

文章编号:1005-0523(2013)05-0081-06

风电场短期功率组合预测模型研究

徐晓玲¹, 郑 潇²

(1. 华东交通大学电气与电子工程学院, 江西 南昌 330013; 2. 江西省电力公司检修分公司, 江西 南昌 330029)

摘要: 由于风能的间歇性, 电网调度与运行一定程度上将依赖于对风电场短期输出功率的准确预测。利用某风电场输出功率 14 d 的历史数据建立 3 种单项预测模型, 对未来 36 h 的短期功率进行预测。基于 3 种单项预测方法的结果, 提出了 3 种组合预测模型: 熵值法组合预测模型、以预测误差平方和最小的线性组合预测模型、基于诱导有序集结算子(IOWA 算子)的组合预测模型。通过实例分析, 3 种组合预测模型有效结合了各单项预测模型的信息, 均能取得较理想的效果。其中, 基于 IOWA 算子的组合预测模型为所有 6 种预测方法中的最优。

关键词: 风电场; 自回归-滑动平均模型; 人工神经网络; 组合预测; 诱导有序信息集结算子

中图分类号: TM614

文献标志码: A

中国大陆 2011 年全年风电装机容量新增 17.63 GW, 累计装机容量 62.36 GW, 位居全球风电装机总容量第 1 位。然而, 随着国家政策不断倾斜、市场日渐规范, 风电并网的速度不断加快, 累计并网容量达到了 47.84 GW, 但是风力发电并网本身具有的技术性难题依然存在, 2011 年风电累计“弃风”超过 100 亿 kWh^[1]。

对风电场短期功率进行预测有利于电网的经济调度, 这可以减少电网备用容量, 有效降低电力系统的运行成本, 提高效益。根据风电场短期功率的预测结果, 相关调度与运行部门可采取一定措施增强系统的安全性、可靠性和可控性。2011 年, 国家发布《风电场接入电力系统技术规定》明确规定: 风电场应配置使用相应的风电功率预测系统, 此系统应具有 0 ~ 72 h 短期风电功率预测以及 15 min ~ 4 h 超短期风电功率预测功能^[2]。

目前, 国内大部分对风电场短期功率预测还停留在理论阶段, 一般预测的误差大部分在 15%~40% 之间。如何研究新的预测技术, 提高预测精度, 并以理论研究尽快开发出适合实际现场应用的预报系统, 是目前国内风电预测领域需要解决的主要问题。

1 时间序列预测方法

时间序列分析方法^[3]广泛地应用于不同领域的实际问题处理中。构造风电场风速或发电功率历史数据的时间序列, 运用时间序列分析建立预测模型是目前进行风电短期功率预测的有效方法。

时间序列模型是从统计角度来揭示各种时间序列内部的统计关系与各时间序列之间的统计关系。风电功率预测一般采用均方误差(mean square error, MSE), 均方根误差(root mean square error, RMSE), 平均绝对百分比误差(mean absolute percentage error, MAPE)^[4-7]来评价模型的精确度及有效性。

建立时间序列预测模型的一般步骤^[8]如图 1 所示, 首先根据风电场历史功率数据建立时间序列 $\{P_t\} = \{P_1, P_2, \dots, P_n\}$, P_t 为 t 时刻风电场的输出功率值。建立预测模型应对数据进行预处理与自相关分析,

收稿日期: 2013-07-25

作者简介: 徐晓玲(1962—), 女, 副教授, 研究方向为电力系统新能源技术。

判断时间序列是否为平稳时间序列。对于非平稳序列,一般对其进行差分运算,经差分之后形成平稳时间序列之后再行建模。对时间序列的自相关函数和偏自相关函数^[4]的分析可以进行模型识别,而后利用最小信息准则 (akaike information criterion, AIC) 进行模型定阶,利用最小二乘估计迭代求解模型参数^[6]。得时间序列的自回归-移动平均混合模型 (autoregressive and moving average, AR-MA) 如下:

$$P_t = \varphi_1 P_{t-1} + \varphi_2 P_{t-2} + \cdots + \varphi_p P_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \cdots - \theta_q e_{t-q} \quad (1)$$

