

DOI:10.3876/j.issn.1000-1980.2021.06.013

基于 VMD 和 IBA-LSSVM 的短期风电功率预测

王 瑞¹,陈泽坤¹,逯 静²

(1. 河南理工大学电气工程与自动化学院, 河南 焦作 454000;
2. 河南理工大学计算机科学与技术学院, 河南 焦作 454000)

摘要: 为了提高风电功率预测精度,提出了一种基于变分模态分解(VMD)和改进的最小二乘支持向量机(LSSVM)的短期风力发电功率预测新模型。利用 VMD 将功率历史数据分解成趋势分量、细节分量和随机分量以降低原始数据的复杂性和不平稳性,然后建立 IBA-LSSVM 预测模型,利用改进蝙蝠算法(IBA)对最小二乘向量机的参数进行优化,并分别对各个子模态进行预测,叠加子模态的预测结果以得到最终的发电功率预测值。对宁夏某风电厂功率预测结果证明了该模型的有效性,通过不同预测模型的对比验证了模型具有较高的预测精度。

关键词: 发电功率预测;风电;变分模态分解;蝙蝠算法;最小二乘支持向量机

中图分类号: TM614 **文献标志码:** A **文章编号:** 1000-1980(2021)06-0575-08

Short term prediction of wind power based on VMD and IBA-LSSVM

WANG Rui¹, CHEN Zekun¹, LU Jing²

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454000, China;
2. School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract: In order to improve the accuracy of wind power prediction, a new short-term wind power prediction method based on the variational mode decomposition (VMD) and the improved least squares support vector machine (LSSVM) is proposed. Firstly, VMD is used to decompose the historical power data into the trend component, detail component and random component to reduce the complexity and instability of original data. Then the IBA-LSSVM prediction model is established, the parameters of the least squares vector machine are optimized by the improved bat algorithm (IBA), and each sub mode is predicted separately. The final predicted wind power is obtained by superimposing the prediction results of sub modes. Finally, the power of a wind power plant in Ningxia is predicted by the proposed prediction method. The effectiveness of the model is proved by the error analysis of the prediction results. The comparison of different prediction methods verifies that the proposed model has higher prediction accuracy.

Key words: power generation forecast; wind power; variational mode decomposition; bat algorithm; least squares support vector machine

近年来为缓解能源紧张,减少环境污染,新能源的开发和利用持续增加,其中风能是具有巨大利用价值的新型清洁环保能源,被广泛应用于风力发电。未来的电力系统必然将为可持续的全球经济增长提供更高渗透率的清洁能源,然而大量清洁能源的不断接入给电力系统提出了前所未有的挑战^[1]。对风电场的功率进行短期预测,可以使电力调度部门能够提前根据风电功率变化,及时调整调度计划,保证电能质量,降低电力系统运行成本,这是减轻风电对电网造成不利影响、提高电网中风电装机比例的一种有效途径^[2]。

目前,国内外对于风力发电功率的预测已有了深入研究,按照预测模型的不同,可分为物理方法、统计方法和学习方法。其中,物理方法需要对所在风电场进行建模^[3],由于受气象预报更新频率的影响,该方法更适合中期风电功率预测。统计方法包括回归分析法^[4]、指数平滑法、时间序列法^[5-6]和灰色预测法。这种预测模型计算简单,但随着预测时间的增加预测精度会快速下降,且不能很好地适应非线性影响因素。

基金项目: 河南省科技攻关计划(182102210054);河南省高等学校重点科研项目(18A470012)
作者简介: 王瑞(1977—),男,副教授,硕士,主要从事电力系统分析研究。E-mail:wangrui@hpu.edu.cn
通信作者: 逯静,副教授。E-mail:lujing@hpu.edu.cn
引用本文: 王瑞,陈泽坤,逯静. 基于 VMD 和 IBA-LSSVM 的短期风电功率预测[J]. 河海大学学报(自然科学版),2021,49(6):575-582.
WANG Rui, CHEN Zekun, LU Jing. Short term prediction of wind power based on VMD and IBA-LSSVM[J]. Journal of Hohai University (Natural Sciences), 2021, 49(6): 575-582.

