

doi:10.3969/j.issn.1673-9833.2019.01.007

基于支持向量机和误差修正算法的风电短期功率预测

王建辉, 匡洪海, 张瀚超, 朱国平

(湖南工业大学 电气与信息工程学院, 湖南 株洲 412007)

摘 要: 基于风电功率预测单一算法带来的预测精度较低问题, 提出一种新型的基于粒子群优化支持向量机结合误差修正算法的短期风电功率预测组合算法。该方法首先对原始数据进行分析 and 清洗; 然后通过粒子群算法对支持向量机参数进行寻优, 对风电功率进行一次预测, 通过经验模态算法对一次预测进行滤波, 达到降噪效果, 同时得到一次预测误差; 最后, 利用误差修正算法对一次预测误差进行修正, 得到最终的预测值。仿真和测试结果表明, 相较于传统的单一算法, 该组合算法能更好地提高预测精度。

关键词: 风电功率预测; 粒子群寻优; 支持向量机; 误差修正; 预测方法

中图分类号: TM614

文献标志码: A

文章编号: 1673-9833(2019)01-0043-07

引文格式: 王建辉, 匡洪海, 张瀚超, 等. 基于支持向量机和误差修正算法的风电短期功率预测 [J]. 湖南工业大学学报, 2019, 33(1): 43-49.

Short-Term Wind Power Prediction Based on SVM and Error Correction Algorithm

WANG Jianhui, KUANG Honghai, ZHANG Hanchao, ZHU Guoping

(College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China)

Abstract: A new short-term wind power forecast combination algorithm, which is based on particle swarm optimization and support vector machine (SVM), combined with error correction algorithm, has been proposed. Firstly, an analysis and cleaning have been made of the original data; then an optimization can be achieved of the parameters of support vector machine by particle swarm optimization algorithm, followed by a prediction of the wind power. The empirical modal algorithm is used to filter the primary prediction to achieve the effect of noise reduction, thus working out the primary prediction error. Finally, the error correction algorithm is used to correct the one-time prediction error, thus obtaining the final prediction value. The simulation and test results show that the combined algorithm can improve the prediction accuracy better than the traditional single algorithm.

Keywords: wind power prediction; particle swarm optimization(PSO); support vector machine(SVM); error correction; prediction method

0 引言

随着风电技术的不断发展, 风能将成为未来能源

的主要结构。但由于风速本身的随机特性, 导致风电功率具有高度随机性, 大规模的风电并网, 会导致电网出现电压、频率的波动, 影响电网的平稳运行^[1-2]。

收稿日期: 2018-05-16

基金项目: 湖南省自然科学基金资助项目 (2018JJ4076)

作者简介: 王建辉 (1992-), 男, 山西文水人, 湖南工业大学硕士生, 主要研究方向为新能源功率预测及并网技术, E-mail: 619740286@qq.com.

通信作者: 匡洪海 (1972-), 女, 湖南双峰人, 湖南工业大学教授, 博士, 硕士生导师, 主要从事分布式发电技术和配电网停电技术方面的教学与研究, E-mail: khhzyz@163.com.

短期风电功率预测可以给电网调度和控制提供依据,有效减小风电功率对电网的影响,增加电网的安全性、稳定性和可靠性。

目前,短期风电功率预测的方法主要有两种^[3]:一是物理方法,即首先利用电场所在地经纬度、地形、气候等自然条件建立模型,得到气象信息,然后根据风机的出力曲线计算得出风机的输出功率^[4];二是统计方法,即收集风电场历史运行数据,在历史气象数据与历史实际功率间建立函数关系,然后根据实时气象信息预测其未来功率。统计方法中的建模方法主要包括时间序列法^[5]、卡尔曼法^[6]、神经网络法^[7]、支持向量机法^[8-15]、小波分析法^[16]和灰色预测法^[17]。

以上各种方法都有其自身特点,但是在应用时都存在一定的不足。目前,采用单一算法进行预测所得的精度不高,一般为60%~75%^[18-19]。显然,单一预测算法已经无法满足预测精度的要求。为此,本文提出一种基于支持向量机(support vector machine, SVM)和误差修正算法的组合预测算法,并且利用Matlab 2015进行建模分析,以期提高风电场短期功率的预测水平,为风电场的发电规划提供参考依据。

