

基于小波变换和相关向量机的短期风功率预测

刘雨莎^{1,2}, 杨晓萍¹, 李锐², 张豪³

(1. 西安理工大学水利水电学院, 西安 710048; 2. 国网渭南供电公司, 陕西 渭南 714000;

3. 国网陕西省电力公司检修公司, 西安 710065)

摘要: 采用小波变换(wavelet transform, WT)和相关向量机(relevance vector machine, RVM)结合的方法对风电场发电功率短期预测进行研究。先利用小波变换将信号分解为不同频率的子序列, 提取出风速中的低频趋势分量和高频波动分量; 再结合风向和温度数据, 运用RVM在不同分量上分别进行预测, 并通过重构得到功率的预测结果。此方法应用于国内某风电场, 仿真结果表明, 通过小波分析能够把握风速变换规律, RVM预测法有较强的学习能力, 小波—相关向量机法有效提高了预测精度, 表明了该方法的可行性。

关键词: 风力发电; 短期功率预测; 小波变换; 相关向量机

Short-term Power Prediction of a Wind Farm Based on Wavelet Transform and Relevance Vector Machine

LIU Yusha^{1,2}, YANG Xiaoping¹, LI Rui², ZHANG Hao³

(1. Xi'an University of Technology, Xi'an 710048, China; 2. State Grid Weinan Electric Power Supply Company, Shaanxi Weinan 714000, China; 3. Maintenance Company of State Grid Shaanxi Electric Power Company, Xi'an 710065, China)

Abstract: This paper studies short-term prediction of wind power generation capacity by means of wavelet transform and relevance vector machine (RVM). Firstly, the original wind speed signal sequence is decomposed into a series of sub-sequences with different frequency by wavelet transform, and the low-and high-frequency components in the wind speed signal are extracted. Then, RVM is applied to these sub-sequences for respective prediction considering the data of wind direction and temperature, and final wind power prediction is hence obtained through reconstruction of the respective predictions. Finally, the proposed prediction method is applied to a certain wind farm, and simulation results show that wavelet transform can help to understand the variation of wind speed, and the combination of wavelet transform with RVM, which has better learning ability, can effectively improve the prediction accuracy.

Key words: wind power generation; short-term wind power prediction; wavelet transform; relevance vector machine

0 引言

近年来, 风电场数量和风力发电总装机容量占电网的比例日趋增大, 风电场风速和输出功率预测作为风力发电研究的基础环节, 对于电网的运行调度有着重要作用, 得到越来越多的关注^[1-2]。

目前, 风电场输出功率的预测主要包括物理和统计两类方法。物理方法是根据风力发电机组轮毂高度的风速、风向等信息, 利用风机的功率曲线预测输出功率^[3-4], 此类方法适合地形复杂的区域, 不

需要风场大量实测数据, 但预测精度较差^[5]; 统计方法是根据历史气象数据与风电场输出功率, 建立气象数据与风功率之间某种映射关系进行预测, 常用的方法有时间序列法、BP神经网络、支持向量机(support vector machine, SVM)及相关向量机等^[6], 此类方法可以根据风场特点和位置随时修改预测模型, 准确度较高, 但模型的改进优化难度大^[7]。时间序列法是应用差分自回归移动平均模型, 利用历史数据建立线性模型从而得到预测值, 由于只能处理线性问题, 而风速往往具有非线性, 所以此方法往往不能达到预测效果^[8]。BP神经网络具有良好的非线性逼近能力, 但其存在收敛速度慢, 易陷入局部

极小值点等缺陷^[9];SVM是通过非线性核函数,将输入样本空间映射到高维线性特征空间,它利用数学方法和优化技术克服了神经网络的训练时间长等缺点,提高了模型的学习泛化能力^[10]。相关向量机模型就是在SVM基础上,通过贝叶斯推理,利用给定的训练样本集优化求解模型参数,建立输入与输出向量之间的非线性映射关系,进而给定一个新的输入样本,能够得到对应输出变量的一个估计值。RVM所需要的样本数据比SVM少很多,从而使RVM相对于SVM的测试时间大幅缩短^[11-12]。