学习方法包括人工神经网络法^[7-9]、决策树^[10-11]和支持向量机^[12-14]等。其中,最小二乘支持向量机(least squares support vector machine, LSSVM)具有预测精度高、计算简单等优点。但是在实际的风电功率预测中,单一的预测模型存在局限性,无法取得最佳的预测效果,因此目前多采用组合预测模型,如周松林^[15]引入粒子群算法(particle swarm optimization, PSO)优化 LSSVM 参数寻优,可有效缩短搜索时间,但存在过早收敛的问题。赵凤展等^[16]采用蝙蝠算法(bat algorithm, BA)优化 LSSVM 模型,与 PSO-LSSVM 相比搜索过程具有更好的收敛性,但存在不能保持优化能力等问题。此外,组合预测模型中经常会用信号分解的方法,目的是将原始序列分解成一系列子模态以降低非平稳性,对分解的序列分别建立预测模型并重组来实现最终预测,如姜贵敏等^[17]通过集成经验模态分解(ensemble empirical mode decomposition, EEMD)将功率历史数据分解为一系列相对平稳的子序列,解决了经验模态分解(empirical mode decomposition, EMD)方法所产生的模态混叠现象。变分模态分解(variational mode decomposition, VMD)是一种非递归、变模式的分解方法,克服了 EEMD 递归求解的缺点,具有更好的谐波分离效果^[18]。

本文在现有研究基础上,提出了一种基于 VMD 和改进蝙蝠算法(improved bat algorithm, IBA)优化的 LSSVM 预测模型(VMD-IBA-LSSVM 模型),并利用该模型对宁夏某风电场的发电功率进行预测,通过与其他几种典型模型进行比较来验证模型的有效性。

1 VMD 方法

VMD 是基于 EMD 提出的一种自适应、完全非递归的模态变分和信号处理的方法。与 EMD 相比,VMD 对噪声和采样误差具有更强的鲁棒性。VMD 的分解过程是变分问题的求解过程,可分为变分问题的构造和求解过程^[19]。

1.1 变分问题的构造

- 步骤 1 对于每个模态函数,采用 Hilbert 变换计算相关的解析信号,以获得单侧频谱。
- 步骤 2 通过混合一个调谐到各自中心频率的指数项,将各个模态的频谱调制到相应的基频带。
- 步骤 3 由解调信号的高斯平滑度,得到的约束变分问题:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \quad \text{s. t.} \quad \sum_k u_k = f(t) \tag{1}$$

式中: $\{u_k\}$ 、 $\{\omega_k\}$ ——子信号及其相应的中心频率集合; k ——子信号总数; t ——采样时刻; $\delta(t)$ ——狄拉克分布; $f(t)$ ——一个序列。

1.2 变分问题的求解

- 步骤 1 将约束性变分问题重构为非约束性变分问题,增广的拉格朗日表达式为

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \tag{2}$$

式中: $\lambda(t)$ ——拉格朗日乘法算子; α ——二次惩罚因子。

- 步骤 2 通过交替更新 $u_{k,n+1}$ 、 $\omega_{k,n+1}$ 和 λ_{n+1} 求解增广后拉格朗日表达式中的“鞍点”。VMD 更新过程如下:

$$\hat{u}_{k,n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \tag{3}$$

$$\omega_{k,n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \tag{4}$$

$$\hat{\lambda}_{n+1}(\omega) = \hat{\lambda}_n(\omega) + \tau[\hat{f}(\omega) - \sum_k \hat{u}_{k,n+1}(\omega)] \tag{5}$$

式中: $\hat{u}_{k,n+1}$ ——各模态分量的维纳滤波; $\omega_{k,n+1}$ ——对应模态分量的频率中心; τ ——更新参数。

- 步骤 3 对于给定判别精度 $\epsilon > 0$,若满足式(6),则 VMD 收敛,停止更新。

$$\sum_k \|\hat{u}_{k,n+1} - \hat{u}_{k,n}\|_2^2 / \|\hat{u}_{k,n}\|_2^2 < e \tag{6}$$

