

DOI: 10.11830/ISSN.1000-5013.201806023



采用小波分析和神经网络的 短期风速组合预测

常雨芳^{1,2}, 张力², 谢昊², 刘光裕²

(1. 湖北工业大学 太阳能高效利用湖北省协同创新中心, 湖北 武汉 430068;

2. 湖北工业大学 电气与电子工程学院, 湖北 武汉 430068)

摘要: 为了提高风速的波动性与随机性预测精度, 提出小波分析和神经网络组合的风速预测模型. 该方法利用小波分解将风速分解为一列频率不相同的分量, 并利用二插值进行重构; 根据各个分量的频率特征, 选择合适的模型分别进行预测; 高频分量采用组合神经网络预测, 低频分量采用合适的单一模型直接进行预测; 将各预测值叠加得到最终预测值. 算例分析表明: 相较于单一预测模型, 所提方法的预测精度得到大幅提升, 更加贴近实际风速曲线, 预测结果更具可靠性.

关键词: 短期预测; 小波分析; 径向基神经网络; Elman 神经网络; 广义回归神经网络

中图分类号: TM 614

文献标志码: A

文章编号: 1000-5013(2019)04-0556-05

Short-Term Wind Speed Combined Forecasting Using Wavelet Analysis and Neural Network

CHANG Yufang^{1,2}, ZHANG Li², XIE Hao², LIU Guangyu²

(1. Hubei Collaborative Innovation Centre for High-Efficiency Utilization of Solar Energy,

Hubei University of Technology, Wuhan 430068, China;

2. School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China)

Abstract: In order to improve the forecasting accuracy and reduce the impact of randomness and volatility of the wind speed, a new forecasting model based on wavelet analysis and neural network is presented. By means of the wavelet analysis technique, the original wind speed series are decomposed into a series of components of different frequencies components, and reconstructed by twice-interpolation. According to the frequency characteristics of each component, the suitable model is selected to forecast separately. The high frequency component is forecasted by combined neural network, and the low frequency component is forecasted by a suitable single model. The final forecasting value is obtained by superimposing each forecasting values. The simulation results show that compared with the single prediction model, the forecasting accuracy of the proposed method is greatly improved, and it is closer to the actual wind speed curve, and it is more reliable.

Keywords: short-term forecasting; wavelet analysis; radial basis function neural network; Elman neural network; general regression neural network

近年来, 风能作为一种环境友好型的可再生能源发展迅速, 在各国能源供应中的比重不断提高. 由

收稿日期: 2018-06-23

通信作者: 常雨芳(1980-), 女, 副教授, 博士, 主要从事智能配电系统和微网能源系统的优化设计与控制的研究. E-mail: changyf@hbut.edu.cn.

基金项目: 国家自然科学基金资助项目(61601176); 湖北省自然科学基金资助项目(2016CFB512)

于风能自身的波动性、间歇性与不可控性,大规模的风电接入电网将对电网安全稳定的运行带来严峻考验.风力发电功率的准确预测一方面可以降低电力系统的运行成本,提高风电穿透功率;另一方面,可以根据预测曲线对电力系统进行及时调度,降低风电接入电网时对电网产生的影响^[1-2].风力发电功率的影响因素很多,但风速对风力发电功率的影响最为突出,风力发电功率准确预测主要取决于风速的准确预测.在实际运用中,选择单一预测模型很难达到较高的预测精度,一般将物理方法与统计方法相结合^[3-10].风速预测是一个非线性的复杂过程,有多种预测的方法与模型,各具特点,且在预测精度上存在一定的差异.本文提出一种基于小波分解重构与组合神经网络的短期风速预测方法.

1 小波分解

Mallat 算法即金字塔算法^[10].利用 Mallat 算法,将非平稳的风速离散时间序列分解为不同频率的风速序列 d_1, d_2, \dots, d_J 和序列 a_j .其中, J 为最大分解层数.上述分解过程可表示为

$$a_{j+1} = H_{a_j}, \quad d_{j+1} = G_{a_j}, \quad j = 1, 2, 3, \dots, J.$$

上式中: $H(\cdot)$ 为低频分解函数,相当于低通滤波器; $G(\cdot)$ 为高频分解函数,相当于高通滤波器.