在各种气象数据中,影响风功率的主要因素是风速。由于风速受多种因素的影响,风速时间序列中通常会存在一些突变的点,而这些数据点是造成风功率预测误差的主要原因。小波变换是一种时频分析方法,它克服短时傅里叶变换单分辨率的缺陷,在时域和频域都具有表征信号局部信息的能力。通过小波分析能有效分离风速中的低频趋势项和高频噪声项,使研究对象转化为规律性和相关性更强的子序列。

文中将小波变换用于分解风速时间序列信号,分离风速中的低频趋势项和高频噪声项,使风速时间序列转化为规律性和相关性更强的子序列,将分解得到的子序列分量与原始风向、温度数据分别输入各相关向量机模型,得到几组预测分量;再将各组预测分量进行小波重构,得到功率预测结果。最后通过现场实际数据进行仿真验证,并与其他方法进行对比分析,说明文中方法的有效性和可行性。

1 相关向量机

RVM是基于核函数模式的模式识别技术,它实现了特征空间、数据空间及类别空间之间的非线性变换,具有自动参数设置和任意使用核函数等优点。

对于一般回归问题^[13],目标值与输入量之间的对应关系可表示为

$$y_n = f(x_n; \omega) + \varepsilon_n. \quad (1)$$

式(1)中: x_n, y_n 分别为第 n 组数据中的输入向量和目标值; $\omega = [\omega_0, \omega_1, \dots, \omega_M]^T$ 为待辨识的权值向量; ε_n 为独立同分布误差项,服从正态分布 $N(0, \sigma^2)$ 。继而 y_n 服从均值为 $f(x_n; \omega)$ 、方差为 σ^2 的正态分布。

基于核方法理论, $f(x_n; \omega)$ 可以表示为

$$f(x_n; \omega) = \omega^T \phi(x_n) = \sum_{i=1}^M \omega_i K(x_n, x_i) + \omega_0. \quad (2)$$

式(2)中: $K(x_n, x_i)$ 为核函数,在回归预测中可采用高斯核函数形式; M 为核函数总数; $\phi(x_n) = [1, K(x_n, x_1), \dots, K(x_n, x_M)]^T$ 。

从式(2)可以看出,对于参数 ω ,模型是线性的, $K(x_n, x_i)$ 可以是高度非线性的,这使模型又具有表示非线性问题的能力,特别是当核函数的数目较多时,模型可灵活运用^[14]。

由 y_n 的分布可知,在 N 次的独立试验中,目标值 $y[y_1, y_2, \dots, y_n]$ 出现的概率为

$$p(y|\omega, \sigma^2) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp(-\frac{1}{2\sigma^2} \|y - \Phi\omega\|^2). \quad (3)$$

式(3)中: $\Phi = [\phi(x_1), \phi(x_2), \dots, \phi(x_N)]^T$ 。 ω_i 和 σ^2 的值可采用极大似然估计求取,为避免出现过学习情况,基于贝叶斯原理,RVM将 ω_i 和 σ^2 均视为随机变量。设定 ω_i 的先验分布为均值0、方差 α_i^{-1} 的正态分布,且相互独立;进而设定超参数 α_i 与 σ^2 的先验分布为形状参数与尺度参数均为0的伽马分布,选择先验分布使得模型有很好的适应训练数据的能力,并保证了模型的稀疏性及泛化能力^[15]。

根据贝叶斯公式得到 ω, α, σ^2 的后验分布

$$p(\omega, \alpha, \sigma^2|y) = \frac{p(y|\omega, \alpha, \sigma^2)p(\omega, \alpha, \sigma^2)}{p(y)}. \quad (4)$$