2 基于 IBA 优化的 LSSVM 预测模型

2.1 LSSVM

LSSVM 是一种新型支持向量机方法,LSSVM 采用最小二乘线性系统作为损失函数,代替传统的支持向量机采用的二次规划方法。利用等式约束取代 SVM 中的不等式约束,将原问题转化为一个解线性方程组的问题。LSSVM 的优化问题^[20]可以转化为

$$\min_{\mathbf{w},b,e} J(\mathbf{w},e) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2 \quad \text{s. t. } y_k = \mathbf{w}^T \boldsymbol{\varphi}(x_k) + b + e_k \quad (k = 1, 2, \dots, N) \tag{7}$$

式中: $\mathbf{w}$ ——权向量; γ ——正则化参数; e_k ——误差变量; $\boldsymbol{\varphi}(x_k)$ —— x_k 在特征空间的映射; b ——偏置。

式(7)可采用拉格朗日乘数法把原问题优化,同时根据 KKT 最优条件求解。本文选择 RBF 函数作为 LSSVM 的核函数。此外,超参数(C, σ)的选取对模型的预测结果有显著影响,本文采用 IBA 对 LSSVM 模型参数寻优,建立最优预测模型。

2.2 IBA

BA 是一种仿生寻优算法,模拟自然界中微蝙蝠的回声定位行为。BA 将回声定位理想化,将蝙蝠种群初始化为一组随机解,然后通过调节蝙蝠发出的声波频率更新个体的脉冲速率和脉冲响度迭代搜寻最优解,且在最优解周围通过随机飞行产生局部新解,加强了局部搜索。

蝙蝠个体更新其声波频率、速度与位置,公式表述为

$$f_i = f_{\min} + (f_{\max} - f_{\min})\beta \tag{8}$$

$$v_{i,t} = v_{i,t-1} + (x_{i,t} - x_*)f_i \tag{9}$$

$$x_{i,t} = x_{i,t-1} + v_{i,t} \tag{10}$$

式中: $f_{\max}, f_{\min}$ ——最大与最小频率值; v ——个体速度; x ——个体位置; β —— $[0, 1]$ 之间的随机数。

在局部寻优过程中,每只蝙蝠更新公式如下:

$$X_{\text{new}} = X_{\text{old}} + \varepsilon A_t \quad (\varepsilon \in [-1, 1]) \tag{11}$$

式中: X_{old} ——当前最优解; ε ——随机数; $A_t = \langle A_{i,t} \rangle$ ——全部个体在第 t 次迭代时的平均脉冲响度。

当蝙蝠发现目标逼近时,会更新发射脉冲的发射速率和响度:

$$A_{i,t+1} = \alpha A_{i,t} \tag{12}$$

$$r_{i,t-1} = r_{i,0}(1 - e^{-\gamma}) \tag{13}$$

式中: A_i ——脉冲响度; α ——脉冲音响衰减系数; r_i ——脉冲发射速率; γ ——搜索频度增强系数。

根据上述 BA 的优化原理可知,其参数更新方式相对固定,个体本身缺乏变异机制,致使存在后期收敛慢、收敛精度低以及容易陷入局部极小值等问题。为了克服 BA 的缺点,本文采用改进的惯性权重、自适应频率与变异机制来改善寻优过程^[21],形成 IBA。

公式(9)中,速度更新时添加惯性权重以改进速度更新的方向,使得种群中个体可以有效地跳出局部最优优点:

$$g = \begin{cases} [g_{\min} + (g_{\max} - g_{\min})(f_{it}(i) - f_{it}(x_*))]/[1/N \sum_{i=1}^N f_{it}(i) - f_{it}(x_*)] & g \neq g_{\max} \\ g_{\max} & g = g_{\max} \end{cases} \tag{14}$$

式中: g ——惯性权重因子; f_{it} ——适应度函数; N ——种群数量。

当蝙蝠 i 的适应度低于平均适应度时,该蝙蝠将赋予较低的权重,增强其寻优全局更优解的能力;而蝙蝠 i 的适应度高于平均适应度时,该蝙蝠将赋予较高的权重,增加其跳出局部最优解的机会,间接增大该蝙蝠寻优全局最优解的能力,主要模仿粒子群算法的惯性权重策略。

