

基于时空相关性的NAR动态神经网络风功率超短期组合预测

黄 慧^{1,2}, 贾 嵘¹, 董开松³

(1. 西安理工大学水利水电学院, 西安 710048; 2. 华北水利水电大学电力学院, 郑州 450011; 3. 国网甘肃电科院, 兰州 730000)

摘 要: 考虑风电场机组空间分布的相关性, 提出基于动态时间序列神经网络(NAR)的风电场超短期功率组合预测方法。首先利用经验函数正交分解(EOF)解析风电机组出力特征的空间相关性, 并依据空间特征贡献率对风电机组进行分组; 其次针对机组的原始功率时间序列均值建立 NAR 预测模型, 进而对风电功率预测结果组合加总获取整个风电场功率预测值。以中国北方某地区风电场实例验证, 与单一风功率序列 NAR 预测模型和 ARMA(2, 2) 模型相比, 预测结果验证了文中所提方法的有效性。

关键词: 空间分布; 时间序列; 风电功率; 组合预测; NAR 神经网络

中图分类号: TM614

文献标志码: A

0 引 言

风电功率预测方法常见有基于数值预报(NWP)的物理方法^[1-2]和基于历史数据建模的统计方法^[3-5]2 大类型。当前物理方法和统计学方法日益成熟, 在这 2 种方法基础上, 考虑空间相关性来改进预测精度成为未来风电功率预测的主要研究方向之一^[6-10]。文献[10]给出了基于空间相关性的风电功率预测的定义、概念以及基本特点, 并全面阐述了基于空间相关性改进风功率预测的方法和未来的研究方向。文献[11]基于风电场周边测风站点的风速数据, 分析其风速的相关性, 并考虑风向的影响, 建立精确的分风向空间相关模型, 以预测未来数小时的风速均值。

目前基于空间相关性的研究大多是考虑不同风电场地理位置、风电场地形数据、风向、粗糙度、温度、气压等因素引起风速的变化^[11-14]。直接从空间相关性对一个风电场不同风电机组出力特性影响这个层面分析的文献尚鲜见。基于风电场内不同风电机组出力特征的空间相关性, 本文首先采用经验正交函数(EOF)对历史风电机组功率数据进行分解, 分析不同风电机组出力特征的空间相关性, 依照空间特征贡献率把风电场机组进行分类; 其次, 基于机组出力的时间相关性, 利用神经网络

动态时间序列(NAR)建立预测模型。与以往空间相关性研究文献相比, 本文考虑风电场内不同机组由于空间位置的不同, 引起风电机组出力的差异。以中国北方某风电场的实测数据验证, 基于 EOF 分解的分组 NAR 模型预测比单一模型预测具有更高的精度。

1 风电功率空间分布特征

风电场风速或风电功率之间的空间相关性是指不同空间位置处的风电场或风电机组的风速或功率在空间上的相关程度^[10]。风电场内不同机组的地理位置不同, 机组型号完全相同的情况下, 其输出功率也不同, 多数文献从风速的尾流效应、地形等因素分析对风速影响的角度来分析其对输出功率的影响。本文把风电机组位置看作整个风电场分布不同的空间点, 提取功率序列在空间分布的特征向量, 分析风电机组出力在空间分布特点。

经验正交函数分解(EOF)最早是由统计学家 Pearson 在 1902 年提出的, 20 世纪 50 年代中期 Lorenz 将其引入大气科学、海洋学领域研究中。经验正交函数分解从计算过程上来考虑, 是单纯的一种数学计算方法, 与其应用的物理背景无关^[15]。设风电场有 m 台机组, 其所占空间位置相当于 m 个空间点, 每个空间点有 n 个时间序列观测值, 每个数据表示为 x_{ij} , 其中

收稿日期: 2018-04-25

基金项目: 陕西省重点研发计划(2018 ZDXM-GY-169); 河南省高等学校重点科研项目(15A70556)

通信作者: 黄 慧(1982—), 女, 博士研究生、讲师, 主要从事新能源并网优化规划、优化运行与调度方面的研究。
cghuanghui2000@163.com