对非平稳的风速离散时间序列进行分解,得到不同频率的分量,但分解后各分量的长度各不相同,每进行一次分解,长度变为分解前的一半,分解后的分量长度与原始长度不相等.因此,选择二插值对分解后的分量进行数据重构,得到与原始序列长度相等,但频率不相同的分解分量,即

$$A_j = (H^*)^j a_j, \quad D_{j+1} = (H^*)^{j-1} G^* d_{j+1}, \quad j = 1, 2, 3, \dots, J.$$

上式中: H^*, G^* 分别为 H 和 G 的对偶算子.利用二插值重构方法对分解后的各个分量进行重构,得到重构后的序列 D_1, D_2, \dots, D_J 和序列 A_J ,且各分量的长度与原始风速序列的长度相等.

对历史风速数据进行小波分解,小基波和分解级数的选择尤为重要,选择不同的小基波得到的预测结果有所差异.选择较大的分解级数对风速序列进行分解与重构,得到分解后的分量较多,对风速进行预测时选择的预测模型也较多,从而导致一定的预测误差,影响预测的精度与结果.而选择较小的分解级数对风速序列进行分解与重构,则可能导致原始序列中部分频率特征的分量未被分离出来,从而影响最终风速预测的精度与结果.

2 短期风速组合预测模型的建立

2.1 神经网络

2.1.1 径向基神经网络 神经网络具有很强的非线性映射能力,可将多维的输入映射到输出.神经网络中径向基(RBF)神经网络结构较为简单、收敛快,且能逼近任意一个非线性函数.在反向传播(BP)神经网络中,三层以上结构也可以实现逼近任意一个非线性函数,但 BP 神经网络的逼近属于全局逼近,相对于 RBF 收敛较慢,且容易陷入局部的极小值.神经网络一般分为输入层、隐含层、输出层,在 RBF 中隐含层的节点数为样本数,基函数的数据中心也由样本本身决定.因此,在 RBF 神经网络的参数中只需设计输出节点的权值和拓展系数.拓展系数一般根据公式确定,以避免基函数太尖或太平.拓展系数 $\delta = d_{\max} / \sqrt{2p}$.式中: d_{\max} 为各个样本间的最大距离; $p = 1, 2, \dots, P$, P 为样本的数目.

输出层的权值设计一般根据公式具体调整,输出层的权值调整公式为 $\Delta W_k = \eta(d_k - \mathbf{W}_k^T \varphi) \varphi$.式中: ΔW_k 的各个分量 $\Delta W_{b,k} = \eta(d_k - \mathbf{W}_k^T \varphi) \phi_b$, $b = 0, 1, \dots, p$, $k = 1, 2, \dots, l$; 权值的初始值可为任意值.

2.1.2 广义回归神经网络 广义回归神经网络(GRNN)^[4]是径向基神经网络的一种特殊变形.但广义回归神经网络与径向基神经网络的区别在于,广义回归神经网络的学习速度及逼近能力较径向基神经网络更加明显.除此之外,在不平稳数据的处理上,GRNN 也表现出较大的优势.广义回归神经网络在隐含层传递函数的选择上也与径向基神经网络有所不同,通常将高斯函数作为传递函数,即

$$R_i = \exp\left[-\frac{\|\mathbf{x} - c_i\|^2}{2\sigma_i^2}\right], \quad i = 1, 2, \dots, n.$$

上式中: \mathbf{x} 为输入向量; c_i, σ_i 分别为第 i 个函数的中心和第 i 个感知单元的变量; n 为个数.

输出层实现 $R_i(\mathbf{x}) \rightarrow y_p$ 的线性映射, $y_p = \sum_{i=1}^m \omega_{i,p} R_i(x_1)$, $p = 1, 2, \dots, P$.

2.1.3 Elman 神经网络 Elman 神经网络是一种典型的局部回归神经网络. 在结构上,局部回归神经网络可以看作是 BP 神经网络多了一个局部反馈的连接层^[11-12]. 局部记忆单元与局部反馈相连的前向神经网络构成 Elman 神经网络. Elman 神经网络存在一种自连,即承接层与隐含层输入的连接,承接层负责隐含层输出延迟与存储,使神经网络对出现过的数据更加敏感;内部的反馈网络使网络处理动态信息的能力得到提升,使 Elman 神经网络能够实现动态建模.