在 BA 中,存在一些蝙蝠已经处在最优解边缘的,仍采用与平时一致的频率来寻优,最终会影响其寻找最优解的机会,因此采用自适应频率调整:

$$d_{ij} = \sqrt{(x_{ij} - x_{j,*})^2} \tag{15}$$

$$r_{\text{ange}} = d_{i,\text{max}} - d_{i,\text{min}}$$

(16)

$$f_j = f_{\text{min}} + \frac{\sqrt{(d_{i,\text{min}} - d_{ij})^2}}{r_{\text{ange}}}(f_{\text{max}} - f_{\text{min}})$$

(17)

式中: d_i ——第*i*个解到最优解距离; r_{ange} ——最大距离与最小距离的差值。

由此,速度更新公式变为

$$v_{ij,t} = v_{ij,t-1} + (x_{ij,t} - x_{j,*})f_j$$

(18)

当蝙蝠都趋于收敛时,部分种群陷入了局部最优解,此时增加变异机制,跳出该局部最优解。本文采用的方法是产生一个随机数,当这个随机数大于变异概率的时候,对蝙蝠重新初始化。

2.3 改进的 IBA-LSSVM 预测模型的建立

为了进一步提高 LSSVM 模型的预测精度和速度,需要对模型的参数进行优化,优化步骤如下:

步骤1 设定 LSSVM 模型中惩罚参数 C 、核参数 σ 的取值范围。

步骤2 种群基本参数化,设定种群数个体 $x_i(i=1,2,\cdots,N)$ 、脉冲频率最大值 f_{max} 和最小值 f_{min} 、脉冲响度 A_i 、脉冲发射率 r_i 、空间维度 d 和最大迭代次数 M_l 。

步骤3 初始化种群中每只蝙蝠个体的位置 x_i 和速度 v_i ,其中蝙蝠 i 的位置代表着参数 C 和 σ 。

步骤4 计算每只蝙蝠的适应度值,寻找当前时刻最优解。以蝙蝠位置对应的参数训练 LSSVM 模型,然后选取训练集进行训练和测试,按照降序排列,找到当前最优解。

步骤5 分别按照式(8)(9)和(18)更新种群中各个蝙蝠个体的脉冲发射率、所在位置和飞行速度,采用改进的惯性权重、自适应频率与变异机制来改善寻优过程。

步骤6 出现第一个随机数 r_{and1} ,当 $r_{\text{and1}} > r_i$ 时,根据式(11)更新出局部最优解 X_{new} 。

步骤7 出现第二个随机数 r_{and2} ,若 $r_{\text{and2}} < A$ 且当前产生的新解适应度更小,则接受产生的新解。并对新解按式(12)和(13)更新脉冲响度 A_i 和脉冲发射率 r_i 。

步骤8 对蝙蝠的适应度重新排序,确认当前最优值,重复迭代过程,直到满足设定的终止条件,停止循环并输出全局最优解。

3 VMD-IBA-LSSVM 模型

VMD-IBA-LSSVM 模型的建模流程为:①利用 VMD 将具有非线性、随机性的原始风电功率序列分解为一系列平稳的模式分量,根据各个子模式的近似熵的分析结果进行子序列重组,对于每个重组后模式分量,结合历史气象数据,分别建立第 2.3 节中的 IBA-LSSVM 模型;②叠加各子模式模型预测值,得到最终的风电功率预测值。建模过程如图 1 所示。

输入变量的选取对预测精度有直接影响,本文将输入原始数据集分为历史气象数据和历史功率数据两类。其中历史气象数据包含多种风速等,历史功率数据作为输入变量的主体,需要进行 VMD 分解,而风速数据只需要加入分解后的子序列中。原始数据集中各个数据量纲不同,为了提高风电功率预测精度,需要进行数据标准化处理,将原始数据线性化转换到 $[0,1]$ 的范围,归一化公式如下:

$$\tilde{\rho}_i = \frac{\rho_i - \rho_{\text{min}}}{\rho_{\text{max}} - \rho_{\text{min}}}$$

(19)