$i=1,2,\dots,m; j=1,2,\dots,n$, x_{ij} 为第 j 个实际空间场, 写成矩阵形式为:

$$\mathbf{X} = x_{ij} = (x_{11}, x_{12}, \dots, x_{1n}) = \begin{bmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{m1} & \cdots & x_{mn} \end{bmatrix} \quad (1)$$

经验正交展开就是将 \mathbf{X} 分解为时间函数 \mathbf{Z} 和空间函数 \mathbf{V} 两部分:

$$\mathbf{X} = \mathbf{VZ}, \mathbf{V} = \mathbf{XZ}^T \quad (2)$$

$$x_j = v_1 z_{1j} + v_2 z_{2j} + \cdots + v_m z_{mj}, \quad j=1,2,\dots,n \quad (3)$$

式中, v_j —— 第 j 个典型场, 它仅是空间的函数, $v_j = (v_{1j}, v_{2j}, \dots, v_{mj})^T$ 。

假设第 j 个实际空间场 x_j 仅在前 k 个基向量上投影较大, 则 x_j 又可表示为:

$$x_j = \sum_{k=1}^K v_k z_{kj} + \varepsilon_j(k), \quad j=1,2,\dots,n \quad (4)$$

EOF 分解最终目的是寻找一组正交基向量, 使 x_1, x_2, \dots, x_n 整体被表达得尽可能准确。EOF 分解主要步骤:

1) 对风电功率时间序列 \mathbf{X} 进行距平化处理, 得到新的矩阵 \mathbf{Y} 。设 x_m 为 x 中的第 m 列, 则距平化后的新矩阵 \mathbf{Y} 中的第 n 行第 m 列元素为:

$$y_{nm} = x_{nm} - \bar{x}_m, \quad m=1,2,\dots,M; n=1,2,\dots,N \quad (5)$$

式中, x_{nm} —— 矩阵中第 n 行第 m 列元素; \bar{x}_m —— x 中第 m 列的样本均值; M —— 风电机组的数量; N —— 时间序列长度。

2) 求 \mathbf{Y} 的协方差矩阵 \mathbf{A}

$$\mathbf{A} = \mathbf{Y}\mathbf{Y}^T \quad (6)$$

3) 计算 \mathbf{A} 的特征根和特征向量, 特征值 ($\lambda_1, \lambda_2, \dots, \lambda_M$) 按照非升序排序, 对应的特征向量序数 (V_1, V_2, \dots, V_M) 做相应变动, 其特征向量对应原始场的空间向量。

4) 计算各空间型的方差贡献率, \mathbf{X} 方差的大小可用简单的特征根大小来表示, λ 越高说明其对应的模式越重要, 对总方差的贡献越大。第 m 个空间型方差贡献率为:

$$\delta_m = \frac{\lambda_m}{\sum_{\lambda=1}^M \lambda_m} \times 100\% \quad (7)$$

特征分量方差的贡献率反映该空间型对原始空间的描述能力, 前 k 个空间型贡献率之和成为前 k 个空间型的累积贡献率, 其值越大利用该 k 个空间型还原得到的空间场与原始场越接近。因此, 可利用方差贡献率作为分类的依据, 实现风电场机组的分类。图 1 所示为某风电场 33 台机组 2017 年 1~12 月不同机组的风功率

序列图。机组所处的地理位置不同, 其风电机组出力在空间分布上有一定的相关性。




图1 风电机组功率时间序列图

Fig. 1 Wind turbine power time series

2 NAR 动态神经网络模型

动态神经网络是无论局部或全部都具备记忆和反馈功能的一种神经网络, 通过反馈和记忆单元, 保留某时间点的数据, 并与其下一点数据进行计算, 使该神经网络同时具备动态和完整系统信息的特征。本文采用非线性自回归模型 NAR (nonlinear auto regressive models) 回归神经网络, 其主要由输入层、隐层、输出层和滞时部分组成。在使用之前要事先确定输入滞时、输出滞时、隐层神经元数量, 其基本结构如图 2 所示。图 2 中, $y(t)$ 表示神经网络的输入; 1:3 表示延时阶数; W 为链接权值; b 为阈值。NAR 神经网络的模型可表示为:

$$Y(t) = f[y(t-1), y(t-2), \dots, y(t-n)] \quad (8)$$




图2 NAR 神经网络结构

Fig. 2 NAR neural network structure

通过式(2)可看出, 下一个 $y(t)$ 值的大小取决于前 n 个 $y(t)$ 。NAR 神经网络为带有延迟的 BP 神经网络, 延迟的节数决定神经网络的输入数量。调节延迟数量、神经元数目及隐层数目以筛选出较好的网络训练模型, 采用递归预测法, 进一步可得较好的预测模型。NAR 动态神经网络预测模型建立步骤:

1) 对风功率时间序列进行自相关和偏相关检测, 确定模型的回归阶数为 3;

2) 对样本内数据进行划分, 确定训练数据比例为

75%、验证数据比例为 25%,应用 preparets 函数将数据转化 NAR 所需的数据序列;

3)根据经验公式确定模型的隐层节点数量为 10 和延迟阶数为 3;

4)运用神经网络模型对样本内数据进行训练,通过误差自相关图判断拟合效果,若不符合要求,重复上述步骤;

5)保存训练好的神经网络,进行数据预测,观察预测误差。

3 组合预测

风电场总的功率值是两组预测结果加总求和。第 1 类风电机组 NAR 预测模型输出为机组功率预测平均值 P_1 ,第 2 类风电机组的 NAR 预测模型输出为机组功率预测平均值 P_2 ,风电场总的功率预测均值为 P_t ,则:

$$P_t = \frac{n_1 P_1 + n_2 P_2}{n_1 + n_2} \quad (9)$$

式中, n_1 ——第 1 类风电机组数量; n_2 ——第 2 类风电机组数量。

4 仿真算例分析

4.1 评价指标

风力发电预测中,常采用的评价指标主要有均方根误差 (RMSE)、平绝对误差 (MAE) 和相对误差 (RE) 来表示,具体定义为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N e_i^2} \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (11)$$

$$RE = \frac{1}{n} \sum_{i=1}^n \frac{|e_i|}{y_i} \times 100\% \quad (12)$$

式中, $e_i = y_i - \hat{y}_i$; y_i ——实际功率值; \hat{y}_i ——预测值。

4.2 算例分析

算例数据选取北方某风电场 33 台机组,采用 2017 年 3 月份数据,数据时间分辨率为 10 min,数据集包含共 4394 个数据点。根据 EOF 分解的意义,空间场累积贡献率越高,说明其空间场越能精确地还原原始场,累积空间贡献率达到 90%以上即可精确还原原始场。设置阈值为 92%,累积贡献率达到该阈值的前几个空间场能反映原始场,将其作为一类,并用层次聚类^[15]来验证其分组结果,最终选择前 6 个空间场累积空间贡献率达到 92.8%的机组作为一类,其余机组作为一类,分别建立 NAR 预测模型。前 6 个空间场的贡献率如表 1 所示。

对 2 类机组分别建立 NAR 神经网络模型,经过不断调试隐层神经元数量和延迟阶数,最终选择隐层神

元数量为 8,延迟阶数为 3,这 2 类机组预测结果经过组合加总得出最终的整个风电场功率预测均值。时间采样数据为 10 min 数据,动态调整预测 8 d 之内 1098 个点的数据,提前 3 个采样时间点预测下一个时间点数据,2 类机组 NAR 预测序列图如图 3~图 5 所示。

表 1 空间场的贡献率

空间场	1	2	3	4	5	6
贡献率	0.812	0.049	0.024	0.018	0.014	0.011






图 3 第 1 类机组 NAR 训练预测序列

Fig. 3 First-unit NAR training prediction sequence



a. 第 1 类机组



b. 第 2 类机组

图 4 风功率预测误差自相关性

Fig. 4 Wind power prediction error autocorrelation




图5 第2类机组 NAR 训练预测序列

Fig. 5 Second-unit NAR training prediction sequence

两类机组组合预测真实值和预测值曲线如图 6 所示。ARMA(2,2)模型预测曲线如图 7 所示。组合预测与单一预测模型和时间序列 ARMA(2, 2)^[16]相比较,预测误差分析如表 2 所示。