1 数据清洗

前期采集的风电场数据量庞大、数据种类较多,不可避免地含有缺失、重复、错数等各类问题,这会干扰后期的建模,因此,建模前需对采集的原始数据进行处理,通过判断和修正获得高精度的可用数据。

1.1 数据分析

数据质量控制是正确反映风电场运行情况的先决条件。风电场数据异常状态有缺数、死数、错数、校验不通过(如限电)4种形式。


1) 缺数的判断规则。当相邻数据时间点的时间差大于数据整体的分辨率时,则可判断存在数据缺失。

2) 死数的判断规则。当连续相邻数据的绝对误差为0的个数大于或等于8(或者10)时,可以认为出现了死数(重复值)。


3) 错数的判断规则。i) 风速的合理范围为[0, 60] m/s,每小时平均风速的合理范围为[0, 40] m/s;风向的合理范围为[0, 360]°;气压的变化范围为[500, 1100] hPa;湿度的合理范围为[0, 100%]RH;环境温度的合理范围为[-60, 60]°C,组件温度的合理范围为[-60, 150]°C。ii) 单机输出功率的合理范围为[-10% p , 110% p] MW,其中 p 为单机额定功率。iii) 全场实际功率的合理范围为[-10% P , 110% P]

MW,其中 P 为额定装机容量。iv) 全场预测功率的合理范围为[0, 110% P] MW。

4) 校验不通过的判断规则。校验不通过的数据往往是由人为、自然等因素造成的,风电场的限电、检修或者极端天气下的风机切出等,都会造成气象数据与功率的不匹配,这就是校验不通过数据。校验不通过数据的特征如下:单维数据(如风速、气压、功率)呈正常化,多维数据的联合分布呈畸形化,图1所示为多维数据的联合分布对比图,其中a图为正常的风速-功率联合分布,呈S型;b图为限电情况下的风速-功率联合分布,呈畸形。这往往需要人工依据经验进行判断。



a) 正常的风速-功率联合分布



b) 限电的风速-功率联合分布

图1 多维度数据联合分布对比

Fig. 1 Comparison of joint distribution of multi-dimensional data

1.2 数据清洗

针对以上方法判断出来的缺数、死数、错数及校验不通过的数据,均需要进行处理。

1) 缺数的处理。i) 当数据缺失数小于8个时,可以采用差值法(如线性差值法)进行填补。ii) 当数据缺失数大于或等于8个时,如果其对数据处理不产生影响,则可以直接删除,否则会增加模型输入误差,影响最终预测精度。

2) 死数的处理。依据死数的判断规则,当出现死数时,予以删除。

3) 错数的处理。i) 风速小于0 m/s时,以0 m/s代替;风速大于60 m/s时,以60 m/s代替;对风向、温度、湿度、气压等的错误处理方式类同风速的处理方式。ii) 功率数据小于 T_{p1} 时,以 T_{p1} 代替,其中 $T_{p1} = -P \times 10\%$;功率数据大于 T_{p2} 时,以 T_{p2} 代替,其中 $T_{p2} = P \times 110\%$ 。

4) 校验不通过数据的处理。原始数据, 由于限电、检修及自然因素等原因, 得到的数据并不能够完全可信, 可能导致数据不合理或者校验不通过。因此, 需要对校验不通过的数据进行处理, 即利用标准四分位距 (norm inter quartile range, NIQR) 法判断数据的合理性, 并删除不符合要求的数据。

2 支持向量机

支持向量机基于结构风险最小化思想, 具有很好的泛化能力, 面对小样本问题时仍能得到较小的误差。此外, SVM 算法本质上是计算二次规划问题, 保证了其找到的极值解为全局最优解。SVM 最初常被用于解决分类问题, 随着不敏感损失函数 ε 的引入, 发展为解决非线性回归问题的支持向量回归 (support vector regression, SVR)。SVR 引入了非线性核函数 k , 将低维的样本点利用非线性函数 k 映射到高维特征空间, 再在高维特征空间内进行线性回归。

