

基于 WindPro 数据修正及风电场风速预测研究

张忠伟^{1,2}, 王维庆^{1,2}, 王海云^{1,2}, 姚秀萍³, 常喜强³

(1. 新疆大学电气工程学院, 新疆 乌鲁木齐 830047;

2. 教育部可再生能源发电与并网控制工程技术研究中心, 新疆 乌鲁木齐 830047,

3. 新疆电力调度控制中心, 新疆 乌鲁木齐 830001)

摘要: 根据某风场数据, 先对风场数据进行修正, 剔除错误数据, 以避免累计误差的出现, 提高预测精度。在神经网络的输入变量中不仅考虑了风速风向, 还加入了跟大气运动形成风能的温度、重力常数和海拔。通过对神经网络法的粒子群优化算法(PSO)优化和惯性权重的调整来预测风速, 通过神经网络训练该方法能够提高预测的准确性, 能够改善风电并网的稳定运行和电网调度的调整。

关键词: 数据修正; 神经网络; 粒子群优化算法(PSO); 惯性权重

Abstract: According to the data of a wind field, the wind field data is corrected firstly, and then the wrong data is eliminated in order to avoid the emergence of the accumulated error and to improve the prediction precision. In the input variables of neural network, it not only considers the wind speed and direction, but also the wind temperature, gravitational constant and elevation formed with atmospheric movement. Through optimizing the particle swarm optimization (PSO) of neural network method and adjusting the inertia weight, it can forecast the wind speed, and through the neural network training method it can improve the prediction accuracy, which can improve the stable operation with wind power integration and the adjustment of power grid scheduling.

Key words: data correction; neural network; particle swarm optimization (PSO); inertia weight

中图分类号: TK81 文献标志码: A 文章编号: 1003-6954(2016)06-0018-05

DOI:10.16527/j.cnki.cn51-1315/tm.2016.06.005

0 引言

随着国家对风力发电的投资日益加大, 风电产业的快速发展, 对风力发电的技术和研究也提出了更高的要求^[1-3]。其风速和风电预测对风电并网稳定运行和电力部门根据预测风速做出调整有很大影响^[5]。国外对风电场风速及风电短期预测已经做了大量深入的研究, 当前中国在短期和超短期风速预测的研究还没有成型理论, 特别是 24~72 h 预测较少^[4]。准确风速预测使电网调度能够有效调整电网计划, 并且能够降低电力设备运转成本^[6]。由于风能不是连续存在且受到大气运动强弱影响, 造成风速随机产生^[7-8]。因此对风电场风速的预测就更加困难^[9-13]。当前在运用源数据时并没有对其进行筛选, 误差累积效应可能导致预测准确性降低并在预测过程中没有很好的权重设定。

基金项目: 教育部创新团队(IRT1285); 自治区重点实验室(2016D03021); 国家自然科学基金(2013211A006)

通过某风场 1 年的测风数据, 在数据源头对数据进行修正, 剔除错误数据。并用神经网络对修正后数据训练, 用粒子群优化算法(particle swarm optimization, PSO)对神经网络进行优化, 通过迭代次数对惯性权重进行调整。根据气象预报来预测最近 48 h 风速, 通过和神经网络算法比较优化后, 神经网络算法预测准确性较好。

1 WindPro 软件对测风数据分析

由于测风数据的获取要经过很多环节, 每个环节都有可能产生误差。而采用存在错误的数据进行仿真预测, 无疑会增加预测的不准确性。如果不减少每个环节的误差, 就可能产生误差的积累严重影响对风速的预测。因此必须提高数据的质量, 剔除错误和无效数据。根据 GB/T 18710-2002 标准规定^[14], 合理性检验的小时平均风速在 0~40 m/s, 平均风向在 0~360°。趋势性检验的平均温度变化小

于 5 °C ,平均风速小时变化小于 6 m · s⁻¹ ,平均气压小时变化小于 1 kPa。

2 对测风数据进行修正

取用数据来源于某风场测风塔 70 m 高度 1 年的测风数据 ,风速和风向的观测梯度是 70、60、40、25、10 m。在 10 m 和 40 m 高度配有温度观测器 ,同时在 10 m 高度处还配有气压观测器。所有使用的传感器均通过国内气象部门检测机构的认证。记录每隔 10 min 的风数据 ,由于风数据的获取要经过很多环节 ,每个环节都可能出现偏差或错误 ,出现的偏差可能会对风速的预测产生较大误差甚至会影响到电力部门不能及时采取措施来减轻对电网的影响。因此测风数据的质量检查、修正和剔除错误数据可以有效降低最终的预测结果。WindPro 软件具有测风数据质量检查和剔除数据错误数据的功能 ,可以有效避免错误数据对风速预测产生的误差影响 ,如图 1 所示。




