

文章编号:1674-2974(2016)10-0070-09

基于 EEMD-IGSA-LSSVM 的 超短期风电功率预测*

江岳春, 杨旭琼[†], 贺 飞, 陈礼锋, 何钟南

(湖南大学 电气与信息工程学院, 湖南 长沙 410082)

摘要:为了提高风电场输出功率的预测精度,在保证安全操作的前提下,建立了一种基于集合经验模态分解(EEMD)、改进引力搜索算法(IGSA)、最小二乘支持向量机(LSSVM)相结合的风电功率组合预测模型.首先运用 EEMD 算法将风电功率时间序列分解成一系列复杂度差异明显的子序列;其次利用相空间重构(PSR)对已分解好的子序列进行重构,对重构后的每个子序列分别建立 IGSA-LSSVM 预测模型,为分析不同核函数构造 LSSVM 的差异性,建立了 8 种核函数 LSSVM 预测模型,利用 IGSA 算法求解其模型;最后以中国内蒙古地区的某一风电场为算例,仿真及验算结果表明,利用 IGSA 算法寻优得到的指数径向基核函数核参数和惩罚因子构建的 LSSVM 模型具有较高的预测准确性;与 EEMD-WNN, EEMD-PSO-LSSVM 等 5 种常规组合模型相比,所提出的指数径向基核函数的 EEMD-IGSA-LSSVM 组合模型能有效、准确地进行风电功率预测.

关键词:集合经验模态分解;风功率预测;最小二乘向量机;改进引力搜索算法;指数径向基核函数

中图分类号:TU375

文献标识码:A

Super-short-Time Wind Power Forecasting Based on EEMD-IGSA-LSSVM

JIANG Yue-chun, YANG Xu-qiong[†], HE Fei, CHEN Li-feng, HE Zhong-nan

(College of Electrical and Information Engineering, Hunan Univ, Changsha, Hunan 410082, China)

Abstract: In order to improve the prediction accuracy of the output power of the wind farm under the premise of ensuring safe operation, a combination of wind power forecasting model based on Ensemble Empirical Mode of Decomposition (EEMD), Improved Gravitational Search Algorithm (IGSA) and Least Squares Support Vector Machine (LSSVM) was established. Firstly, the wind power time series was decomposed into a series of subsequences with significant differences in complexity by using EEMD algorithm. Secondly, the decomposed subsequence was reconstructed by the phase space reconstruction (PSR), and then, an IGSA-LSSVM prediction model of each sub-sequence reconstructed was established respectively. In order to analyze the differences of LSSVM which sets up different kernel functions, eight kinds of kernel function LSSVM prediction models were established, and the IGSA algorithm was adopted

* 收稿日期:2016-03-22

基金项目:国家自然科学基金资助项目(51277057), National Natural Science Foundation of China(51277057)

作者简介:江岳春(1965-),男,湖南长沙人,湖南大学副教授,博士

[†] 通讯联系人, E-mail: yang8238579@163.com

to solve those models. Finally, taking a wind farm in Inner Mongolia of China as an example, the simulation and calculation results illustrate that LSSVM prediction model based on the exponential radial basis kernel function and penalty factor obtained by using the IGSA algorithm has higher prediction accuracy. Compared with five conventional combined models such as EMD-WNN and EMD-PSO-LSSVM, the combined model EEMD-IGSA-LSSVM of exponential radial basis kernel function mentioned above can forecast wind power in an effective and accurate way.

Key words: ensemble empirical mode decomposition (EEMD); wind power prediction; least squares support vector machine (LSSVM); improved gravitational search algorithm(IGSA); exponential radial basis function(ERBF)

风电的随机性和波动性会导致风电功率输出的波动和不稳定,阻碍了大规模风力发电上网,导致制订发电调度计划和电力调度的困难,但是,通过提高超短期风电功率的预测精度,能有效地解决这些难题^[1].

