； p 输出层的节点数。

2.2 径向基神经网络的优点

不同于 BP 神经网络，径向基神经网络在学习过程中隐含层的神经元数目是变化的。在训练网络时，通过检查网络的误差来不断调整网络隐含层神经元以及隐含层与输出层间的权值矩阵，直到误差满足要求或达到最大隐含层神经元数。正是径向基函数网络的这种结构自适应特性，使得其输出与初始权值无关。除此之外，虽然要达到同一目的，RBF 网络的神经元个数可能要比 BP 网络的神经元个数多，但是 RBF 网络训练误差收敛要比 BP 网络快，学习时间要少。总而言之，径向基函数网络相比在函数逼近能力、分类能力和学习速度等方面均优于 BP 网络，因而其在预测应用上有一定优势。

3 算例分析

3.1 数据说明

1996—1998年，中国国家电力公司水电规划总院

与美国国家可再生能源实验室联合，对我国东南沿海进行了风能资源评估^[10]。其中给出了上海市崇明东旺沙测风塔小时风速测量结果。东旺沙所在的地理位置：东经纬121°56′，北纬31°31′，海拔高度8m。测风塔高度为50m，分别在50、40和10m高度装设风速计，风速测量起止时间：1998年5月19日——2000年10月20日。

3.2 建立模型

以我国上海崇明东旺沙1998年5月19日-1998年6月19日共31天的每小时风速作为本研究的样本^[15]。每小时风速时间序列指按日历次序逐时记录的风速时间序列，即该风速序列是每隔一小时采样的实际风速值，依据该序列运用径向基神经网络进行建模。该风速时间序列取自50m高处，取其中的前173点数据作为模型的输入样本。前500点风速序列如图2所示。依据这些风速时间序列点，利用RBF神经网络建立风速的预测模型。




Figure 2. Sample wind speed sequence
图 2. 采样风速序列

3.3 输入样本的处理

本文建立 RBF 模型以及 BP 模型的预测目标都是利用一天 24 小时的风速采样来预测紧接其后一个小时的的风速。因此，利用训练好的模型进行预测时，输入数据要随着预测目标作相应的变化，即始终保持输入数据为预测目标的前一天的风速序列。所以要实现其后更多时段的风速预测，模型输入要不断的做滚轮式变化：假设前一次预测输入的风速序列为 $v_1 \dots v_n$ ，可预测出后一时间点风速 v_{n+1} 的预测值 \hat{v}_{n+1} ；而要进行其下一步预测时，输入的风速序列应变成 $v_2 \dots v_{n+1}$ ，此时预测得到输出值 \hat{v}_{n+2} ，即实际风速 v_{n+2} 的预测值。

依此类推，实现整个预测过程的数据滚动处理。即在预测过程中，输入要随着预测目标的变化作相应改变。

3.4 网络结构参数对预测结果的影响

在RBF网络训练中，隐含层的神经元数量的确定是一个关键的问题，直接影响到模型预测结果的好坏。隐含层神经元数目太多，首先会导致网络训练量的增大，网络隐含层神经元越多，网络训练量越大。再有隐含层神经元越多对模型预测结果不一定有利，甚至可能导致预测结果不准确。因此隐含层神经元数一般都依靠经验和试验来确定。径向基函数的分布密度对网络的性能也有一定程度的影响。一般来说，分布密度越小，对函数的逼近就越精确，但是逼近的过程越不平滑；分布密度越大，逼近过程就比较平滑，但是逼近误差就会比较大。因此在设计网络的过程中，同样需要对其分布密度选取做大量测试，以此来保证网络的预测精度。表1给出了网络性能相对较好时不同隐含层神经元数与分布密度组合的200小时预测的平均绝对误差。本文模型中，经过多次试验和筛选，当网络隐含层神经元数为30且分布密度21.8时，网络的预测平均绝对误差为0.7532，网络预测效果很好。

Table 1. The average absolute error of prediction
表 1. 预测平均绝对误差

分布密度	平均绝对误差			
	神经元数 25	30	35	40
20	0.9921	1.9699	2.2478	2.5428
21.8	0.7888	0.7532	1.2669	1.5982
25	1.1431	0.9572	0.9017	0.9149

3.5 预测分析

作为神经网络的一种，RBF 网络能学习到风速间的非线性关系，因此预测效果要优于一般方法。本文中的网络提前 1 小时的风速预测效果如图 3 所示。

图中记录了 RBF 网络对 48 小时风速的预测结果。从图中可以看出，建立的 RBF 网络预测模型基本上能跟随风速的变化，其平均绝对误差为 0.5771 m/s。除此之外，在风速变化剧烈的时段，预测基本上也能跟随风速的变化，而风速变化平缓的时段，预测误差很小。因此该模型有很好的预测效果。