将式(4)左侧分解得

$$p(\omega, \alpha, \sigma^2|y) = p(\omega|y, \alpha, \sigma^2)p(\alpha, \sigma^2|y). \quad (5)$$

式(5)将原问题转化为求 α, σ^2 在 y 情况下的后验分布,以及 ω 在 α, σ^2, y 情况下的后验分布。实际中为简化计算,近似认为 α, σ^2 的后验分布为狄拉克分布 $\delta(\alpha_{mp}, \sigma_{mp}^2)$,其中 α_{mp} 和 σ_{mp}^2 分别表示 α, σ^2 的极大似然估计^[16]。进而,可计算求得服从正态分布的 ω 参数值,即均值和方差分别为:

$$E = (\sigma^{-2}\Phi^T\Phi + A)^{-1}; \quad (6)$$

$$\mu = \sigma^{-2}E\Phi^Ty. \quad (7)$$

式(6)中, $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_M)$ 。

在计算过程中,许多权重的后验分布趋近与零。对于相关向量回归模型,这些非零的向量代表数据中的原型样本,因此称这些样本为“相关向量”(relevance vectors, RVs)^[17],体现了数据集中最核心特征。

通过训练数据得到模型参数后,对于新的输入向量 x_* ,目标值 y_* 的分布密度为

$$p(y_*|y) = \int p(y_*|\omega, \alpha, \sigma^2)p(\omega, \alpha, \sigma^2|y)d\omega d\alpha d\sigma^2. \quad (8)$$

由式(8)可知, y_* 为正态分布。期望 $\bar{y}_*$ 与方差 σ_*^2

$$\begin{cases} \bar{y}_* = \mu^T \phi(x_*) \\ \sigma_*^2 = \sigma_{mp}^2 + \phi^T(x_*)E\phi(x_*) \end{cases}. \quad (9)$$

2 小波变换分解风速与风功率时间序列

小波分析主要是为了分析非线性、非平稳信号的局部特性,将一个已知的基本函数 $\psi(t)$ 经平移和

缩放后与被分析的信号作比较,得到在各个时刻、各种局部范围的局部特性^[18]。

将任意 $L^2(R)$ 空间中的函数 $x(t)$ 在小波基下展开^[15], 即

$$WT_x(m, n) = \left[\int_R x(t) \psi\left(\frac{t-n}{m}\right) dt \right] / \sqrt{|m|} \quad (10)$$

式(10)中: $\psi(t)$ 是一母小波; m, n 为尺度参数和位移参数。

将 m, n 同时离散化, 即 $m=m_0^j, n=k m_0^j n_0$, 对应的离散小波函数 $\psi_{j,k}(t)$ 为

$$WT_x(j, k) = \int_R x(t) \psi_{j,k}(t) dt \quad j, k \in Z \quad (11)$$

在信号的多分辨率分析基础上, Mallat 提出了计算离散正交小波变换的快速算法, 即 Mallet 算法^[19]。它是一种类金字塔式的层层分解算法, 其基本原理是: 将信号 $x(t)$ 正交投影到空间 V_j 和 W_j , 能对应得到分辨率 j 下的离散逼近信号 $c_j(t)$ 和离散细节信号 $d_j(t)$, 令 j 由零逐级增大, 便可得信号分解的逐级实现^[20]。

对原始风速数据和功率数据进行小波分解(WT), 选择不同的小波函数和分解层数进行小波分解, 信号重构误差见表 1。

表 1 不同的小波函数和分解层数对
风电功率数据分解的重构误差($\times 10^{-10}$)

Table 1 Reconstruction error comparison between
different wavelet function and decompose layers($\times 10^{-10}$)

误差	db ₄ 小波	db ₅ 小波	db ₆ 小波
3层分解重构误差	2.863 9	4.250 8	2.423 2
4层分解重构误差	3.807 8	5.935 5	3.289 7
5层分解重构误差	5.294 4	9.036 3	4.947 3