在 Elman 神经网络中,当输出节点选择线性转移函数时,隐含层单元、反馈单元、输出单元分别为 $X(e+1)=F(X^c(e+1),U(e))$, $X^c(e)=X(e-1)$, $Y(e-1)=WX(e-1)$. 式中: $U(e)$ 为输入; $X^c(e)$ 为隐含层的反馈信号(e 时刻的输出); $X(e-1)$ 为隐含层输入; $Y(e-1)$ 为隐含层输出.

2.2 支持向量机

支持向量机(SVM)是一种统计学习方法,是在统计学习理论的 VC 维理论和结构风险最小化原理基础上发展起来的一种新的机器学习方法^[8]. 将 SVM 运用于风速预测,首先,应将历史风速映射到一个高维空间,利用线性回归方法对映射后的样本进行分析,此时,存在回归函数 $f(v) = \sum_{h=1}^l (\alpha_h - \alpha_h^*)k(v, v_h) + b$. 其中: α_h, α_h^* 不等于 0,分别对应支持向量; $k(v, v_h)$ 为核函数.

在应用 SVM 时,选择运用最为广泛的径向基核函数. 此外, SVM 的使用还涉及惩罚系数 C 、不敏感损失值的选择. 为避免盲目性,通过交叉验证得到合适的参数.

2.3 组合预测模型

组合预测模型结合使用两种或几种预测模型,在提升预测精度的基础上,可避免单一预测模型产生的局限性^[13-14]. 各模型根据同一样本进行预测,得到多个预测值,将其预测结果进行叠加,得到最终的预测结果. 在运用组合预测时,最重要的是如何运用各模型或方法的预测结果. 因此,各模型的权重值选择尤为关键,权重值或权重比的选择直接影响最终的预测结果与精度.

针对组合模型的运用,风速预测值与实际值的非线性关系,以及各模型的预测值相对于样本数据较少的情况,选择 GRNN 对各模型的风速预测值进行拟合,即将各模型的预测结果输入 GRNN,GRNN 的输出即最后的风速预测值.

2.4 基于小波分解的神经网络组合预测

为了降低风速随机性、波动性与不可控性的影响,提高预测精度,采用小波分析对风速进行数据预处理,将风速时间序列进行分解,得到不同频率的子分量,同时采用小波二插值重构各子分量的数据. 选择 Elman 神经网络、RBF 神经网络、支持向量机的组合预测模型对子分量中最高频分量进行预测;通过广义回归神经网络对 3 种模型的预测结果进行拟合,得到高频分量的预测值;通过单一的 RBF 神经网络对低频分量进行预测. 将高频分量的预测值与低频分量的预测值进行等权叠加,得到最终的风速预测值. 通过参数筛选,RBF 神经网络的拓展系数选择 85,广义回归神经网络的拓展系数选择 0.08;支持向量机采用工具箱进行实现,选择使用最为广泛的高斯径向基核函数,可以验证得到最佳的参数 $c=5$,高斯核函数参数 $\sigma=1.715$,不敏感损失函数 $\epsilon=0.1$.

基于小波分解的神经网络组合算法的流程,如图 1 所示. 图 1 中: CD_1, \dots, CD_n, res 为小波分解与重构后与原风速序列长度相等的风速序列; T_1, T_a, T_b, T_c 分别为各预测模型的预测结果.

文中方法的实现有以下 6 个步骤.

步骤 1 选择合适的分解级数对风速历史数据进行小波分解,得到不同频率的风速分量.

步骤 2 对小波分解后的各频率分量进行二插值重构,在不改变各组分量频率特征的情况下,使风量的长度达到原始风速数据的长度.