式中: p, q 分别是自回归与移动平均模型的阶数; $\varphi_1, \varphi_2, \varphi_p$ 是自回归模型的参数; $\theta_1, \theta_2, \theta_q$ 是移动平均模型的参数; e_t 表示预测模型在 t 时刻的预测误差; P_t 为 t 时刻的 AR-MA 模型。

所得模型记为 $A(p, q)$, 如为差分后的序列, 则原序列模型可记为 $I(p, q)$ 。

2 人工神经网络预测方法

利用人工神经网络 (ANN) 技术对时间序列进行预测则是一种非参数预测方法, 它不需要提前进行数据处理及相关分析, 在工程应用上比参数预测方法有更广的应用范围^[9-10]。

目前, 国内外应用人工神经网络对风速或风电场功率进行预测, 设计神经网络的方法不同, 采用的神经网络模型也不尽相同。目前大部分应用于风速及风电功率预测的模型还是误差反向传播 (back propagation, BP) 神经网络与径向基函数 (radial basis function, RBF) 神经网络^[11-14]。

2.1 BP 人工神经网络^[12]

BP 人工神经网络共有 3 层: 输入层、隐含层和输出层。信息正向传播时, 输入样本从输入层传入神经网络, 经各隐层处理完成后, 信息传入输出层。比对输出层的实际输出与期望输出, 如果两者误差较大, 则转入误差反向传播过程。误差反向传播过程中, 网络将输出误差通过隐含层向输入层逐层反传, 并将误差依据一定准则分配给各层所有神经元, 从而获得各神经元的误差值, 然后依据此误差值修正各单元权值, 可通过调整权值来改变误差, 以误差函数最小化为目标函数, 进行权值调整。这种信号正向传播和误差反向传播将一直进行到网络实际输出与期望输出之间的误差减少到可以接受的程度, 或进行到预先设定的训练次数为止。

2.2 广义 RBF 人工神经网络^[15]

RBF 神经网络没有输入层, 使用高斯函数作为基函数, 隐含层适当变换输入矢量, 将低维的模式输入数据变换映射到高维空间内, 利用在高维空间的高灵敏度使在低维空间内的线性不可分的问题在高维空间内变得线性可分。一般的, 广义 RBF 网络的“基函数”大部分也为高斯函数,

3 组合预测方法

由于各种单项预测方法利用的信息不尽相同, 在进行预测的过程中, 如果仅仅因为某个单项预测方法

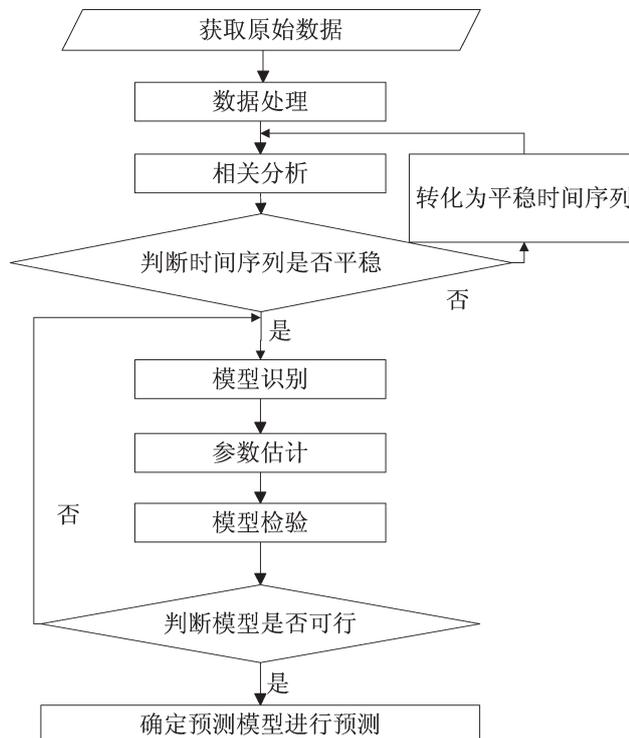


图1 时间序列分析预测流程
Fig.1 Time series forecasting process

预测误差较大便将其排除在外,可能会导致部分有用的信息丢失。

1969年,Bates和Granger提出把不同的单项预测模型结合起来,综合利用各种预测模型的有效信息,以适当的加权平均形式得出组合预测模型^[16]。组合预测以充分利用各单项预测方法已知信息为基础,提取并依据各单项预测方法中的有用信息指导进行组合。