对比表 1 的数据可以发现, 运用不同的小波函数对文中选用的风电场功率序列进行不同层次分解, db₆ 小波比其他小波函数能更好地减少重构误差。综合考虑, 文中选用紧支撑双正交 db₆ 小波对风速和功率信号进行 3 层小波分解, 分解后得到的子序列见图 1、2。

从图 1、2 可以看出, 随着分解层数的增加, 风速时间序列和功率时间序列渐趋平缓。此外, 由于风速受多种因素的影响, 数据中通常会存在一些突变的点, 而这些数据点往往会造成预测结果与真实值存在很大差异, 利用小波分解可以有效剔除风速数据中这些突变点, 增强稳定性, 提高预测精度。

3 基于小波变换和相关向量机功率预测模型构建

1) 采用小波变换对原始风速时间序列进行分




图 1 风速的小波分解结果

Fig. 1 WT analysis result of wind speed time series




图 2 风功率的小波分解结果

Fig. 2 WT result of power time series

解, 将非平稳时间序列分解成具有不同尺度特征的平稳序列, 得到 1 个低频趋势分量 $\{x_1(n)\}$ 和 3 个高频波动分量 $\{x_2(n)\}$ 、 $\{x_3(n)\}$ 、 $\{x_4(n)\}$, n 为样本数;

2) 将分解得到的风速趋势分量与原始风向、温度数据共同组成输入矩阵 $\{x_1\} = \{x_1(n), d_n, t_n\}$, 输入至 RVM1 模型, 将 3 个风速波动分量结合风向、温度形成矩阵 $\{x_2\}$ 、 $\{x_3\}$ 、 $\{x_4\}$ 分别输入 RVM2-4 模型, 4 个 RVM 模型进行回归预测, 得到 4 组预测分量;

3) 将 4 组预测分量进行小波重构, 得到最终功率预测结果。

4 算例

文中选取国内某风电场 2012 年 6 月中某 10 天的数据, 风速、风向及温度数据每隔 10 min 采样一次, 共计 240 h。选取预测点前 9 天共 216 个小时的实际数据形成训练样本, 对预测点及之后一天 24 h 的风功率进行预测。风电场一共 36 台风机, 每台容量 2 MW, 切入风速 3 m/s, 额定风速 18 m/s, 切出风速 23 m/s。

为了衡量预测结果, 选取国家电网发布的《风电功率预测功能规范》中均方根误差作为统计指标。

$$E_{ms} = \sqrt{\sum_{i=1}^n (P_{Mi} - P_{Pi})^2 / (C_{ap} \cdot \sqrt{n})} \quad (12)$$

式(12)中: P_{Mi} 为*i*时刻实际功率; P_{Pi} 为*i*时刻预测功率; C_{ap} 为装机容量; n 为样本个数。

4.1 基于相关向量机的风功率预测

根据风电场实际运行数据,选择风速、风向以及温度作为输入变量,应用单一 RVM 模型进行风功率预测,结果见图 3。从图 3 可以看出,对于风速均匀变化的时间点,该方法能够较为准确预测,但对于风速突变的时间点,预测效果较差,精度不够稳定。




图 3 单一 RVM 预测图

Fig. 3 The figure of power prediction by RVM

4.2 基于小波变换和相关向量机结合的风功率预测

对原始风速和功率数据集用 db_6 小波进行小波分解,结果如图 1、2。

将分解后的训练数据结合风向、温度数据,通过 RVM 训练得到预测模型,然后对预测数据集进行回归预测,得到最终的功率预测结果见图 4。从图 4 可以看出,预测误差整体呈现先小后大的趋势,即在最初的预测点处,预测误差较小,随着预测时间增长以及固有的误差累计,预测误差有所增大,但整体预测效果仍然较好。