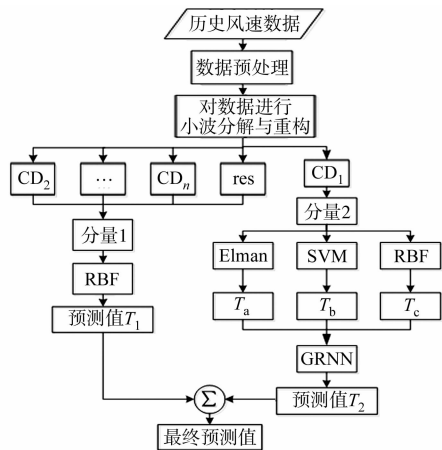


图 1 基于小波分解的神经网络组合算法流程图
Fig.1 Algorithm flow chart of combination neural network based on wavelet decomposition

- 步骤 3 对重构后的各频率风速分量进行数据归一化处理.
- 步骤 4 根据各组分量的频率特点, 分别为其选择合适的风速预测模型并进行训练.
- 步骤 5 最高频分量采用组合预测模型对未来 24 h 的风速进行预测, 其余分量采用单一的风速预测模型进行预测.
- 步骤 6 将得到的两组风速预测值进行合适的加权求和, 得到的风速值即最终的风速预测值.

3 算例分析

样本数据来自某风电场某月的实际风速, 测试时间间隔为 1 h, 在 Matlab 中编程, 对上述预测方法进行验证. 历史风速样本, 如图 2 所示. 图 2 中: v 为风速. 利用前 30 d 的风速数据对接下来第 31 天(24 h)的风速进行预测.

根据上述方法将历史风速样本用小波分解, 选择二插值重构对分解后各个风速分量进行重构, 得到重构后各频率的风速分量, 如图 3 所示. 图 3 中: s 为原始信号.




图 2 历史风速数据

Fig. 2 Original wind speed time series




图 3 小波分解与重构结果

Fig. 3 Results of wavelet decomposition and reconstruction

由图 3 可知: d_1 分量的频率为各个分量中最高频分量, 风速变化较大, 将其作为分量 2. 针对最高频分量的风速, 选择支持向量机、Elman 神经网络、RBF 神经网络、GRNN 神经网络组合的预测模型对其进行训练, 并对接下来 24 h 的风速进行预测, 即采用支持向量机、Elman 神经网络、RBF 神经网络分别对第 31 天(24 h)的风速进行预测, 预测结果作为 GRNN 神经网络的输入, 通过拟合得到的值为最高频风速分量的预测值. 由图 3 还可知: 除去最高频风速分量还剩下 d_2, d_3, d_4, d_5, a_5 等 5 组分量, 较分量 2 频率明显较低, 将其归为低频分量 1, 单一的预测模型可以达到较好的预测精度与预测效果. 因此, 选择 RBF 对分量 1 进行预测.

在得到分量 1、分量 2 风速预测值时, 将两组预测值进行等权叠加, 得到第 31 天(24 h)的风速值, 即最终的风速预测值. 针对历史风速数据, 采用单一的预测模型进行分解, 直接对第 31 天(24 h)风速进行预测, 预测结果与所提方法进行比较, 其结果如图 4 所示.

由图 4 可知: 相较于传统预测模型, 所提方法能更好地随着实际风速的变化而变化, 且 24 h 各个时间点的风速值也更接近实际风速. 为了更好地判断各个模型的预测效果, 比较预测精度, 选择平均相对百分比误差 (E_{MR}) 和均方根误差 (E_{MA}) 作为评价标准, 有

$$E_{MR} = \frac{1}{N} \sum_{i=1}^N \frac{|v_i - v'_i|}{v_i}, \quad E_{MA} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{v_i - v'_i}{v_i} \right)^2}.$$




图 4 组合模型和单一模型的预测结果

Fig. 4 Prediction results based on combination model and single model

上式中: N 为预测样本长度,即 24; v_i 为实测风速值; v'_i 为预测风速值.

经计算可知:组合预测模型的 E_{MR} 值和 E_{MA} 值分别为 7.050 0%,0.732 0%,单一预测模型(RBF)的 E_{MR} 值和 E_{MA} 值分别为 14.960 0%,0.178 5%,而单一预测模型(SVM)的 E_{MR} 值和 E_{MA} 值分别为 18.460 0%,0.216 4%.采用的预测模型在绝大部分点给出了较准确的预测值,相较于单一预测模型预测,其误差明显降低,精度大幅提升.此外,采用单一神经网络模型得到的预测曲线无法随实际风速曲线而变化,存在明显的滞后问题,而所提方法很好地改善了滞后问题,更加贴近实际风速变化曲线,更好地反映风速的变化,预测结果更具有实际价值.