SVR 预测的基本思想如下: 给定一组观测样本集序列 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$; $x_n \in \mathbf{R}^n$; $y_n \in \mathbf{R}$, 则其回归方程见式 (1)。

$$F = \{f | f(x) = \mathbf{w}^T x + b, \mathbf{w} \in \mathbf{R}^n\}。 \quad (1)$$

式 (1) 的回归问题等价于最小化代价泛函:

$$\begin{cases} \min \left[\frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{C}{n} \sum_{i=1}^n (\xi_i + \xi_i^*) \right], \\ \text{s.t.} \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i, \\ y_i - f(x_i) \leq \varepsilon + \xi_i^*, \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, n. \end{cases} \end{cases} \quad (2)$$

式 (2) 中: C 为惩罚系数; ξ_i 、 ξ_i^* 均为松弛因子; ε 为不敏感损失系数。

引入拉格朗日乘子, 将式 (2) 转化为如下求解对偶问题:

$$\begin{cases} \min \left[\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (a_i^* - a_i)(a_j^* - a_j) K(x_i, x_j) \right] + \\ \quad \varepsilon \sum_{i=1}^n (a_i^* + a_i) - \sum_{i=1}^n y_i (a_i^* + a_i); \\ \text{s.t.} \sum_{i=1}^n (a_i - a_i^*) = 0, \text{ 且 } 0 \leq a_i, a_i^* \leq \frac{C}{n}. \end{cases} \quad (3)$$

式 (3) 中: $K(x_i, x_j)$ 为核函数, 满足 Mercer 条件; a_i 和 a_i^* 均为拉格朗日乘子。

求解式 (3), 可得其最优回归函数如式 (4) 所示:

$$f(x) = \sum_{i=1}^n (a_i - a_i^*) K(x_i, x_j) + b。 \quad (4)$$

本文选用 RBF 核函数作为风电功率预测研究的核函数, 如式 (5) 所示:

$$K(x_i, x_j) = \exp\left(-\|x - x_i\|^2 / 2\sigma^2\right)。 \quad (5)$$

本研究中将利用粒子群寻优 (particle swarm optimization, PSO) 算法, 在模型训练阶段, 对 C 、 ε 以及核函数的 σ 3 个参数进行自动寻优。

3 误差修正算法

利用误差修正算法, 通过寻找合适的修正因子, 达到对一次预测误差的再处理。本文不是单纯地通过误差序列直接寻找修正因子, 而是通过误差的时间标签选取历史相似日的误差。通过这种方案, 可以更好地模拟历史相似日的误差项, 从而达到对未来相似日的精准修正。寻找修正因子的方法主要有中位数法、多项式拟合法和排序聚类法。其实现过程如下: 在生成一次误差序列的基础上, 首先寻找误差的中位数, 作为修正因子①; 然后利用同时段的误差序列和风速进行多项式拟合, 作为修正因子②; 接下来对误差序列进行特征分析, 再基于特征进行聚类, 作为修正因子③; 最后对各修正因子进行加权平均, 得到最终的修正参数。

3.1 中位数法

中位数 (median) 又称中点数、中值。中位数是按顺序排列的一组数据中居于中间位置的数, 不受其自身数列固有特性的影响, 因而中位数更具有代表性。如有一组数据: $X: \{x_{i1}, x_{i2}, \dots, x_{in}\}$, 将它按从小到大的顺序排序为 $X: \{x_{(1)}, x_{(2)}, \dots, x_{(n)}\}$, 则当 n 为奇数时, 中位数 $x_m = x_{(n+1)/2}$; 当 n 为偶数时, $x_m = x_{(n/2)}$ 或 $x_{(n/2)+1}$ 。