式中: $\tilde{\rho}_i$ ——归一化后的数据值; ρ_i ——原始数




图1 风电功率预测流程

Fig.1 Flow chart of wind power prediction

据; $\rho_{\max}$ $\rho_{\min}$ ——原始数据最大值和最小值。

4 算例分析

4.1 算例概况

a. 数据来源。以宁夏某风电场 2017 年 1 月 1—31 日的样本作为研究数据,数据包括 24 h 风电功率数据和日环境数据。数据采样时间间隔为 15 min,总共 96 个点。在实际建模过程中,将 2017 年 1 月 1—28 日数据作为 LSSVM 模型的训练集,其余数据作为模型的测试集。

b. 预测模型。本文 VMD-IBA-LSSVM 模型和 BP、SVM、LSSVM、VMD-BP、VMD-SVM、VMD-LSSVM、IBA-LSSVM 7 种对比模型。8 种模型在输入量不变的情况下进行对比预测。

c. 功率预测模型参数。在建立 IBA-LSSVM 模型过程中,惩罚参数 C 、核参数 σ 的寻优范围均为 $[0.001,1000]$,IBA 参数设置为:种群数大小 $N=10$,脉冲频率最大值 $f_{\max}=2$,最小值 $f_{\min}=0$,解的维度 $d=2$,脉冲响度 $A_i=0.9$,初始脉冲发射率 $r_0=0.5$,最大迭代次数 $M_1=1000$,惯性权重因子最大值 $w_{\max}=0.5$ 、最小值 $w_{\min}=0.2$ 。对比模型 BP 隐含层神经元数量为 20,学习率为 0.01,学习目标为 0.001,迭代次数为 5000。对比模型 SVM 中的模型学习参数 C 与 ε 与 LSSVM 中参数选取均通过网格搜索法优化得出,参数范围为 $[2^{-8},2^8]$,迭代步长为 0.1。

4.2 评价标准

采用均方根误差(RMSE)和平均绝对误差(MAE)作为模型预测精度评价指标。

4.3 原始风电功率序列的分解结果

VMD 的参数设置如下:惩罚参数 $C=2000$;模态函数个数 K 由于当其大于 5 后子序列趋于相似,因此取 $K=5$;初始中心频率 $\omega=0$;收敛判据 $t=10^{-7}$ 。VMD 分解效果如图 2 和图 3 所示。




图 2 原始风电功率序列及 VMD 分解结果

Fig. 2 Original wind power sequence and VMD decomposition results

从图 2 可以看出,原始风电功率被分解为多个存在不同波动性的子序列,若分别对各个子序列分别建立模型进行预测,不仅增加了任务量,而且忽略了各个子序列的相关性。本文采用近似熵度量各个子序列的复杂度,将具有相关性的序列进行重组,合并成新的序列,形成趋势分量、细节分量、随机分量,这样不仅可以有效缩短运算时间,而且可以更好地突显同类序列的特性^[22]。

根据各分量的近似熵,图 2(b)中第一分量为 0.01 数量级,图 2(c)中第 2 分量和图 2(d)中第 3 分量为 0.1 数量级,图 2(e)中第 4 分量和图 2(f)中第 5 分量为 1 数量级,按照数量级不同可以将子序列重新分组。即第 1 分量作为趋势分量,第 2 和第 3 分量组成细节分量,第 4 和第 5 分量组成随机分量,重构的新序列如图 3 所示。

分析图 3 重构后的分量序列,3 种分量都具有各自明显的特点,其中趋势分量波动平缓,可以将原始序列的总体波动趋势表现出来;细节分量规律性较强,可以很好地表征出原始序列的细节波动;随机分量以很




图3 原始风电功率序列及模态函数重构结果

Fig.3 Original wind power sequence and modal function reconstruction results

好地表征出原始序列的细节波动,随机分量具有一定的随机性和波动性表明了一些不确定因素造成的波动。

4.4 预测结果对比分析

采用上述8种预测模型对2017年1月29—31日进行提前24 h 风电功率预测,最后一天的预测结果如图4所示,可以看出VMD和IBA-LSSVM模型相较于其他对比模型可以更好地对真实曲线的波动规律进行预测,整体趋势与真实曲线更为贴合。而单一的预测模型在风电功率预测中其曲线明显滞后于实际曲线,采用VMD对原始序列进行分解,分别对各个分量建立预测模型可以改善这一现象,预测精度有不同程度的提高。

以上8种预测模型2017年1月29—31日预测误差及3日预测误差平均值如表1所示。




图4 不同模型1月31日功率预测曲线
Fig.4 Power prediction curves of different models on 31st January