图 4 WT-RVM 法预测结果

Fig. 4 The result of RVM prediction used WT

为了分析文中组合模型的有效性,用 RVM 预测,EMD-RVM 预测与文中提出的 WT-RVM 3 种方法得到预测结果进行分析对比,结果见图 5。

单一 RVM 法的预测结果均方根误差为 0.134 7, EMD-RVM 法的预测误差为 0.094 7,文中所提出的 WT-RVM 法的预测误差为 0.071 8。可以看出,与单一 RVM 法相比,WT-RVM 法的预测精度提升明显,原因为对风速序列进行小波分解,使其形成规律性和相关性较好的子序列,同时可有效去除白噪声,从而能够有效提高预测精度。与 EMD-RVM 法相




图 5 风功率预测结果

Fig. 5 Wind power prediction results

比,WT-RVM 法预测精度有所提升。EMD 没有基函数,分解结果由自适应性产生,而且存在模态混叠现象影响准确性;小波分析对于小波函数的选择相对自由,一旦选定了合适的小波函数和分解层次,分析过程简单且精度高,特别是对风速突变点,该方法得到了稳定可靠的预测结果。

5 结语

文中将小波变换和相关向量机结合引入风功率预测理论中,小波变换用来分解风速降低信号的非平稳性,RVM 法可以建立输入输出变量间的非线性关系,形成回归预测模型。该方法满足《风电功率预测功能规范》中规定预测均方根误差应小于 20% 的要求,并通过分析小波重构误差选择合适的小波函数和分解层数,与单独使用 RVM 法相比,WT-RVM 法有精度更高的预测效果;与 EMD-RVM 法相比,WT-RVM 对于风速突变点的预测更为稳定及准确。

参考文献:

- [1] KHALID M, SAVKIN A V. A method for short-term wind power prediction with multiple observation points[J]. IEEE Transactions on Power Systems, 2013, 28(2): 1898-1899.
- [2] SOMAN S S, ZAREIPOUR H, MANDAL O, et al. A review of wind power forecasting methods with different time horizons[C]//North American Power Symposium. Arlington: [s. n.], 2010: 26-28.
- [3] GAO Shuang, DONG Lei, LIAO Xiaozhong. Wind power prediction based on multiposition NWP with rough set theory [C]//Control and Decision Conference (CCDC), 2013 25th Chinese. China: IEEE, 2013: 2513-2518.
- [4] 冯双磊, 王伟胜, 刘纯, 等. 基于物理原理的风电场短期风速预测研究[J]. 太阳能学报, 2011, 32(5): 611-616. FENG Shuanglei, WANG Weisheng, LIU Chun, et al. Short term wind speed prediction based on physical principle[J]. Acta Energiæ Solaris Sinica, 2011, 32(5): 611-616.
- [5] FOLEY A M, LEAHY P G, MCKEOGH E J. Wind power forecasting & prediction methods[C]//Environment and