在时间尺度层面,风电功率的预测可分成中长期(数天),短期(数小时至数天)和超短期预测(几分钟至几小时)。目前,风电功率预测方法划分为以下两类:一类是数值天气预报(numerical weather prediction, NWP)物理建模技术^[2],另一类是历史数据的统计建模技术。前者需考虑地形、气压和气温等复杂因素,使预测运算量大,成本高。后者主要是智能学习算法,包括:以时间序列法^[3-4]建立的预测模型、以卡尔曼滤波^[5]建立的预测模型、以支持向量机法^[6]构建的预测模型以及以最小二乘支持向量机法^[7]构建的预测模型;最小二乘支持向量机(least squares support vector machine, LSSVM)对于非线性、小样本、高尺度识别等问题的解决,占据独特的优势,具有较高的泛化性能和较好的非线性拟合性能。但是, LSSVM 的核函数和核参数选择会影响其预测精度和泛化能力。文献^[7]在进行风速预测时,预测 LSSVM 模型选取高斯径向基核函数。文献^[8-9]采用最小二乘向量机方法进行风速预测建模时,选择了径向基(radial basis function, RBF)核函数,但是上述方法预测风速时精度有待进一步提高。遗传算法^[10]、蚁群优化算法^[11]和粒子群算法^[12]等已经逐渐应用到寻找 LSSVM 的最优参数中,对于常规模式寻优速度慢的困扰提供了解决办法。文献^[13]详细介绍了 GSA 算法的收敛的精度、速度这两方面具有相对的优势。目前,有文献^[14]将引力搜索算法(GSA 算法)应用于支持向量机参数识别中,表明了采用 GSA 算法对支持向量机参数优化具有很好的效果。所以 GSA 算法应当对 LSSVM 的核函

数、核参数的寻找和优化也同样的适用。

此外,风功率信号的非平稳性严重的制约预测模型的建立和预测精度的提高。目前,降低风电功率非平稳性主要有:傅里叶分解法^[15]、小波分解法^[16]和经验模态多尺度分解法^[17]。其中,傅里叶分解法得到的子序列在时域内没有分辨率,自适应性差;小波分解法则需要人为预先设定基函数,操作不便,分解结果含有多余信号;EMD 多尺度分解具有较高的时频分辨性能,其基函数由原始数据驱动产生。但是,端点效应和模态混叠现象会降低 EMD 分解质量,进而影响预测准确性。

本文将 EEMD, IGSA 算法和 LSSVM 方法相结合,提出了基于 EEMD-IGSA-LSSVM 组合预测模型。通过 EEMD 将风功率时间序列分解成一系列差异复杂度明显的子序列,利用相空间重构对每个本征模态函数(intrinsic mode function, IMF)分量进行重构,对重构后的每个 IMF 变量分别建立 IGSA-LSSVM 预测模型。为分析不同核函数构造 LSSVM 的差异性,本文利用 IGSA 算法对 8 种核函数 LSSVM 预测模型进行对比分析。最后,以某风电场的风电实测数据进行仿真对比分析,仿真结果表明了基于指数径向基核函数的混合的 EEMD-IGSA-LSSVM 模型具有更高的精度。同时,与常见的 EEMD-WNN, EEMD-LSSVM 等 5 种组合模型对比,所提组合模型的预测结果最好;因此对于风电预测来说 EEMD-IGSA-LSSVM 组合模型能有效、准确地进行风电功率预测。

1 聚类经验模态多尺度分解(EEMD)

文献^[17]介绍了经验模态分解(Empirical mode decomposition, EMD)是一种可将非线性非平稳的序列信号分解为各种不同尺度的本征模态函

数(intrinsic mode function, IMF)和一个剩余分量的自适应信号的分解方法. EMD的分解结果如式(1):

$$x(t) = \sum_{i=1}^n C_i(t) + r_n(t). \quad (1)$$

式中: $C_i(t)$ 为固有本征模态分量函数; $r_n(t)$ 为多余函数.

在实际中,风电功率的时间序列往往会掺杂不纯净的白噪声,导致分解会丢失重要的时间尺度,出现模态混叠现象.文献[18]介绍了EEMD可以利用噪声特性来有效地抑制这一现象,其实现的详细步骤如下:

1)在风电功率数据上加入服从正态分布 $(0, (\alpha\epsilon)^2)$ 的白噪声序列得到新的风功率序列 $\{\tilde{x}(t)\}$, 其中, α 为噪声强度, ϵ 为标准差.

2)利用EMD将新的风电功率时间序列 $\{\tilde{x}(t)\}$ 分解成若干IMF分量 $C_i(t)$ 和一个余下的残差信号 $r_n(t)$.

3)重复步骤1)、步骤2) r 次,每次加入幅值不同的白噪声序列.

4)将 r 次分解得到的各个IMF分量整体求平均值,并将其作为原始风电功率时序的IMF分量.

当残差信号 $r = 100$, 噪声强度 α 从 $[0.1, 0.3]$ 之间取值时能够得到较好地分解结果.因此本文取 $r = 100$, $\alpha = 0.25$.