图 1 剔除错误数据后的风速曲线

从图 1 圆圈可以看出将不满足条件的风速剔除 ,对后续的风电场风速预测精度提供了有效保障。

表 1 是将 1 天中每隔 10 min 记录的 144 个数据进行质量检测后统计的有效数据个数 ,可以发现 2015 年 2 月 7 日只有 49 个有效值 ,在 2015 年 8 月 3 日有 137 个有效值 ,与图 1 的风速图形相吻合。通过数据质量检测能够保证数据选择的完整性并初步减少误差避免造成预测不准确性。

通过 WindPro 软件对原始测风数据的质量检测剔除错误的的数据 ,能够提高原始数据的可信度 ,在后续模型建立和神经网络训练中可以有效降低误差并提高测测风速的可信度。

3 神经网络模型

3.1 神经网络法基本原理

表 1 2015 年有效风速表

日	月 份						
	2 月	3 月	4 月	5 月	6 月	7 月	8 月
1	144	144	144	144	144	144	144
2	144	144	144	144	144	144	144
3	144	144	87	144	144	144	137
4	144	144	86	144	144	144	144
5	144	144	84	144	144	144	144
6	144	144	144	144	144	144	144
7	49	144	144	144	144	144	144
8	144	144	144	144	144	144	144
9	144	144	144	144	144	144	144
10	144	144	144	144	144	144	144
11	144	144	144	144	144	144	144
12	144	144	144	144	144	144	144
13	56	144	144	144	144	144	144
14	144	144	144	144	144	144	144
15	144	144	144	144	144	144	144
16	144	144	144	144	144	144	144
17	144	144	144	144	144	144	144
18	144	144	144	144	144	144	144
19	144	144	144	144	144	144	144
20	144	144	144	144	144	144	144
21	144	144	144	144	144	144	144
22	24	144	144	144	144	144	144
23	24	144	144	144	144	144	144
24	24	144	144	144	144	144	144
25	24	144	144	144	144	144	144
26	24	144	144	144	144	144	144
27	24	144	144	144	144	144	144
28	24	144	144	144	144	144	144
29	24	144	144	144	144	144	144
30	24	144	144	144	144	144	144
31		144		144	144		144
有效率	93%	100%	96%	100%	100%	100%	99.8%

神经网络法主要模拟人脑各部分的结构和其功能 ,并且由大量协同简单元件相互作用形成的复杂网络。神经网络可以学习和储存大量的输入 - 输出映射关系 ,并且不需要提前揭示描述输入 - 输出映射关系的数学方程。和数字计算机相比较 ,神经网络在形成原理和效用特点等方面更加类似于人脑 ,它不像数字计算机一步一步地执行运算 ,而是能够自身适应周围环境 ,总结规律 ,完成某种运算。基于人脑处理复杂信息的能力 ,应用多层前馈神经网络 (back propagation artificial neural network ,BP - ANN) 法的风速和风功率预测能够被有效解决。

3.2 神经网络模型结构

这里应用多层前馈神经网络 (BP 神经网络) ,

应用广泛的3层网络结构包含1个输入层、1个隐层和1个输出层。神经元间采用 Sigmoid 函数作为传递函数,然而传统 BP 神经网络算法存在如下缺点:1) 由于固定的学习效率,因此网络的收敛速度较慢,训练的时间相应延长;2) 由于 BP 算法可以使权值收敛到某个特定值,但并不能保证某个特定值为误差平面的最小值,即陷入局部最小。可采用以下方法来提高 BP 算法的性能:1) 在学习过程中采用 L-M 算法;2) 对学习效率进行自我调治;3) 引入自适应粒子群优化算法来提高收敛速度。