本文首先基于历史同一时刻对一次预测误差进行分类, 然后分别求取各类中位数, 作为中位数二次修正误差。

3.2 多项式拟合法

多项式拟合是指给定一组原始序列, 在未知函数关系 $y=f(x)$ 的情况下, 根据序列数据的内在特性, 找出一个含有 $(k+1)$ 个参数的 k 阶多项式来逼近原始数组及 $y = f(x) = a_0 + a_1x + a_2x^2 + \dots + a_kx^k$ 。对于同一序列数据, 很难判定哪一阶数的多项式具有更好的拟合效果, 往往越高阶项对 y 的影响越小。

本研究采用一阶拟合, 利用历史同一时刻的一次预测误差和风速建立回归拟合方程, 拟合误差系数与常数项, 再将实时风速代入拟合方程, 得出的结果作为多项式拟合修正误差。

3.3 排序聚类法

首先,基于历史同一时刻对一次预测误差和风速进行分类,同类按风速大小排序并三等分;然后,对同等分风速取平均值、对同等分一次预测误差取中位数,得到排序聚类后的平均风速和误差中位数矩阵;最后,以风速的误差最小项为索引,取误差的中位数为排序聚类修正误差。对3种修正算法得到的修正误差进行平均处理,结合一次预测结果,将其作为最终的预测值。

4 基于支持向量机和误差修正算法的组合预测建模

4.1 算法实现步骤

Step 1 实际功率、风速前期数据质量控制处理,包括对死数、错数进行删除处理,对缺数进行插值或删除处理等。

Step 2 利用粒子寻优算法,对支持向量回归机的惩罚参数 C 、回归区间 ε 进行寻优。

Step 3 基于 PSO-SVR-EMD 模型对功率进行回归拟合。

Step 4 计算实际功率与预测功率的误差,输出一组预测的误差序列、风速序列、时间序列。

Step 5 调用二次预测函数,步骤如下:1)计算历史相同时刻一次预测误差的中位数,返回中位数误差矩阵;2)对历史相同时刻一次预测误差、风速作一次回归拟合,得到拟合方程,再将实时的同时刻风速代入拟合方程,得到拟合误差矩阵;3)按照风速大小,对误差序列、风速序列进行排序聚类,返回风速均值矩阵、误差中位数矩阵;4)对3种误差修正值加权平均,返回误差修正值。

Step 6 输出 Figure,包括实际功率、一次预测功率、组合修正预测功率等在 N 个时刻下的平均值;输出表格,包括时间、实际功率、原始预测功率、修正预测功率等数据。

4.2 预测误差的评价函数

预测误差的评估采用国家电网关于新能源下发的《风电功率预测评价管理规定》中的均方误差(mean squared error, MSE)计算方式,日均方根误差计算如式(6)所示:

$$MSE_{\text{日}} = \sqrt{\sum (P_{\text{实际功率}} - P_{\text{预测功率}})^2 / N} / c \quad (6)$$

式中: $MSE_{\text{日}}$ 为日均方根误差; N 为数据量(每日96个点); c 为装机容量。

月均方根误差计算式见式(7),式中 T 为天数。

$$MSE_{\text{月}} = \sum MSE_{\text{日}} / T \quad (7)$$

5 实例分析

5.1 研究对象、参数与方案

1) 原始数据。原始数据为某风电场2016年10月1日至2017年12月31日的历史数据,包括实际功率、70 m 风速,每15 min 收集1个采样点,共得近30 000条原始数据。对原始数据进行清洗,删除实际功率小于0、实际功率大于装机容量、实际功率连续重复值、限电时段等异常值,最后得到23 917条清洗后的数据。图2显示了清洗后的实际功率。




图2 风电场实际功率输出曲线

Fig. 2 Wind farm actual power output curves

从图2所示功率输出曲线的变化情况看,这些数据遍及风电功率的各种状态,能很好地反映风电场的实际运行情况,是一组比较理想的仿真数据。

2) 输入、输出量。输入量为清洗后的风速数据,输出量为清洗后的实际功率数据。且在训练阶段,取前20 000条清洗后的风速与功率数据作为训练数据;在测试阶段,取后2 000条清洗后的风速与功率数据为测试数据。