2 相空间重构相关论述

文献[19]证明风功率时间序列具备混沌的特性,而相空间重构则是分析混沌时序的一种重要方法,已成为挖掘风功率时序非线性动力学特征和优化预测模型学习样本的新颖、有效地手法[20].已知风电功率时序为 $\{x(i)\}$, $i = 1, 2, \dots, n$. 可通过重构相空间向量 $\mathbf{X}(t)$ 来构造一个 m 维吸引子.

$$\mathbf{X}(i) = [x(i), x(i+\tau), x(i+2\tau), \dots, x(i+(m-1)\tau)]^T. \quad (2)$$

式中: m 为嵌入维数; τ 为延迟时间, $i = 1, 2, \dots, N$, $N = n - (m-1)\tau$. 由Takes定理,当 $m \geq 2d + 1$ (d 为原动力系统维数),其重构后的相空间与原动力系统吸引子相等价.

本文采用关联积分(correlation-integral, C-C)法[21]来对章节1分解得到的风电功率子时序进行重构向量. C-C法中的嵌入维数 m 和延迟时

间 τ 是相互关联的,通过关联积分函数能够同时估计最优时延 τ 和嵌入窗 τ_w , 根据嵌入窗时间公式 $\tau_w = (m-1)\tau$ 求出嵌入维数 m .

3 基于IGSA优化的LSSVM预测模型

3.1 最小二乘支持向量机的相关理论

对于数据回归的处理,支持向量机(SVM)通过结构风险最小化代替之前的经验风险技术,克服了过度拟合的问题,提高了泛化能力. LSSVM改进和扩展了SVM的数学模型, LSSVM是将误差二范数作为损失函数,将SVM的不等式约束变为等式,而且LSSVM在求解线性系统代替二次规划问题的训练方面,减少了模型学习的计算时间. LSSVM最终用于表示回归的LSSVM预测模型为:

$$f(x) = \sum_{i=1}^N \beta_i K(x_i, x_j) + b. \quad (3)$$

式中: $K(x_i, x_j)$ 为核函数; b 为固定值偏差; β 为预测模型的权值向量.

虽然LSSVM在解决诸如小样本、非线性、高尺度等方面问题上取得了更好的效果,但是LSSVM依然受到惩罚因子 γ 、核函数类型和核参数的影响.文献[20]指出核函数及其参数的组合不同会对LSSVM回归性能有很大的影响,也会影响它的泛化能力.因此,如何正确的选择核函数及其参数对最小二乘支持向量机的模型具有重大的研究意义.

目前,常用的核函数有RBF核、POLY核、Sigmoid核和高斯(Gaussian)核以及线性核[7-9]共5种;本文除了采用以上5种基本的核函数之外,还将采用以下的3种核函数[22-23]来构建LSSVM模型;核函数的公式如下:

1)ERBF核函数(指数径向基)

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|}{2\sigma^2}\right). \quad (4)$$

2)Morlet核函数

$$K(x_i, x_j) = \cos\left[1.75 \frac{\|x_i - x_j\|}{\sigma}\right] \times \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right). \quad (5)$$

3)Mexican Hat (Mexihat)核函数

$$K(x_i, x_j) = \frac{2}{\sqrt{3}}\pi^{-\frac{1}{4}} \cdot \left[1 - \frac{\|x_i - x_j\|^2}{\sigma^2} \right] \times \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right). \quad (6)$$

式(4)~(6)中: σ 为核的宽度. 为了增强预测模型的准确度, 避免核函数及其参数选择的盲目性, 需要优化所建立的 8 种核函数的 LSSVM 模型. 故本文采用了一种已改进后的 GSA 算法来选择两个参数 γ 和 σ 的最优值.

3.2 引力搜索算法(GSA 算法)

对于一组空间样本集合, $X_i = (x_i^1, \dots, x_i^d, \dots, x_i^n)$, $i = 1, 2, \dots, N$ 为第 i 个粒子在 D 维空间搜索的位置; 由牛顿万有引力定理知, 粒子 i 与粒子 j 的互作用力为:

$$F_{ij}^d(t) = G(t) \frac{M_{pi}(t) \times M_{aj}(t)}{\|x_i(t), x_j(t)\|_2} (x_j^d(t) - x_i^d(t)). \quad (7)$$

式中: M_{aj} 和 M_{pi} 分别为粒子 j 的万有引力质量和粒子 i 的万有引力质量; ϵ 为很小的固定值, $G(t)$ 为万有引力时间常数.