3.3 预测模型

神经网络结构如图2所示,结构中采用1个隐层。由于以往采取的输入层变量较为单一,只考虑风速风向,因此在一定程度上降低了预测准确性。为提高预测准确性,所讨论的预测模型中的输入层变量考虑了风速、风向、空气密度。风电机组的输出功率取决于风速及空气密度,其计算如式(1)所示:

$$P_i = \frac{1}{2} C_p \rho_a A_T V^3 \quad (1)$$

式中: P_i 为风力机实际转换的风功率; C_p 为风力机功率系数; A_T 为风轮扫风面积; V 为风速; ρ_a 为空气密度,而空气密度由气压、温度、重力常数、温度传感器的海拔决定;其计算如式(2)所示:

$$\rho_a = \left(\frac{P_0}{RT} \right) e^{\left(\frac{-gz}{RT} \right)} \quad (2)$$

式中: P_0 为用 P_a 表示的标准海平面气压(101 325 Pa); T 为温度(K), $T(K) = T(^\circ C) + 273.15$; g 为重力常数(9.807 m · s⁻²); z 为温度传感器的海拔 m; R 为干燥空气的比气体常数 287.04 J · (kg · K)⁻¹。将 P_0 、 R 和 g 的值代入,则密度如式(3)所示:

$$\rho_a = \left(\frac{353.05}{T} \right) e^{-0.0347 \frac{z}{T}} \quad (3)$$

将由式(3)得出的空气密度当作神经网络输入层的一个输入变量,它能够间接反映气压、海拔和温度的影响,使神经网络的输入更加简便。分别对风速、风向、空气密度进行归一化处理。

1) 风速归一化,选取1年统计中的最大风速对风速归一化,如式(4)所示:

$$V_n = \frac{V_i}{V_{\max}} \quad (4)$$

式中: V_n 为归一化后的风速; V_i 为测风塔观测的风速值; V_{\max} 为测风塔观测的最大风速。

2) 风向归一化,认为是水平方向的风,把各个风向分成不同的扇区即把风速的水平面看成圆,分为12个扇区,规定正北方向是0°。为了区分风向,

引入正弦和余弦值作为输入。

3) 温度、气压、海拔通过式(3)的整合看作为空气密度的归一化,与风速的归一化方法类似,取最大空气密度对空气密度归一化。神经网络结构模型如图2所示。




图2 3层BP神经网络结构图

这里隐层函数选择 logsig 函数,输出层选择 purelin 函数,这样可以保证较高的预测精度。在学习过程中采用 L-M 算法使其具有较高的收敛速度。

3.4 粒子群算法(PSO)及优化

粒子群算法简单可靠,训练时间相对较短,收敛速度比较快,设置参数少,已成为现代优化算法领域研究的热点,故通过其方法来寻求最优风速解。PSO 基于信息的社会共享,通过初始化产生一群随机粒子,通过每一次迭代来找到最优解。它假设每个粒子都有记忆所搜寻的最佳位置的信息,并且每个粒子都具有速度来决定飞行的距离和方向,速度能够根据自身的经验进行调整。其数学思想为:设 D 维空间中,有 N 个粒子,第 i 个粒子的位置为 $X_i = (X_{i1}, X_{i2}, \dots, X_{id})$; 第 i 个粒子速度 $V_i = (V_{i1}, V_{i2}, \dots, V_{id})$; 其中粒子 i 经历过的最好位置为 $p_{\text{best}_i} = (p_{i1}, p_{i2}, \dots, p_{id})$,种群经历过的最好位置为 $g_{\text{best}_i} = (g_{i1}, g_{i2}, \dots, g_{id})$; 粒子 i 的第 D 维速度和位置更新公式分别为式(5)和式(6)。

$$V_{id}^k = \omega V_{id}^{k-1} + c_1 r_1 (p_{\text{best}_{id}} - X_{id}^{k-1}) + c_2 r_2 (g_{\text{best}_{id}} - X_{id}^{k-1}) \quad (5)$$

$$X_{id}^k = X_{id}^{k-1} + V_{id}^k \quad (6)$$

式中: V_{id}^k 为第 k 次迭代粒子 i 飞行速度矢量的第 d 维分量; X_{id}^k 为第 k 次迭代粒子 i 位置矢量的第 d 维分量; c_1 、 c_2 为加速度常数,调节学习最大步长; r_1 、 r_2 为2个随机函数,取值范围 [0, 1],以增加搜索随机性; ω 为惯性权重,非负数,调节对解空间的搜索范围。

算法过程如下:

1) 设定粒子群的群体数目,多数情况下10个

粒子已经能够取得较好的结果,因此这里选取 10 个种群粒子数,并对粒子随机定义位置和速度。

2) 评价每个粒子的自适应度 $c_1 = c_2 = 2$, $\omega_{\max} = 0.9$, $\omega_{\min} = 0.3$ 。

3) 较大的 ω 有较好的全局收敛能力;较小的 ω 则有较强的局部收敛能力;因此,随着迭代次数的增加,惯性权重应不断减少,从而使得粒子群算法在初期具有较强的全局收敛能力,而晚期具有较强的局部收敛能力。可由式(7)不断地调整惯性权重。

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \times \frac{run}{run_{\max}} \quad (7)$$

式中: ω_{\max} 为最大惯性权重; ω_{\min} 为最小惯性权重; run 为当前迭代次数; run_{\max} 为算法迭代总次数。

4) 对每个粒子,对比当前适应值与个体历史最佳位置适应值(p_{best}),更新适应值较高的作为历史最佳位置(p_{best})。再对比当前适应值与全局最佳位置(g_{best})适应值,更新适应值较高的作为全局最佳位置(g_{best})。

5) 根据公式更新每个粒子的速度与位置。当没有达到粒子群迭代次数或达到可以接受的满意则返回步骤 2),直到算法停止。

3.5 仿真结果及分析

通过对实测值修正、神经网络法优化和惯性权重的调整来提高预测精度。对神经网络法和优化后神经网络法进行对比研究。仿真结果如图 3 可见,整体 BP 模型预测值和实际值存在较大误差,并在 4 m/s 风速时误差较为明显,最高时误差达到 17%,而经过 PSO 算法优化后的模型具有较好的预测准确度,在 4 m/s 和 8 m/s 风速时和实际值误差较小,误差稳定性好,具有很好的参考性。




图 3 预测误差比较

选择预测风速的绝对平均误差 E_{MAE} 和预测风速的均方根误差 E_{RMSE} ,通过式(8)和式(9)来评估风速预测的效果。

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{V}_i - V_i|}{V_i} \times 100\% \quad (8)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \frac{(\hat{V}_i - V_i)^2}{V_i}} \times 100\% \quad (9)$$

式中: \hat{V}_i 为预测风速; V_i 为实测风速。对比神经网络和优化后的神经网络,预测误差如表 2 所示。

表 2 风速预测误差效果

模型	$E_{MAE}/\%$	$E_{RMSE}/\%$
BP 神经网络	12.43	15.87
POS 优化后	10.54	14.49

从表 2 中可以看出,与 BP 神经网络算法相比,经过优化后的 BP 神经网络模型的预测准确度明显更高,这是由于 BP 神经网络容易陷入局部最小造成的,而经过优化后的 BP 神经网络模型通过迭代次数不断调整惯性权重 ω ,有效避免了局部最小并且提高了收敛效率。

4 结 语

提出通过修正测风数据来减少累计误差,并在网络的输入变量中考虑形成风能的温度、海拔和重力常数。使用粒子群优化算法(PSO)优化神经网络,并在网络训练中通过迭代次数对惯性权重进行调整来提高收敛速度,避免陷入局部最小。由于只采用了 1 年的风数据资源,在数据集上对网络训练可能还不完善,造成预测上可能还是存在些许偏差。

参考文献

- [1] 罗文,王莉娜. 风场短期风速预测研究[J]. 电工技术学报, 2011(7): 68-74.
- [2] 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.
- [3] 杨锡运,孙宝君,张新房,等. 基于相似数据的支持向量机短期风速预测仿真研究[J]. 中国电机工程学报, 2012, 32(4): 35-41.
- [4] Costa A, Crespo A, Navarro J, et al. A Review on the Young History of the Wind Power Short-term Prediction [J]. Renewable and Sustainable Energy Reviews, 2008, 12(6): 1725-1744.
- [5] 戴浪,黄守道,黄科元,等. 风电场风速的神经网络组合预测模型[J]. 电力系统及其自动化学报, 2011(4): 27-31.
- [6] 范高锋,王伟胜,刘纯,等. 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.
- [7] 李莉,刘永前,杨勇平,等. 基于 CFD 流场预计算的短期风速预测方法[J]. 中国电机工程学报, 2013, 33(7): 27-32.

[8] 孙国强,卫志农,翟玮星. 基于 RVM 与 ARMA 误差校正的短期风速预测[J]. 电工技术学报, 2012(8): 187-193.

[9] Joaquin Quinonero - Candela, Lars Kai Hansen. Time Series Prediction Based on the Relevance Vector Machine with Adaptive Kernels[C]. IEEE International Conference on Acoustics, Speech, and Signal Processing, Hong Kong, China, 2002: 985-988.