3.1 熵值法组合预测

熵值是系统无序程度或混乱程度的度量,信息被解释为系统无序程度的减少,信息表现为系统的某项指标的变异性。

假设存在 m 种单项预测模型,第 i 种预测模型 t 时刻的预测值为 P_{it} ,第 i 种预测模型 t 时刻的预测误差为 $e_{it}=(P_t - P_{it})$ 。用熵值法确定组合预测权系数的计算步骤如下:

第1步:计算第 i 种单项预测方法第 t 时刻的预测相对误差占总相对误差的比重 $x_{it} = \frac{e_{it}}{\sum_{i=1}^m e_{it}}$,

$i=1,2,\dots,m$ 。

第2步:计算第 i 种单项预测方法的预测相对误差的熵值 $h_i = -k \sum_{i=1}^m x_{it} \ln x_{it}$ 。

第3步:计算第 i 种单项预测方法的预测相对误差序列的变异程度系数 $d_i = 1 - h_i$ 。

第4步:通过下式计算各种预测方法在组合预测中的加权系数 $l_i = \frac{1}{m-1} (1 - \frac{d_i}{\sum_{i=1}^m d_i})$ 。

第5步:得到组合预测模型,计算组合预测值

$$\hat{P}_t = \sum_{i=1}^m l_i P_{it} \tag{2}$$

3.2 以预测误差平方和达到最小的线性组合预测^[17-18]

组合预测模型预测误差的平方和 $J(M) = \sum_{t=1}^N e_t^2 = \sum_{t=1}^N \sum_{i=1}^m \sum_{j=1}^m l_i l_j e_{it} e_{jt}$,由此可得以预测误差平方和为准则的线性组合预测模型为下列最优化问题:

$$\min J_1 = \sum_{t=1}^N \sum_{i=1}^m \sum_{j=1}^m l_i l_j e_{it} e_{jt} \quad \text{s.t.} \begin{cases} \sum_{i=1}^m l_i = 1 \\ l_i \geq 0 \end{cases} \quad i=1,2,\dots,m \tag{3}$$

式中: J_1 为最优模型; l_i, l_j 为加权系数; e_i, e_{it}, e_{jt} 为预测误差; $J(M)$ 预测误差平方和。

以误差平方和最小为准则的组合预测模型应用于风速及风功率预测的实例比较多。该模型有明确的组合准则并构建了合理的目标函数。相关研究证明,该模型大部分都取得了较理想的预测效果^[17-18]。

3.3 基于诱导有序信息集结算子的组合预测

现有传统的组合预测方法是按单项预测方法的不同权系数,同一个单项预测方法在样本区间上各个时点的权系数是不变的。然而在不同时刻,不同的单项预测方法的效果也不尽相同,现有的组合预测方法并不能完全达到最优。组合预测的实质就是一种信息的有效集成,为此可引入诱导有序集结算子^[19-20],通过各单项预测方法各个时点的预测精度的高低按顺序赋权建立组合预测模型。

令 $a_{it} = \begin{cases} 1 - |(P_t - P_{it})/P_t|, & \text{当 } |(P_t - P_{it})/P_t| < 1 \text{ 时} \\ 0, & \text{当 } |(P_t - P_{it})/P_t| \geq 1 \text{ 时} \end{cases}$,则可 a_{it} 表示第 i 种预测方法第 t 时刻的预测精度。以预