- Electrical Engineering(EEEIC).[S.l.]:IEEE,2010;16-19.
- [6] 王宁,叶林,陈盛,等. 支持向量机向量维数对短期风电功率预测精度的影响[J]. 电力系统保护与控制, 2012,40(15):63-69.
WANG Ning, YE Lin, CHEN Sheng, et al. Influence of the vector- dimension of SVM on short-term wind power prediction accuracy[J]. Power System Protection and Control, 2012,40(15):63-69.
- [7] MAO Meiqin, CAO Yu, CHANG Liuchen. Improved fast short-term wind power prediction model based on superposition of predicted error[C]//Power Electronics for Distributed Generation Systems(PEDG).[S.l.]:IEEE,2013;8-11.
- [8] 常鹏,高亚静,张琳,等. 基于EEMD与时间序列法的短期风电场功率预测[J]. 电力科学与工程,2012,28(3):33-39.
CHANG Peng, GAO Yajing, ZHANG Lin, et al. Short-term power forecast of wind farm based on EEMD and time series[J]. Electric Power Science and Engineering, 2012, 28(3):33-39.
- [9] 肖迁,李文华,李志刚,等. 基于改进的小波—BP神经网络的风速和风电功率预测[J]. 电力系统保护与控制, 2014,42(15):80-86.
XIAO Qian, LI Wenhua, LI Zhigang, et al. Wind speed and power prediction based on improved wavelet-BP neural network[J]. Power System Protection and Control, 2014,42(15):80-86.
- [10] MENG Li, SHI Jinwei, WANG Hao, et al. SVM with improved grid search and its application to wind power prediction[C]//IEEE Conference Publications.Tianjin:IEEE, 2013;603-609.
- [11] 严欢,卢继平,覃俏云,等. 基于多属性决策和支持向量机的风电功率非线性组合预测[J]. 电力系统自动化, 2013,37(10):29-34.
YAN Huan, LU Jiping, QIN Qiaoyun, et al. A nonlinear combined model for wind power forecasting based on multi-attribute decision-making and support vector machine[J]. Automation of Electric Power Systems, 2013,37(10):29-34.
- [12] 杨晓萍,王宝,兰航,等. 风电场短期功率预测[J]. 电力系统及其自动化学报,2015,27(9):85-90.
YANG Xiaoping, WANG Bao, LAN Hang, et al. Short-term wind farm power prediction[J]. Proceedings of the CSU-EPSA, 2015,27(9):85-90.
- [13] TIPPING M E. Sparse bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research, 2001,1(1):211-244.
- [14] 杨明,范澍,韩学山,等. 基于分量稀疏贝叶斯学习的风电场输出功率概率预测方法[J]. 电力系统自动化, 2012,36(14):125-130.
YANG Ming, FAN Shu, HAN Xueshan, et al. Wind farm generation forecast based on componential sparse bayesian learning[J]. Automation of Electric Power Systems, 2012, 36(14):125-130.
- [15] HUANG S C, WU T K. Wavelet-based relevance vector machines for stock index forecasting[C]//IEEE International Joint Conference on Neural Networks. [S.l.]:IEEE,2006;603-609.
- [16] 黄帅栋,卫志农,高宗和,等. 基于非负矩阵分解的相关向量机短期负荷预测模型[J]. 电力系统自动化,2012,36(11):62-66.
HUANG Shuaidong, WEI Zhinong, GAO Zonghe, et al. A short-term load forecasting model based on relevance vector machine with nonnegative matrix factorization[J]. Automation of Electric Power Systems, 2012,36(11):62-66.
- [17] LIN N, LIU M, ZHAO J G, et al. Prediction of audible noise from UHV AC transmission lines based on relevance vector learning mechanism[C]//IEEE Trans. on Power Apparatus and Systems.[S.l.]:IEEE,2010;1-5.
- [18] CATALA J P S, POUSINHO H M I, MENDES V M F. Hybrid wavelet-PSO-ANFIS approach for short-term wind power forecasting in portugal[J]. IEEE Transactions on Sustainable Energy, 2011,2(1):50-59.
- [19] 陈盼,陈皓勇,叶荣,等. 基于小波包和支持向量回归的风速预测[J]. 电网技术,2011,35(5):177-182.
CHEN Pan, CHEN Haoyong, YE Rong, et al. Wind speed forecasting based on combination of wavelet packet analysis with support vector regression[J]. Power System Technology, 2011,35(5):177-182.
- [20] 王丽婕,冬雷,廖晓钟,等. 基于小波分析的风电场短期发电功率预测[J]. 中国电机工程学报,2009,29(28):30-33.
WANG Lijie, DONG Lei, LIAO Xiaozhong, et al. Short-term power prediction of a wind farm based on wavelet analysis[J]. Proceedings of the CSEE, 2009,29(28):30-33.
- 刘雨莎(1989—),女,硕士研究生,主要研究新能源技术。
杨晓萍(1963—),女,教授,硕士生导师,主要研究为电力系统运行与控制。