设万有引力质量与万有引力的惯性质量相等, 通过适应度函数给出粒子的万有引力质量, 其定义为:

$$m_i(t) = \frac{[\text{fitness}_i(t) - \text{worst}(t)]}{[\text{best}(t) - \text{worst}(t)]};$$

$$M_i(t) = m_i(t) / \sum_{j=1}^N m_j(t), i = 1, 2, \dots, N. \quad (8)$$

式中: $\text{fitness}_i(t)$ 为粒子适应度函数值; $\text{best}(t)$ 为最优适应度函数值; $\text{worst}(t)$ 为群体最差适应度函数值.

d 维的空间中, 个体 i 所受来自其他所有个体的作用力总和 $F_i^d(t)$ 的定义如式(9):

$$F_i^d(t) = \sum_{j \in k \text{ best}, j \neq i} \text{rand}_j F_{ij}^d(t). \quad (9)$$

式中: rand_j 为在 $[0, 1]$ 之间的随机数, $k \text{ best}$ 为一开始适应值最好的个体的数集.

根据牛顿第二定律, 个体 i 在第 d 维上 t 时刻的粒子万有引力加速度 $a_i^d(t)$ 定义如式(10):

$$a_i^d(t) = F_i^d(t) / M_i(t). \quad (10)$$

最后, 可以得到个体的万有引力速度和位置改进公式如式(11), 式(12):

$$v_i^d(t+1) = \text{rand}_i \times v_i^d(t) + a_i^d(t). \quad (11)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1). \quad (12)$$

式中: rand_i 为在 $[0, 1]$ 之间的随机数.

3.3 改进引力搜索算法(IGSA 算法)

根据文献[13]中的测试结果可知, GSA 的优化性能虽然相比于粒子群等其他智能优化算法有了较大的提高, 但是对于大多数标准的测试函数, GSA 一般只能收敛到最优解附近的某个局部最优值, 存在早熟收敛现象. 为了判断 GSA 算法中粒子个体是否会陷入早熟收敛, 采用文献[24]中的早熟鉴定方程式:

设群体适应度方差 ω^2 为:

$$\omega^2 = \sum_i^m \left(\frac{f_i - f_{\text{avg}}}{f} \right)^2. \quad (13)$$

式中: m 为种群大小; f_i 为第 i 个个体的适应度; f_{avg} 为平均适应度; f 为归一化定标因子用来限制 ω^2 的大小, 取值如式(14):

$$f = \begin{cases} \max |f_i - f_{\text{avg}}| / \max |f_i - f_{\text{avg}}| > 1, \\ 1 & \text{其他.} \end{cases} \quad (14)$$

由于迭代次数的不断增多, 种群个体相互之间的位置、作用力等, 会逐渐的接近, 则 ω^2 会逐渐减小. 若 $\omega^2 < \alpha$ (α 为已给定值), 则种群就越容易发生陷入局部最优的困扰. 因此, 应当对个体增加一定的扰动, 使陷入局部最优个体得到新的搜索位置, 从而保证个体跳出局部最优, 增加扰动因子 β 对其粒子位置的处理, β 的表达式如式(15):

$$\beta = a_1 [G(0, 1) + a_2 C(0, 1)]. \quad (15)$$

式中: a_1 取值为 1.75; a_2 取值为 3.78; $G(0, 1)$ 为服从基本高斯分布的随机值; $C(0, 1)$ 为服从基本柯西分布的随机值, 最终个体粒子的位置更新公式为:

$$x_i^d(t+1) = x_i^d(t) + (1 + \beta)v_i^d(t+1). \quad (16)$$

IGSA 优化 LSSVM 模型参数的具体步骤如下:

1) 设置 GSA 的相关参数, 随机设置个体的位置.

2) 程序将输出量均方误差 MSE 作为目标函数, 根据 MSE 的计算公式, 得到每个个体的适应度数值. MSE 表达式如式(17)所示:

$$\text{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_p)^2}. \quad (17)$$

式中: N 为原始数据的具体数目; y_i 为真实数据值; y_p 为拟合数据.