测精度 a_{it} 作为预测值 P_{it} 的诱导值,预测精度与预测值构成了二维数组 $(\langle a_{1t}, P_{1t} \rangle, \langle a_{2t}, P_{2t} \rangle, \dots, \langle a_{mt}, P_{mt} \rangle)$,将第 t 时刻预测精度序列 $a_{1t}, a_{2t}, \dots, a_{mt}$ 按从大到小顺序排列,以 I 作为第 i 个大的预测精度的下标;以 J 作为

第 j 个大的预测精度的下标。令组合预测值 $I_L(\langle a_{1t}, P_{1t} \rangle, \langle a_{2t}, P_{2t} \rangle, \dots, \langle a_{mt}, P_{mt} \rangle) = \sum_{i=1}^m l_i P_i$, I_L 称为 $a_{1t}, a_{2t}, \dots, a_{mt}$ 所产生的 m 维诱导有序加权算术平均算子, 简称为 IOWA 算子, a_{it} 称为 p_{it} 的诱导值。令 $e_i = P_i - P_t$, 组合预测误差平方和 $S = \sum_{i=1}^N (P_i - \sum_{i=1}^m l_i P_i)^2 = \sum_{i=1}^m \sum_{j=1}^m l_i l_j (\sum_{i=1}^N e_i e_j)$ 。

组合预测模型可表示成如下最优化模型

$$\min S(L) = \sum_{i=1}^m \sum_{j=1}^m l_i l_j (\sum_{i=1}^N e_i e_j) \quad \text{s.t.} \begin{cases} \sum_{i=1}^m l_i = 1 \\ l_i \geq 0, i = 1, 2, \dots, m \end{cases} \quad (4)$$

基于 IOWA 组合预测值为

$$I_L(\langle a_{1t}, P_{1t} \rangle, \langle a_{2t}, P_{2t} \rangle, \dots, \langle a_{mt}, P_{mt} \rangle) = \sum_{i=1}^m l_i^* P_i \quad (5)$$

各单项预测方法已预测了 n 期数据, 在预测区间 $[n+1, n+2, \dots]$ 上的预测精度序列 $a_{1t}, a_{2t}, \dots, a_{mt}$ 的大小是根据各个单项预测方法在样本空间上近几期拟合平均精度的高低, 即若要进行未来 k 步的预测, 用第 i 种方法最近 k 期拟合的平均精度来反映预测区间 $n+k$ 期的预测精度。

4 实例分析

采用某风电场 12 月 11 日至 24 日 14 d 的小时平均功率共 336 个实测数据。以前 300 h 的数据建立预测模型, 对该风电场未来 36 h 的功率进行预测。

4.1 单项预测模型

4.1.1 时间序列预测模型

以 AIC 准则确定差分处理之后的确风电场功率时间序列 $A(p, q)$ 模型的阶数 $p=3, q=8$ 。故可初步将差分后时间序列定为差分后的 $A(3, 8)$ 模型, 即差分前为 $A(3, 1, 8)$ 模型。然后对模型参数进行最小二乘估计, 迭代确定模型参数。预测模型的阶数与相关参数确定之后, 代入式(1)可得到最终的预测模型

$$P_{1t} = -0.701P_{1t-1} + 0.352P_{1t-2} + 0.427P_{1t-3} + e_{1t} + 0.586e_{1t-1} - 0.069e_{1t-2} - 0.521e_{1t-3} + 0.092e_{1t-4} + 0.133e_{1t-5} + 0.015e_{1t-6} + 0.256e_{1t-7} + 0.022e_{1t-8}$$

利用得到的预测模型对未来 36 h 该风电场的输出功率进行预测, 得到预测值。平均绝对百分比误差为 14.37%, 均方根误差为 2 377.056 kW。

4.1.2 BP 神经网络预测模型

对所有历史数据进行归一化处理, 将所有数据都转化至 $[0, 1]$ 区间内。由风电场功率时间序列的相关分析, 知道有 11 个自相关系数与零有显著差异, 故可由前 11 个风功率数据 $P_{2t-11}, P_{2t-10}, \dots, P_{2t-1}$ 预测第 12 个数据 P_{2t} , 输入向量为 11 个。经过 90 次训练, 网络学习完毕。平均绝对百分比误差为 10.05%, 均方根误差为 1 841.78 kW。可见其预测精度明显优于时间序列 ARMA 模型, 效果比较理想。