3) 参数寻优方案。采用 PSO 算法优化选择 SVR 学习参数进行训练,通过多次交叉验证寻找训练误差最小时的学习参数。学习参数搜索范围如下: $C \in [60, 150]$, $\varepsilon \in [0.01, 1.01]$, $\sigma = 50$ 。PSO 群体规模取200,学习因子取1,最大迭代次数取10。

5.2 PSO-SVR 模型输入量不同时的仿真对比

针对风速随机性较强的特征,将 PSO-SVR 模型的输入量由一维风速转化为多维风速,即利用历史多个风速点来预测未来出力。为了验证此方法的有效性,采用基于粒子群支持向量机的风电功率预测模型进行预测,所得3种不同输入的风电功率对比预测结果如图3所示。表1是输入不同维度风速时的预测误差对比。

从图3可以看出,随着输入维度的提高,预测曲

线逐步逼近真实值, 且预测曲线较为平滑。当输入超

过三维时, 预测效果逐渐变差, 局部开始出现负值。




图3 3种不同风速输入下的风电功率预测曲线

Fig. 3 Three different types of wind power prediction curves

表1 3种不同风速输入下的风电功率预测误差对比

Table 1 Comparison of three types of wind power prediction errors

输入量	MSE	MAE
一维风速	47.995 1	6.897 9
三维风速	30.236 5	5.493 1
五维风速	146.339 2	12.071 8

由表1中的数据可知, 当输入三维风速进行预测时, 其MSE和MAE指标分别为30.24和5.49, 为不

同输入量时的最小值, 证明该输入方案有效降低了由风速造成功率的波动性, 因此接下来的预测模型选择三维风速作为输入量。

5.3 PSO-SVR和PSO-SVR-EMD的仿真对比

为了验证PSO-SVR-EMD预测模型的可靠性, 分别用PSO-SVR和PSO-SVR-EMD进行预测对比, 图4为原始数据和两种预测值对比图。




图4 两种模型的预测曲线对比图

Fig. 4 Comparison of prediction curves of two models

从图4中的曲线可以看出, 相较于PSO-SVR预测曲线, 利用EMD算法经过一次滤波后的预测曲线明显平滑了许多, 预测精度也相对提高。表2展示了两种模型的MSE指标和MAE指标。

通过图4和表2的比较, 可知PSO-SVR-EMD算法能有效降低预测曲线的粗糙度, 达到平滑的效果; 同时能有效降低预测误差指标。因此, 接下来选择PSO-SVR-EMD模型对风电功率进行预测。

表2 PSO-SVR与PSO-SVR-EMD预测误差对比

Table 2 Comparison of prediction errors between PSO-SVR and PSO-SVR-EMD

算 法	MSE	MAE
PSO-SVR	30.236 5	5.493 1
PSO-SVR-EMD	28.445 8	5.331 1

5.4 PSO-SVR-EMD-EF的仿真结果

确定了PSO-SVR-EMD的基本预测模型后, 为

了验证 EF 算法的修正效果, 将前文得到的预测值、实际值、误差作为 EF 算法的输入量, 得到修正后的

预测值。PSO-SVR-EMD 与 PSO-SVR-EMD-EF 模型的对比预测效果如图 5 所示。




图 5 PSO-SVR-EMD 与 PSO-SVR-EMD-EF 预测对比图

Fig. 5 Comparison of PSO-SVR-EMD and PSO-SVR-EMD-EF predictions

将各个模型的预测误差指标进行列表对比, 如表 3 所示。

表 3 各方案预测误差指标对比

Table 3 Comparison of prediction error indicators for each scheme

算 法	MSE	MAE
PSO-SVR	30.236 5	5.493 1
PSO-SVR-EMD	28.445 8	5.331 1
PSO-SVR-EMD-EF	21.117 4	4.597 4

从图 5 和表 3 所示的仿真结果来看, 在选取适当的模型输入量后, 利用 PSO-SVR-EMD 算法, 不仅能提高预测的平滑度, 达到降噪的效果, 同时能提高预测的精度。可见, PSO-SVR-EMD 结合 EF 算法, 可以大大提高预测的准确度。