表1 不同模型预测误差对比

Table 1 Comparison of prediction errors of each model

模型	RMSE				MAE			
	1月29日	1月30日	1月31日	平均值	1月29日	1月30日	1月31日	平均值
BP	30.61	24.90	35.20	30.23	23.44	18.70	25.32	29.62
SVM	30.09	31.84	35.75	32.56	23.33	27.61	30.95	27.29
LSSVM	30.74	23.08	34.52	29.44	21.94	17.29	24.22	21.15
VMD-BP	27.70	19.55	28.59	25.28	20.56	16.16	22.67	20.66
VMD-SVM	20.05	23.13	21.53	21.57	15.10	20.90	16.83	17.61
VMD-LSSVM	19.13	15.16	20.01	18.10	13.62	9.95	13.56	12.37
IBA-LSSVM	24.77	17.76	24.03	22.18	15.17	11.85	16.18	14.40
VMD-IBA-LSSVM	14.39	11.10	14.38	13.29	9.29	7.07	10.05	8.80

从表1 预测误差值可以看出,VMD-IBA-LSSVM 模型的 RMSE 和 MAE 均低于其他模型,证明该模型预测效果相比于其他模型更好。同时相较于单一的预测模型 BP、SVM 和 LSSVM,经过 VMD 进行数据分解,建立组合预测模型的 VMD-BP、VMD-SVM 和 VMD-LSSVM 其预测性能都有不同程度的提高,其中 RMSE 精度分别提高了 4.95%、10.99% 和 11.34%;MAE 精度分别提高了 8.96%、9.68% 和 8.78%。在运行时间方面,基础模型 BP、SVM 和 LSSVM 平均训练用时分别为 9 s、384 s 和 127 s,虽然 LSSVM 耗时较长,但是预测效果最好。此外,采用 IBA 对 LSSVM 模型优化后,其训练时间缩短为 48 s。分析对比 LSSVM 与 IBA-LSSVM 预测模型,在采用了 IBA 后,其预测精度具有明显的提高,在此基础上利用 IBA-LSSVM 预测模型对 VMD 技术分解的原始序列产生的各个变量分别进行建模,从而进一步提高了预测精度,RMSE 和 MAE 分别仅为 13.29% 和 8.80%。

5 结 论

- a. 针对具有非线性的原始风电功率序列,采用 VMD 分解为一系列平稳的模式分量,利用近似熵度量各个子序列的复杂度,将具有相关性的序列进行重组,降低了预测模型的计算规模。
- b. 针对 LSSVM 模型参数难以选取,影响模型预测性能,提出了采用 IBA 优化 LSSVM 的核参数选取,利用其全局寻优能力强、收敛精度高等优点,为重组后的子序列分别构建 IBA-LSSVM 预测模型,提高了模型预测精度。
- c. VMD-IBA-LSSVM 模型能有效对风电场的功率进行短期预测,从而可以及时调整调度计划,降低电力系统运行成本,具有一定的应用价值。下一步应对风电机组特性进行深入分析并考虑更多的环境信息作为输入样本,从而进一步提高其预测精度。

参考文献:

[1] 傅质馨,李潇逸,袁越. 泛在电力物联网关键技术探讨[J]. 电力建设,2019,40(5):1-12. (FU Zhixin,LI Xiaoyi,YUAN Yue. Research on key technologies of ubiqutions power Internet of things [J]. Electric Power Construction,2019,40 (5):1-12. (in Chinese))

[2] 吴峰,睢康,黄弘扬,等. 基于 PSASP 自定义接口功能的直驱型风电机组简化模型[J]. 河海大学学报(自然科学版),2019,47(1):79-87. (WU Feng,JU Kang,HUANG Hongyang,et al. Simplified modeling and parameter identification of directly driven wind turbine with permanent magnet synchronous generator based on PSASP[J]. Journal of Hohai University (Natural Sciences),2019,47(1):79-87. (in Chinese))

[3] 鞠平,郭德正,曹路,等. 含主动负荷的综合电力负荷建模研究综述与展望[J]. 河海大学学报(自然科学版),2020,48(4):367-376. (JU Ping,GUO Dezheng,CAO Lu,et al. Review and prospect of modeling on generalized synthesis electric load containing active loads[J]. Journal of Hohai University (Natural Sciences),2020,48(4):367-376. (in Chinese))

[4] 侯海良,孙妙平,蔡斌军. 基于 RBF-ARX 模型的短期电力负荷预测[J]. 河海大学学报(自然科学版),2015,43(3):271-277. (HOU Hailiang,SUN Miaoping,CAI Binjun. Short-term electric load forecasting based on RBF-ARX model[J]. Journal of Hohai University(Natural Sciences),2015,43 (3):271-277. (in Chinese))

[5] AN X,JIANG D,LIU C,et al. Wind farm power prediction based on wavelet decomposition and chaotic time series[J]. Expert Systems with Applications,2011,38(9):11280-11285.