4.1.3 广义 RBF 神经网络预测模型

广义 RBF 神经网络输入样本也为 11, 预测模型的平均绝对百分比误差为 19.5%, 均方根误差为 3 003.7 kW, 误差在可接受的范围内。广义 RBF 神经网络虽然训练速度快, 但是预测误差与 BP 网络相比显得更大。

4.2 组合预测模型

4.2.1 熵值法组合预测模型

由 3.1 的步骤可计算熵值法组合预测模型预测值

$$\hat{P}_t = l_1 P_{1t} + l_2 P_{2t} + l_3 P_{3t} = 0.331P_{1t} + 0.335P_{2t} + 0.334P_{3t}$$

熵值法短期功率组合预测模型平均绝对百分比误差为 11.19%, 均方根误差为 1 732.09 kW。

4.2.2 以预测误差平方和达到最小的线性组合预测模型

求解与此组合预测模型等价的最优化模型式(3),求解可得 $l_1=0.3056, l_2=0.5937, l_3=0.1007$ 。组合预测模型可表示为 $\hat{P}_t = l_1 P_{1t} + l_2 P_{2t} + l_3 P_{3t} = 0.3056 P_{1t} + 0.5937 P_{2t} + 0.1007 P_{3t}$ 。

以预测误差平方和最小的线性组合预测模型的平均绝对百分比误差为 9.42%,均方根误差为 1 059.45 kW,两项指标均为单项模型的最优,且比熵值法组合预测模型更为理想。

4.2.3 基于IOWA算子的风电场短期功率组合预测模型

根据式(4),建立与该组合预测模型等价的二次规划模型,求解,可得 $l_1^*=0.753, l_2^*=0.247, l_3^*=0$ 。由解得的最优权系数可知,在 t 时刻,预测精度最差的一种单项组合预测模型为冗余预测方法,其权系数为 0。而后根据式(5),可得基于 IOWA 算子的风电场功率组合预测模型表达式为

$$P_t = l_1^* P_{1t} + l_2^* P_{2t} + l_3^* P_{3t} = 0.753 P_{4t} + 0.247 P_{5t}$$

式中: l^* 为最优权系数。

基于 IOWA 算子的组合预测模型的平均绝对百分比误差为 6.18% 和 745.47 kW,均明显优于前两项组合预测模型及 3 项单项预测模型。其结果优于以预测误差平方和最小的组合预测模型也表明,时变的组合预测模型参数能更有效地结合各单项预测方法的信息,进一步提高预测的精度。3 种组合预测模型与单项预测模型的预测性能见表 1。

表 1 六种预测模型性能比较
Tab.1 Comparison of six forecasting models

性能	时间序列预测	BP神经网络预测	广义RBF神经网络预测	熵值法组合预测	基于误差平方和最小组合预测	基于IOWA算子组合预测
平均绝对百分比误差/%	14.37	11.06	19.5	11.19	9.42	6.18
均方根误差/kW	2 377.056	1 908.10	3 003.7	1 732.09	1 059.45	745.47

根据预测结果可知,基于 IOWA 算子的组合预测模型为 6 种模型的最优。

5 结论与展望

根据预测结果可知,基于 IOWA 算子的组合预测模型能有效提取各单项预测模型的有用信息,并以实际拟合精度作为权重的依据,预测结果为 6 种模型的最优。

在多步预测中,时间序列预测模型是固定不变的,在预测的后期可能不能准确地反映时间序列模型的内在规律。建立时变参数的时间序列模型可提高模型的拟合效果与适用性。但这些方法步骤繁琐,求解困难,还需进一步简化与深入研究。