3) 根据式(8)计算个体的万有引力惯性质

量,根据式(7)和式(9)计算每个个体力的总和,根据式(10)计算个体万有引力加速度。

4)根据式(11)和式(12)改良每个个体的速度和位置。

5)计算适应度值方差 ω^2 ,若 $\omega^2 < \alpha$ 则存在早熟,跳入步 6);否则,将跳入步 7)。

6)通过式(16)对种群里的个体位置进行干扰举动。

7)终止条件判断.达到系统设定最大迭代次数后,算法搜索停止,算法所输出的最优解值即为最优的 LSSVM 参数值;否则,则跳入步骤 3)。综上可知,IGSA-LSSVM 进行风电功率预测的建模如图 1 所示。

1)对原始的数据值进行最大最小化处理,处理公式为:

$$\hat{x}(i) = \frac{x(i) - x(i)_{\min}}{x(i)_{\max} - x(i)_{\min}}, i = 1, 2, \dots, n. \quad (18)$$

式中: $\hat{x}(i)$ 为处理后的数据值; $x(i)$ 为原数据值; $x(i)_{\max}$ 为原数据最大值; $x(i)_{\min}$ 为原数据最小值。

2)选择 3.1 节所述的 8 种核函数构建初始的 LSSVM 模型。

3)建立基于 IGSA 优化 LSSVM 参数的预测模型。

4)建立步骤 3)得到的最优核函数和其参数的最优新型 LSSVM 预测模型。

5)将最优新型的 LSSVM 模型的训练数据误差对比分析。

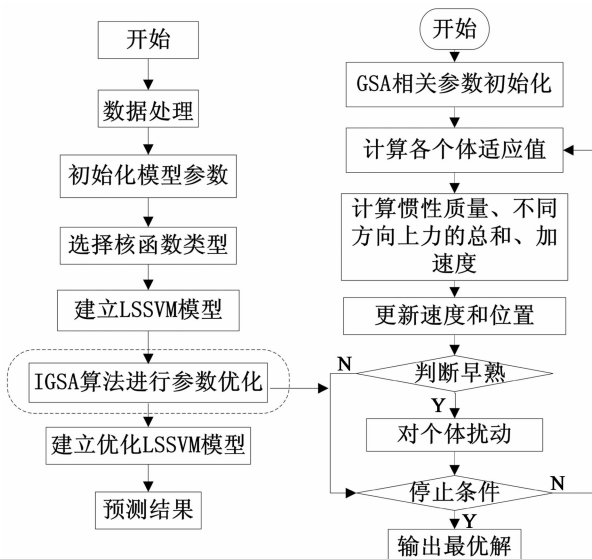


图 1 超短期 IGSA-LSSVM 模型的预测流程
Fig. 1 IGSA-LSSVM model prediction for super-short-time

4 EEMD-IGSA-LSSVM 相结合的风电功率超短期预测模型

风功率时间序列具有非稳态性、非线性和混沌特性,只采用一般的预测方法难以取得较高的预测精度.基于 EEMD 降低风功率信号非稳态性的优势以及 IGSA-LSSVM 模型预测非线性系统的良好性能,本文建立了一种基于 EEMD-IGSA-LSSVM 组合模型预测风功率,其建模流程如图 2 所示.具体流程如下:

1)对原始的风功率时间序列 $\{x(t)\}$ 进行 EEMD 分解,得到不同时间尺度的 n 个 IMF 分量和 1 个残差余项 r_n 。

2)根据相空间重构方法,确定各个本征模态分量函数和残差项函数的延迟窗 τ_w ,延迟时间 τ 和嵌入维数 m ,显然,不同分量函数的延迟窗 τ_w 、延迟时间 τ 和嵌入维数 m 均不相同。

3)针对每个 IMF 分量和残差余项 r_n . 分别建立各自的 IGSA-LSSVM 模型并进行预测,得到全部 IGSA-LSSVM 模型的预测值。

4)叠加不同尺度下风功率预测值,将其作为最终的风功率预测值。

5)误差分析。

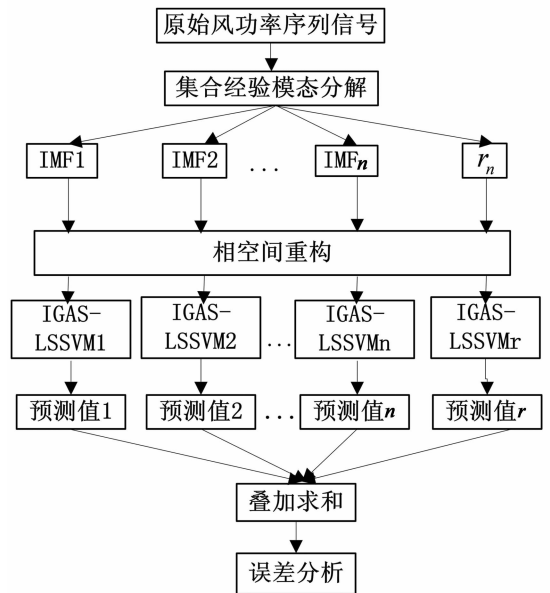


图 2 风电功率超短期 EEMD-IGAS-LSSVM 模型流程
Fig. 2 Model Structure of EEMD-IGSA-LSSVM model of wind power series forecasting