[6] ZHANG Xueqing,LIANG Jun. Chaotic characteristics analysis and prediction model study on wind power time series[J]. Acta Physica Sinica,2012,61(19):70-81.

[7] 师洪涛,杨静玲,丁茂生,等. 基于小波-BP 神经网络的短期风电功率预测方法[J]. 电力系统自动化,2011,35(16):44-48. (SHI Hongtao,YANG jingling,DING Maosheng,et al. A short-term wind power prediction method based on wavelet decomposition and BP neural network[J]. Automation of Electric Power Systems,2011,35 (16):44-48. (in Chinese))

[8] 杨琦,张建华,王向峰,等. 基于小波-神经网络的风速及风力发电量预测[J]. 电网技术,2009,33(17):44-48. (YANG Qi,ZHANG Jianhua,WANG Xiangfeng,et al. Wind speed and generation wind power forecast based on wavelet neural network[J]. Power System Technology,2009,33 (17):44-48. (in Chinese))

[9] 孟洋洋,卢继平,孙华利,等. 基于相似日和人工神经网络的风电功率短期预测[J]. 电网技术,2010,34(12):163-167. (MENG Yangyang,LU Jiping,SUN Huali,et al. Short-term wind power forecasting based on similar days and artificial neural network[J]. Power System Technology,2010,34 (12):163-167. (in Chinese))

[10] 李国,江晓东. 基于提升回归树与随机森林的风电功率集成预测方法[J]. 电力系统及其自动化学报,2018,30(11):70-74. (LI Guo,JIANG Xiaodong. Wind power generation ensemble forecasting method based on boosted regression tree and random forest[J]. Proceedings of the CSU-EPSA,2018,30 (11):70-74. (in Chinese))

[11] 许杏花,潘庭龙. 基于 KPCA-RF 的风电场功率预测方法研究[J]. 可再生能源,2018,36(9):1323-1327. (XU Xinghua,PAN Tinglong. Wind power prediction based on KPCA-RF[J]. Renewable Energy,2018,36(9):1323-1327. (in Chinese))

[12] 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. (SU Ran,KE Yongqin,ZHANG Xiaoqian,et al. Wind power forecasting based on time series and SVM[J]. Electric Power,2012,45 (1):64-68. (in Chinese))

[13] 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. (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. (in Chinese))

[14] 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):63-69. (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):63-69. (in Chinese))

[15] 周松林. 风电功率预测及微电网概率潮流分析[D]. 合肥:合肥工业大学,2013.

[16] 赵凤展,郝帅,张宇,等. 基于变分模态分解 BA-LSSVM 算法的配电网短期负荷预测[J]. 农业工程学报, 2019,35(14):190-197. (ZHAO Fengzhan,HAO Shuai,ZHANG Yu,et al. Short-term load forecasting for distribution transformer based on VMD-BA-LSSVM algorithm[J]. Transactions of the Chinese Society of Agricultural Engineering,2019,35(14): 190-197. (in Chinese))

[17] 姜贵敏,陈志军,李笑竹,等. 基于 EEMD-ACS-LSSVM 的短期风电功率预测[J]. 太阳能学报,2020,41(5):77-84. (JIANG Guimin,CHEN Zhijun,LI Xiaozhu,et al. Short-term prediction of wind power based on EEMD-ACS-LSSVM[J]. Acta Energiae Solaris Sinica,2020,41 (5):77-84. (in Chinese))

[18] LAHMIRI S. Comparing variational and empirical mode decomposition in forecasting day-ahead energy prices[J]. IEEE Systems Journal,2017(3):1-4.