[10] 王有禄,李淑华,宋飞. 风电场测风数据的验证和处理方法[J]. 电力勘测设计, 2009(1): 60-66.

[11] 张国强,张伯明. 基于组合预测的风电场风速及风电

机功率预测[J]. 电力系统自动化, 2009, 33(18): 92-95.

[12] 卿湘运,杨富文,王行愚. 采用贝叶斯-克里金-卡尔曼模型的多风电场风速短期预测[J]. 中国电机工程学报, 2012, 32(35): 107-114.

[13] 杜颖,卢继平,李青,等. 基于最小二乘支持向量机的风电场短期风速预测[J]. 电网技术, 2008, 32(15): 62-66.

[14] 邵璠,孙育河,梁岚珍. 基于 ARMA 模型的风电场风速短期预测[J]. 电网与清洁能源, 2008(7): 52-55.

(收稿日期: 2016-08-20)

(上接第 13 页)

参考文献

6 结 论

1) 电网故障下,由于定子磁链不能突变,产生由定子电阻和电感决定的时间常数衰减的暂态直流分量,并在最后衰减到 0。该分量会在转子中感应转子反电动势,影响转子的暂态特性。

2) 考虑电机的暂态过程及变换器控制作用下的转子短路电流成份,其中转子电流分量分别为转子电流参考值决定的周期分量;转子电流对反电动势的响应,大小由反电动势的值决定,即受到电压跌落程度的影响;转子电流的自然分量与变换器的控制参数有关。

3) 双馈风电机组定子短路电流分量可以通过定子磁链及转子电流表示,其中周期分量与定子磁链的周期分量相对应,与 DFIG 初始状态无关;直流暂态分量与定子磁链的直流暂态分量相对应,DFIG 故障下定子电压跌落越严重,该直流暂态分量越大;转子电流分量暂态特性受转子侧变换器控制影响,若转子侧变换器的闭环控制带宽足够大,转子侧变换器提供的励磁电压能够很好地跟随指令值,在变换器响应时间足够快的情况下,转子电流周期分量可以近似地认为是参考值。

4) 考虑到双馈风机自身结构及变换器复杂的控制策略问题,DFIG 在电网发生故障的情况下提供的故障电流明显异于同步发电机,其大规模并网的情况下,提供的短路电流会对电网的电气量变化特性产生较为复杂的影响,因此双馈风机故障电流特性的分析对以故障特征为基础的继电保护研究具有重要的现实意义。

[1] 欧阳金鑫,熊小伏. 计及转子励磁控制的双馈感应发电机短路电流研究[J]. 中国电机工程学报, 2014, 34(34): 6083-6092.

[2] Ouyang J, Xiong X, Zeng X X. Analysis and Evaluation of Short-circuit Current of Doubly Fed Induction Generation under Rotor Excitation Control[J]. Journal of Renewable & Sustainable Energy, 2014, 6(5): 158-166.

[3] 金晶. 双馈风电机组转子变流器对短路特性的影响研究[D]. 重庆: 重庆大学, 2012.

[4] Kong X, Zhang Z, Yin X, et al. Study of Fault Current Characteristics of the DFIG Considering Dynamic Response of the RSC[J]. IEEE Transactions on Energy Conversion, 2014, 29(2): 278-287.

[5] 孔祥平,张哲,尹项根,等. 计及励磁调节特性影响的双馈风力发电机组故障电流特性[J]. 电工技术学报, 2014, 29(4): 256-265.

[6] X Kong, Z Zhang, X Yin, et al. Study on Fault Current of DFIG during Slight Fault Condition[J]. Telkomnika Indonesian Journal of Electrical Engineering, 2013, 11(4): 2221-2230.

[7] 熊小伏,欧阳金鑫. 电网短路时双馈感应发电机转子电流的分析与计算[J]. 中国电机工程学报, 2012, 32(28): 114-121.

[8] 郑涛,魏占朋,迟永宁,等. 考虑撬棒保护动作时间的双馈式风电机组短路电流特性[J]. 电力系统自动化, 2014, 38(5): 25-30.

[9] 柳鑫,刘晓华,吕文芳,等. 考虑撬棒保护动作的双馈风机故障暂态特性分析[J]. 电力科学与工程, 2016, 32(1): 49-52.

作者简介:

柳鑫(1984), 研究生, 研究方向为风电在电力系统中的应用。

(收稿日期: 2016-09-05)