6 结论

本研究为基于支持向量机和误差修正算法的风电短期功率预测, 针对风速的随机性, 采用选取适当的模型输入量结合 EMD 算法达到降噪目的。当使用 PSO-SVR-EMD 预测后, 增加了误差修正环节, 大大提高了预测的精度。通过对实际数据的仿真和分析, 可得出以下结论:

1) 前期的数据清洗规则, 在有效地清洗原始干扰的同时, 能很好地保留数据的完整性和代表性, 有效降低了原始干扰带来的预测误差。

2) 前期选取适当的模型输入量, 后期通过 EMD 算法对预测值进行滤波, 有效地弱化了风速的随机性, 达到降噪效果, 同时能提高预测精度。

3) 误差修正算法的支持向量机风电预测模型比

传统的单一预测模型具有更好的预测准确性, 预测结果的均方根误差和平均误差均有所降低。

本文前期模型输入量的选取, 其实质为对数据的特征选取。本文主要通过人为选取输入量, 并未通过相关的特征选取算法和理论进行特征筛选。因此, 对数据的特征分析将是未来的研究方向。

参考文献:

- [1] 陈树勇, 宋书芳, 李兰欣, 等. 智能电网技术综述 [J]. 电网技术, 2009, 33(8): 1-7.
CHEN Shuyong, SONG Shufang, LI Lanxin, et al. Survey on Smart Grid Technology[J]. Power System Technology, 2009, 33(8): 1-7.
- [2] FOCKEN U, LANGE M, HEINEMANN D. Previento: Regional Wind Power Prediction with Risk Control[EB/OL]. [2018-05-10]. <http://www.doc88.com/p-1886563969349.html>.
- [3] 钱 政, 裴 岩, 曹利霄, 等. 风电功率预测方法综述 [J]. 高电压技术, 2016(4): 1047-1060.
QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of Wind Power Forecasting Method[J]. High Voltage Engineering, 2016(4): 1047-1060.
- [4] 朱晓荣, 刘艳萍. 基于稳健估计时间序列法的风功率预测 [J]. 电力系统及其自动化学报, 2012, 24(3): 107-110, 126.
ZHU Xiaorong, LIU Yanping. Wind Power Forecasting Using Time Series Model Based on Robust Estimation[J]. Proceedings of the CSU-EPSCA, 2012, 24(3): 107-110, 126.
- [5] 周松林, 茆美琴, 苏建徽. 基于主成分分析与人工神