4 结 束 语

提出一种小波分解与重构和组合神经网络相结合的风速预测模型.以某风电场的历史平均风速数据为例,对所提方法进行仿真验证,并传统风速预测模型进行实验对比.结果表明:所提方法降低了风速波动性与随机性,提高了预测精度,适用于风速的短期预测,预测曲线也更贴近实测风速变化曲线.但所提方法无法完全克服风速的随机性与波动性,有待继续研究,从而降低影响,使预测精度进一步提高.

参 考 文 献:

[1] 张妍,王东风,韩璞.一种风电场短期风速组合预测模型[J]. 太阳能学报,2017,38(6):1510-1516.

[2] 彭怀午,刘方锐,杨晓峰.基于组合预测方法的风电场短期风速预测[J]. 太阳能学报,2011,32(4):543-547.

[3] ZULUAGA C D,ÁLVAREZ M A,GIRALAO E. Short-term wind speed prediction based on robust Kalman filtering: An experimental comparison[J]. Applied Energy,2015,156(10):321-330. DOI:10.1016/j.apenergy.2015.07.043.

[4] 勾海芝,赵征,夏子涵.基于经验模式分解的神经网络组合风速预测研究[J]. 电力科学与工程,2017,33(10):62-67. DOI:CNKI:SUN:DLQB.0.2017-10-011.

[5] RAMASAMY P,CHANDEL S S,YADAV A K. Wind speed prediction in the mountainous region of India using an artificial neural network model[J]. Renewable Energy,2015,80(8):338-347. DOI:10.1016/j.renene.2015.02.034.

[6] 刘爱国,薛云涛,胡江鹭,等.基于 GA 优化 SVM 的风电功率的超短期预测[J]. 电力系统保护与控制,2015,43(2):90-95.

[7] WANG Jianzhou,HU Jianming. A robust combination approach for short-term wind speed forecasting and analysis: Combination of the ARIMA, ELM, SVM and LSSVM forecasts using a GPR model[J]. Energy,2015,93(12):41-56. DOI:10.1016/j.energy.2015.08.045.

[8] LIU Huichao,TIAN Hongqi,LI Yanfei. Four wind speed multi-step forecasting models using extreme learning machines and signal decomposing algorithms[J]. Energy Conversion and Management,2015,100(4):16-22. DOI:10.1016/j.enconman.2015.04.057.

[9] 高阳,钟宏宇,陈鑫宇,等.基于神经网络和小波分析的超短期风速预测[J]. 可再生能源,2016,34(5):705-711.

[10] 陈德生,李培强,李欣然,等.基于小波变换的短期风速预测综合模型[J]. 电工电能新技术,2012,31(3):73-76. DOI:10.3969/j.issn.1003-3076.2012.03.016.

[11] 陈艳平,毛弋,陈萍,等.基于 EEMD-样本熵和 Elman 神经网络的短期电力负荷预测[J]. 电力系统及其自动化学报,2016,28(3):59-64. DOI:10.3969/j.issn.1003-8930.2016.03.011.

[12] SAFARI N,CHUNG C Y,PRICE G C D. A novel multi-step short-term wind power prediction framework based on chaotic time series analysis and singular spectrum analysis[J]. IEEE Transactions on Power Systems,2017,33(1):590-601. DOI:10.1109/TPWRS.2017.2694705.

[13] ROSENTHAL W S,TARTAKOVSKY A,HUANG Zhenyu. Ensemble Kalman filter for dynamic state estimation of power grids stochastically driven by time-correlated mechanical input power[J]. IEEE Transactions on Power Systems,2017,33(4):1-10. DOI:10.1109/TPWRS.2017.2764492.

[14] 修春波,任晓,李艳晴,等.基于卡尔曼滤波的风速序列短期预测方法[J]. 电工技术学报,2014,29(2):253-259.

(责任编辑:钱筠 英文审校:吴逢铁)