组合预测模型目前在风电场风速和功率预测中并没有得到太多的应用,相关研究也停留在初步的理论阶段上。未来可以根据实际需要建立多准则(即多目标函数)的组合预测模型。另外在组合预测赋权的过程中,可以参照本文使用诱导有序信息集结算子的思想,探索更多的有序赋权方法。在组合方式上,也可对非线性组合模型进行更多的研究。

参考文献:

- [1] 李俊峰. 中国风电发展报告 2012[M]. 北京:中国环境科学出版社,2012:9.
- [2] 国家电网. GB/T 19963-2011 风电场接入电力系统技术规定[S]. 北京:国家电网公司,2009.
- [3] BOX G E P. 时间序列分析:预测与控制[M]. 顾岚,译. 北京:中国统计出版社,1997:9.

- [4] 孙明玺. 实用预测方法与案例分析[M]. 北京:科学技术文献出版社, 1993:6.
- [5] ALEXANDRE COSTA, ANTONIO CRESPO, JORGE NAVARRO. A review on the young history of the wind power short-term prediction[J]. *Renewable and Sustainable Energy Reviews*, 2008(12):1725-1744.
- [6] 张臻. 风电功率短期预测方法研究[D]. 广州:华南理工大学硕士论文, 2010.
- [7] 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.
- [8] 张仲斐, 赵一飞. 基于ARIMA模型的全球跨国快递业务量预测[J]. *华东交通大学学报*, 2012, 29(1):102-107.
- [9] SFETSOS A. A comparison of various forecasting techniques applied to mean hourly wind speed time series[J]. *Renewable Energy*, 2000(21):23-35.
- [10] 韩爽. 风电场功率短期预测方法研究[D]. 北京:华北电力大学, 2008.
- [11] KARINIOTAKIS G, STAVRAKAKIS G, NOGARET E. Wind power forecasting using advanced neural network models[J]. *IEEE Trans Energy Conversion*, 1996, 11(4):762-767.
- [12] 杨刚, 陈鸣. 基于BP神经网络的风速预测和风能发电潜力分析[J]. *华东电力*, 2010, 38(2):304-309.
- [13] 蔡凯, 谭伦农, 李春林, 等. 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):82-90.
- [14] GONG LI, JING SHI. On comparing three artificial neural networks for wind speed forecasting[J]. *Applied Energy*, 2010, 87:2313-2320.
- [15] 孟莎莎, 孙宝华, 杨辉, 等. 径向基神经网络辨识非线性系统的改进算法[J]. *华东交通大学学报*, 2009, 26(3):37-41.
- [16] BATES J M, GRANGER C W J. The Combination of Forecasts[J]. *Operational Research Quarterly*, 1969, 20(4):451-468.
- [17] 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.
- [18] 刘纯, 范高峰, 王伟胜, 等. 风电场输出功率的组合预测模型[J]. *电网技术*, 2009, 33(13):74-79.
- [19] YAGER R R. On ordered weighted averaging aggregation operators in multicriteria decisionmaking[J]. *IEEE Transactions on Systems Man and Cybernetics*, 1988, 18:183-190.
- [20] 陈华友. 组合预测方法有效性理论及其应用[M]. 北京:科学出版社, 2008:2.

Combination Forecast Model of Short-term Power Output in Wind Farms

Xu Xiaoling¹, Zheng Xiao²

(1. School of Electrical & Electronic Engineering, East China Jiaotong University, Nanchang 330013, China; 2. Maintenance Branch Company of Jiangxi Power Company, Nanchang 330029, China)

Abstract: Owing to the intermittent of wind power, power grid scheduling and operating will largely depend on accurate forecasts of the wind farm's output power. Three single forecasting models using 14 days' historical data of a wind farm were established to predict the following 36 hours output power. Based on the results of three single forecasting models, another three combined forecasting models were proposed: entropy combined forecasting model, minimum squared error linear combined forecasting model and the combined forecasting model based on the IOWA operator. Through case analysis, three combined forecasting models achieved ideal effects by combining individual information of single models. The research found the combined forecasting model based on the IOWA operator got the best result among six models.

Key words: wind farm; ARMA model; ANN; combined forecasting model; IOWA operator