图6 NAR 功率组合预测曲线

Fig. 6 NAR power combination forecasting curve




图7 ARMA(2,2)预测序列

Fig. 7 ARMA(2,2) prediction sequence

随机选取风电场一年中 6、9、12 月份历史风电功率序列对本文所提方法进行验证,并与未进行机组分类的 NAR 预测模型和传统 ARMA(2, 2)模型进行对比分析。样本数据采取历史 10 min 数据,每个月采集 4394

个数据点,其预测误差 $RMSE$ 、 MAE 和相对误差 RE 对比分析如图 8,本文提出的机组分类 NAR 模型、未进行分类 NAR 模型和 ARMA(2,2)模型的预测误差值分别用柱状图展示。

表2 预测误差值比较

Table 2 Comparison of prediction errors

误差值	分类组合 NAR	NAR 模型	ARMA(2,2)模型
$RMSE$	0.4448	0.4675	0.8216
MAE	0.0112	0.0144	0.1823
$RE/\%$	16.58	18.09	24.14




a. $RMSE$ 柱状图b. MAE 柱状图c. RE 柱状图

图8 预测误差对比分析图

Fig. 8 Comparison bar of prediction errors

经上述分析比较, ARMA(2,2)模型需进行时间序列的平稳化处理, 受模型阶数选择的影响, 预测误差较大。文中提出的经 EOF 分解, 根据贡献率分类进行 NAR 组合预测的方法, 考虑风电场机组出力的时空相关性, 实时动态调整时间序列进行预测, 使得超短期功率预测准确度能进一步提高。

5 结 论

风电场机组处于不同位置, 导致风电机组的输入风速不同, 风电机组出力也不同。依据风电场功率的空间分布特征和动态时间序列神经网络建立超短期组合功率预测模型, 得出如下主要结论:

1) 根据 EOF 分解的思想, 把原始风电功率时间序列进行 EOF 分解, 提取风电功率在空间上分布的特征, 每台机组代表一个空间位置, 分解提取不同空间向量对应的空间贡献率, 结论表明该机组出力对整个风电场的空间贡献率这一特征提取的方法是可行的。

2) NAR 动态时序模型进行网络训练和预测时, 其延迟阶数和隐层神经元数量选取需要结合实际的时间序列不断进行调整。经过大量数据的多次训练仿真得到期望的预测效果。

[参考文献]

- [1] TASICARA OGLU A, UZUNOGLU M. A review of combined approaches for prediction of short-term wind speed and power[J]. Renewable and sustainable energy reviews, 2014, 34(6): 243-254.
- [2] HOWARD T, CLARK P. Correction and downscaling of NWP wind speed forecasts[J]. Meteorological applications, 2010, 14(2): 105-116.
- [3] 冯双磊, 王伟胜, 刘纯, 等. 风电场功率预测物理方法研究[J]. 中国电机工程学报, 2010, 30(2): 1-6.
FENG S L, WANG W S, LIU C, et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE, 2010, 30(2): 1-6.
- [4] 欧阳庭辉, 查晓明, 秦亮, 等. 中长期风电功率的多气象变量模型组合预测方法[J]. 电网技术, 2016, 40(3): 847-852.
OUYANG T H, ZHA X M, QIN L, et al. Medium- or long-term wind power prediction with combined models of meteorological multi-variables[J]. Power system technology, 2016, 40(3): 847-852.
- [5] 杨茂, 董骏城, 齐玥. 基于近似熵的风电功率可预测性研究[J]. 太阳能学报, 2016, 37(10): 2710-2718.
YANG M, DONG J C, QI Y. Predictability of wind power based on approximate entropy[J]. Acta energiae solaris sinica, 2016, 37(10): 2710-2718.
- [6] CHEN K L, YU J. Short-term wind speed prediction using an unscented Kalman filter based state-space support vector regression approach[J]. Applied energy, 2014, 113(6): 690-705.
- [7] 张亚超, 刘开培, 秦亮. 基于VMD-SE和机器学习算法的短期风电功率多层次综合预测模型[J]. 电网技术, 2016, 40(5): 1334-1340.
ZHANG Y C, LIU K P, QIN L. Short-term wind power multi-leveled combined forecasting model based on variational mode decomposition-sample entropy and machine learning algorithms[J]. Power system technology, 2016, 40(5): 1334-1340.
- [8] 刘彦华, 董泽. 风速及风电功率超短期动态选择线性组合预测[J]. 太阳能学报, 2016, 37(4): 1009-1016.
LIU Y H, DONG Z. Ultra-short-term wind speed and power forecast based on dynamic selective linear combined forecast[J]. Acta energiae solaris sinica, 2016, 37(4): 1009-1016.
- [9] ZHENG W Q, PENG X G, LU D L, et al. Composite quantile regression extreme learning machine with feature selection for short-term wind speed forecasting: a new approach[J]. Energy conversion and management, 2017, 151: 737-752.
- [10] 叶林, 赵永宁. 基于空间相关性的风电功率预测研究综述[J]. 电力系统自动化, 2014, 38(14): 126-135.
YE L, ZHAO Y N. A review on wind power prediction based on spatial correlation approach[J]. Automation of electric power systems, 2014, 38(14): 126-135.
- [11] 陈妮亚, 钱政, 孟晓风, 等. 基于空间相关法的风电场风速多步预测模型[J]. 电工技术学报, 2013, 28(5): 15-21.
CHEN N Y, QIAN Z H, MENG X F, et al. Multi-step ahead wind speed forecasting model based on spatial correlation and support vector machine[J]. Transactions of China Electrotechnical Society, 2013, 28(5): 15-21.
- [12] SHI J, DING Z, LEE W J, et al. Hybrid forecasting model for very-short term wind power forecasting based on grey relational analysis and wind speed distribution features[J]. IEEE transactions on smart grid, 2014, 5(1): 521-526.
- [13] TASICARA OGLU A, SANANDAJI B M, POOLLA K, et al. Exploiting sparsity of interconnections in spatio-temporal wind speed forecasting using wavelet transform[J]. Applied energy, 2016, 165: 735-747.
- [14] 杨正瓴, 冯勇, 熊定方, 等. 基于季风特性改进风电