图 4 记录了 BP 神经网络与 RBF 网络的 72 小时风速预测。从图中明显可以看出，相较于 RBF 网络，

BP 网络效果明显要差些, 其平均绝对误差为 0.9580 m/s, 而 RBF 网络的平均绝对误差为 0.7826 m/s, 而且, 在风速变化剧烈的时段, 预测风速跟随风速变化的能力明显不如 RBF 网络, 这就表明 RBF 网络模型的预测性能要优于 BP 网络模型。另外, 可以看出, 随着预测时间的增长, RBF 预测误差有所增加, 这个问题可以对网络再训练来解决, 即利用更新的数据样本重新训练网络, 可一定程度上保证精度。




Figure 3. The forecasting of RBF network
图 3. 径向基网络预测结果




Figure 4. 1 hour ahead forecasting of RBF and BP network
图 4. RBF 和 BP 网络提前 1 小时风速预测结果

4 结论

风速预测的根本目的是增加风电场输出功率的预见性, 对含风电场接入的电力系统调度有重大意义。对基于径向基函数神经网络的风速预测的研究结论有:

- 1) 径向基函数网络具有较强的非线性学习能力, 其训练时间短, 而且预测效果也优于 BP 神经网络。
- 2) 利用实测的风速作为神经网络的输入可一定程度上保证预测精确度。本文利用径向基函数神经网络

建立的模型, 虽然没有考虑其他数值天气预报数据, 诸如风向, 温度, 气压等因素, 但是仍然很好的实现了提前一小时的风速预测。

3) 输入数据变化方式和模型结构都与预测误差很大关系, 适当的改进这两个影响因素能一定程度提高预测精度。

4) 虽然风速的随机性增加了预测的难度, 但是预测精度还有提升空间。综合影响风速的更多因素以及对模型的适当改进将可于进一步提高预测精度。

References (参考文献)

- [1] YANG Xiu-yuan, XIAO Yang, CHEN Shu-yong. Wind Speed and Generated Power Forecasting in Wind Farm[J]. Proceedings of the CSEE, 2005, 25 (11): 1-5(Ch).
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
- [2] FAN Gao-feng, WANG Wei-sheng, LIU Chun, DAI Hui-zhu. Wind Power Prediction Based on Artificial Neural Network[J]. Proceedings of the CSEE, 2008, 28(34):118-123(Ch).
范高锋, 王伟胜, 刘纯, 戴慧珠. 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..
- [3] CAI Kai, TAN Lun-nong, LI Chun-lin, TAO Xue-feng. Short-Term Wind Speed Forecasting Combining Time Series and Neural Network Method [J]. Power System Technology, 2008, 32 (8): 82-85 (Ch).
蔡凯, 谭伦农, 李春林, 陶雪峰. 时间序列与神经网络法相结合的短期风速预测[J]. 电网技术, 2008, 32 (8): 82-85.
- [4] Lexiadis M A, Dokopoulos P, Sahsamanoglou H S et al. Short term forecasting of wind speed and related electrical power[J]. Solar Energy, 1998, 63(1): 61-68.
- [5] Li Jing, Song Jiahua, Wang Weisheng. Modeling and dynamic simulation of variable speed wind turbine with large capacity [J]. Proceedings of the CSEE, 2004, 24(6): 100-105(Ch).
李晶, 宋家骅, 王伟胜. 大型变速恒频风力发电机组建模与仿[J]. 中国电机工程学报, 2004, 24(6): 100-105.
- [6] Kariniotakis G, Stavrakakis G, Nogaret E. Wind power forecasting using advanced neural network models[J]. IEEE Trans Energy Conversion, 1996, 11(4): 762-767.
- [7] Pan Difu, Liu Hui, Li Yanfei. A wind speed forecasting optimization model for wind farms based on time series analysis and kalman filter algorithm[J]. PowerSystemTechnology, 2008, 32(7):82-86(Ch).
潘迪夫, 刘辉, 李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术, 2008, 32(7): 82-86. .
- [8] Andrew Boone. Simulation of short-term wind speed forecast errors using a multi-variate ARMA(1,1) time-series model[D]. Stockholm, Sweden: Royal Institute of Technology, 2005.
- [9] Sun Chunshun, Wang Yaonan, Li Xin ran. A vector auto regression model of hourly wind speed and its application in hourly wind speed forecasting[J]. Proceedings of the CSEE, 2008, 28(14): 112-117(Ch).
孙春顺, 王耀南, 李欣然. 小时风速的向量自回归模型及应用[J]. 中国电机工程学报, 2008, 28(14): 112-117.
- [10] Elliott D, Schwartz M, Scott G, et al. Wind energy resource atlas of southeast china[R]. Golden, Colorado, USA: National Renewable Energy Laboratory, 2002.