- 经网络的风电功率预测[J]. 电网技术, 2011, 35(9): 128-132.
- ZHOU Songlin, MAO Meiqin, SU Jianhui. Prediction of Wind Power Based on Principal Component Analysis and Artificial Neural Network[J]. Power System Technology, 2011, 35(9): 128-132.
- [6] 潘迪夫, 刘 辉, 李燕飞. 风电场风速短期多步预测改进算法[J]. 中国电机工程学报, 2008, 28(26): 87-91.
- PAN Difu, LIU Hui, LI Yanfei. Optimization Algorithm of Short-Term Multi-Step Wind Speed Forecast[J]. Proceedings of the Chinese Society for Electrical Engineering, 2008, 28(26): 87-91.
- [7] 张立影, 孟令甲, 王泽忠. 基于双层BP神经网络的光伏电站输出功率预测[J]. 电测与仪表, 2015, 52(11): 31-35.
- ZHANG Liying, MENG Lingjia, WANG Zezhong. Photovoltaic Power Station Output Power Prediction Based on Double BP Neural Network[J]. Electrical Measurement and Instrumentation, 2015, 52(11): 31-35.
- [8] 栗 然, 柯拥勤, 张孝乾, 等. 基于时序-支持向量机的风电场发电功率预测[J]. 中国电力, 2012, 45(1): 64-68.
- LI Ran, KE Yongqin, ZHANG Xiaoqian, et al. Wind Power Forecasting Based on Time Series and SVM[J]. Electric Power, 2012, 45(1): 64-68.
- [9] 丁志勇, 杨 苹, 杨 曦, 等. 基于连续时间段聚类的支持向量机风电功率预测方法[J]. 电力系统自动化, 2012, 36(14): 131-135, 139.
- DING Zhiyong, YANG Ping, YANG Xi, et al. Wind Power Prediction Method Based on Sequential Time Clustering Support Vector Machine[J]. Automation of Electric Power Systems, 2012, 36(14): 131-135, 139.
- [10] 王 恺, 关少卿, 汪令祥, 等. 基于模糊信息粒化和最小二乘支持向量机的风电功率联合预测建模[J]. 电力系统保护与控制, 2015, 43(2): 26-32.
- WANG Kai, GUAN Shaoqing, WANG Lingxiang, et al. A Combined Forecasting Model for Wind Power Prediction Based on Fuzzy Information Granulation and Least Squares Support Vector Machine[J]. Power System Protection and Control, 2015, 43(2): 26-32.
- [11] 李 霄, 王 昕, 郑益慧, 等. 基于改进最小二乘支持向量机和预测误差校正的短期风电负荷预测[J]. 电力系统保护与控制, 2015, 43(11): 64-69.
- LI Xiao, WANG Xin, ZHENG Yihui, et al. Short-Term Wind Load Forecasting Based on Improved LSSVM and Error Forecasting Correction[J]. Power System Protection and Control, 2015, 43(11): 64-69.
- [12] 陈道君, 龚庆武, 金朝意, 等. 基于自适应扰动量子粒子群算法参数优化的支持向量回归机短期风电功率预测[J]. 电网技术, 2013, 37(4): 974-980.
- CHEN Daojun, GONG Qingwu, JIN Zhaoyi, et al. Short-Term Wind Power Prediction Based on Support Vector Regression Machine Optimized by Adaptive Disturbance Quantum-Behaved Particle Swarm Optimization[J]. Power System Technology, 2013, 37(4): 974-980.
- [13] 杨志凌, 刘永前. 应用粒子群优化算法的短期风电功率预测[J]. 电网技术, 2011, 35(5): 159-164.
- YANG Zhiling, LIU Yongqian. Short-Term Wind Power Prediction with Particle Swarm Optimization[J]. Power System Technology, 2011, 35(5): 159-164.
- [14] 王永翔, 陈国初. 基于改进鱼群优化支持向量机的短期风电功率预测[J]. 电测与仪表, 2016, 53(3): 80-84.
- WANG Yongxiang, CHEN Guochu. Short-Term Wind Power Prediction Based on IAFSA Optimized SVM[J]. Electrical Measurement and Instrumentation, 2016, 53(3): 80-84.
- [15] 叶 林, 刘 鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.
- YE Lin, LIU Peng. Combined Model Based on EMD-SVM for Short-Term Wind Power Prediction[J]. Proceedings of the Chinese Society for Electrical Engineering, 2011, 31(31): 102-108.
- [16] 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 Chinese Society for Electrical Engineering, 2009, 29(28): 30-33.
- [17] 孟祥星, 田成微, 冬 雷, 等. 灰色理论用于风力发电容量中长期预测的研究[J]. 电力系统保护与控制, 2011, 39(21): 81-85.
- MENG Xiangxing, TIAN Chengwei, DONG Lei, et al. A Study of Grey Theory Used in Prediction of Medium and Long-Term Wind Power Generation[J]. Power System Protection and Control, 2011, 39(21): 81-85.
- [18] 孟岩峰, 胡书举, 邓 雅, 等. 风电功率预测误差分析及预测误差评价方法[J]. 电力建设, 2013, 34(7): 6-9.
- MENG Yanfeng, HU Shuju, DENG Ya, et al. Analysis and Evaluation Method of Wind Power Prediction-Error[J]. Power Construction, 2013, 34(7): 6-9.
- [19] 李康平, 高亚晶. 一种结合合作博弈理论的风电功率预测方法[J]. 电力建设, 2014(2/3): 36-40.
- LI Kangping, GAO Yajing. A Combination Method for Wind Power Prediction Based on Cooperative Game Theory[J]. Electricity, 2014(2/3): 36-40.

(责任编辑: 廖友媛)