- 功率预测的研究展望[J]. 智能电网, 2015, 3(1): 1-7.
- YANG Z L, FENG Y, XIONG D F, et al. Research prospects of improvement in wind power forecasting based on characteristics of monsoons[J]. Smart grid, 2015, 3(1): 1-7.
- [15] 王尤嘉, 鲁宗相, 乔颖, 等. 基于特征聚类的区域风电短期功率统计升尺度预测[J]. 电网技术, 2017, 41(5): 1383-1389.
- WANG Y J, LU Z X, QIAO Y, et al. Short-term regional wind power statistical upscaling forecasting based on feature clustering [J]. Power system technology, 2017, 41(5): 1383-1389.
- [16] 赵欣, 王爽心, 刘如九. 基于灰色关联和协整理论的风功率组合预测研究[J]. 太阳能学报, 2017, 38(5): 1299-1306.
- ZHAO X, WANG S X, LIU R J. Research on combination wind power forecasting based on gray correlation and cointegration theory[J]. Acta energiae solaris sinica, 2017, 38(5): 1299-1306.

ULTRA SHORT-TERM COMBINED FORECASTING OF WIND POWER WITH NAR NEURAL NETWORK BASED ON SPATIO-TEMPORAL CORRELATION

Huang Hui^{1,2}, Jia Rong¹, Dong Kaisong³

(1. Institute of Water Resources and Hydro-Electric Engineering, Xi'an University of Technology, Xi'an 710048, China;

2. School of Electric Power, North China University of Water Resources and Electric Power, Zhengzhou 450011, China;

3. State Grid Gansu Institute of Electric Power, Lanzhou 730000, China)

Abstract: Considering the spatial distribution correlation of the wind farm units, a combination prediction method based on the dynamic time series neural network (NAR) for the ultra-short-term power of wind farms is proposed. Firstly, the spatial correlation of output characteristics of wind turbine generators is analyzed by Empirical Orthogonal Function (EOF), and the wind turbines are classified according to the spatial characteristic contribution rate. Secondly, the NAR prediction model is established based on the mean value of original power time series from the wind units. Then the wind power prediction results are combined to get a total number of wind farm power forecasting value. A case study of a wind farm in northern China is carried out. The new model is compared with the single wind power series NAR prediction model and the typical ARMA(2, 2) prediction model. The comparison results verify the validity of the prediction results.

Keywords: spatial distribution; time series; wind power; combination prediction; NAR neural network