[19] 刘长良,武英杰,甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报,2015,35(13):3358-3365. (LIU Changliang,WU Yingjie,ZHEN Chenggang. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering[J]. Proceedings of The Chinese Society for Electrical Engineering,2015,35 (13): 3358-3365. (in Chinese))

[20] 王贺,胡志坚,张翌晖,等. 基于聚类经验模态分解和最小二乘支持向量机的短期风速组合预测[J]. 电工技术学报,2014,29(4):237-245. (WANG He,HU Zhijian,ZHANG Yihui,et al. A hybrid model for short-term wind speed forecasting based on ensemble empirical mode decomposition and least squares support vector machines[J]. Transactions of China Electrotechnical Society,2014,29(4):237-245. (in Chinese))

[21] YILMAZ S, KUCUKSILLE E U. Improved bat algorithm (IBA) on continuous optimization problems [J]. Lecture Notes on Software Engineering,2013,1(3):279-283.

[22] 梁智,孙国强,李虎成,等. 基于 VMD 与 PSO 优化深度信念网络的短期负荷预测[J]. 电网技术,2018,42(2):598-606. (LIANG Zhi,SUN Guoqiang,LI Hucheng,et al. Short-term load forecasting based on VMD and PSO optimized deep belief network[J]. Power System Technology,2018,42 (2):598-606. (in Chinese))

(收稿日期:2020-08-03 编辑:郑孝宇)

(上接第 520 页)

[16] 任尚义. 干旱概念探讨[J]. 干旱地区农业研究,1991,9(1):78-80. (REN Shangyi. Discussion on the concept of drought[J]. Agricultural Research in the Arid Areas,1991,9(1):78-80. (in Chinese))

[17] CHEN Yanli,LUO Yongming,MO Weihua,et al. Differences between MODIS NDVI and MODIS EVI in response to climatic factors[J]. Journal of Natural Resources,2014,29(10):1802-1812.

[18] GOCIC M,TRAJKOVIC S. Analysis of precipitation and drought data in Serbia over the period 1980-2010 [J]. Journal of Hydrology,2013,494:32-42.

[19] 贾晓芬,郭永存,黄友锐,等. 基于斯皮尔曼等级相关性的彩色图像椒盐噪点检测算法[J]. 中国科学技术大学学报,2019,49(1):63-70. (JIA Xiaofen,GUO Yongcun,HUANG Yourui,et al. Color image salt and pepper noise detection algorithm based on Spearman rank correlation[J]. Journal of University of Science and Technology of China,2019,49(1):63-70. (in Chinese))

[20] FIELLER E C,HARTLEY H O,PEARSON E S. Tests for rank correlation coefficients[J]. Biometrika,1957,44(3/4):470-481.

[21] 徐维超. 相关系数研究综述[J]. 广东工业大学学报,2012,29(3):12-17. (XU Weichao. A review of correlation coefficient research[J]. Journal of Guangdong University of Technology,2012,29(3):12-17. (in Chinese))

[22] ZHANG Jinghua,JIANG Luguang,FENG Zhiming,et al. Detecting effects of the recent drought on vegetation in southwestern China[J]. Journal of Resources Ecology,2012,3(1):43-50.

[23] JI Lei,PETERS A J. Assessing vegetation response to drought in the northern Great Plains using vegetation and drought indices [J]. Remote Sensing of Environment,2003,87(1):85-98.

[24] HARO-MONTEAGUDO D,DACCACHE A,KNOX J. Exploring the utility of drought indicators to assess climate risks to agricultural productivity in a humid climate[J]. Hydrology Research,2018,49(2):539-551.

[25] GONG Z,KAWAMURA K,ISHIKAWA N,et al. MODIS normalized difference vegetation index (NDVI) and vegetation phenology dynamics in the Inner Mongolia grassland[J]. Solid Earth,2015,6(4):1185.

[26] 钱拴,伏洋. 三江源地区生长季气候变化趋势及草地植被响应[J]. 中国科学:地球科学,2010,40(10):1439-1445. (QIAN Shuan,FU Yang. Climate change trend and grassland vegetation response during the growing season in the Three-River Source Region[J]. Science China:Earth Science,2010,40(10):1439-1445. (in Chinese))

(收稿日期:2020-07-12 编辑:郑孝宇)