5 算例及结果分析

5.1 风电功率模型的样本选择及处理

以中国内蒙古扎鲁特一期风电场夏秋季 2015 年 5 月 12 号~7 月 10 号的连续 1 440 h 的实测数据为例,该风场由 58 台丹麦 Vestas(维斯塔斯)生产的 V58~850 kW 机组组成,装机总容量 49.3 MW,每 15 min 进行采样;该机组在 6 月 14 号~6 月 16 号 3 d 的输出功率达到功率 800 kW 左右.为进一步数据处理的方便,以小时为单位将其平均化处理,并且以额定功率 850 kW 为基值进行归一化处理,如式(19):

$$\hat{y}_i = y_i / P_{\text{cap}}, i = 1, 2, \dots, n. \quad (19)$$

式中: y_i 为原始数据值; \hat{y}_i 为归一化后的数据值, P_{cap} 为风机的额定功率 850 kW.对归一化后的实测数据进行了再次选择,将实测功率的负值和大于 1 的功率值进行了剔除;剔除处理完成后取其中的 1 000 个数据,如图 3 所示.取总数据的前 900 个作为 LSSVM 模型的训练部分,余下的数据作为 LSSVM 模型测试部分.通过 EEMD 分解风电功率原始数据,仿真平台可得到 IMF1-IMF9 这 8 个固有模态函数以及唯一一个 $R(t)$ 余量函数,其结果如图 4 所示.IGSA-LSSVM 的参数预先设定为:粒子规模为 30,维数为 3,万有引力常数为 $G_0 = 100$,最大迭代次数 $T_{\text{MAX}} = 300$,适应度方差给定数值 $\alpha = 0.000 1$,参数 γ 、核参数 σ 的范围分别为 $[0, 1 000]$, $[0.000 1, 10]$.




图 3 风电功率的超短期时间序列

Fig. 3 Super-short-time series of wind power

选用归一化的两种指标:绝对平均误差指标 E_{NMAE} 、均方根误差指标 E_{NRMSE} 和最大的相对误差指标 E_{MAE} 用来对预测结果进行误差分析,这 3 种指标具体表达式如下:

$$E_{\text{NMAE}} = \frac{1}{P_{\text{cap}}} \frac{1}{N} \sum_{k=1}^N | \tilde{y}(k) - y(k) |, \quad (20)$$

$$E_{\text{NRMSE}} = \frac{1}{P_{\text{cap}}} \sqrt{\frac{1}{N} \sum_{k=1}^N (\tilde{y}(k) - y(k))^2}, \quad (21)$$

$$E_{\text{MAE}} = \frac{1}{P_{\text{cap}}} \max_{k=1,2,\dots,N}. \quad (22)$$

式中: N 为预测点个数; P_{cap} 为风机的额定容量值, $\tilde{y}(k)$ 为风电功率的真实数值; $y(k)$ 为风电功率的预测数值.




图 4 超短期风电功率的 EEMD 处理结果

Fig. 4 EEMD results of the super-short-time wind power

5.2 超短期风电功率 EEMD-IGSA-LSSVM 模型的样本选择及处理

针对 EEMD 处理所得到的 9 项风电功率子序列进行相空间重构,9 项风电功率 IMF 序列的关联积分法参数,如表 1 所示.得到的 EEMD-IGSA-LSSVM 组合模型预测值,如图 5 所示.表 2 为通过 IGSA 算法优化 8 种核函数的 LSSVM 模型所得到的最优参数组合结果.表 3 为 8 种不同种类的核函数构建的 LSSVM 风功率预测模型的性能差异.从表 3 可以看出:选择的 8 种核函数获得的预测效果是相差甚远的.由表 3 分析可以得到,指数径向基函数(ERBF 核函数)的 LSSVM 风功率模型预测性能指标 E_{NMAE} 为 2.787 1% 和 E_{NRMSE} 为 3.601 2%,相对于其余 7 种核函数指标性能较小,且优于其它核函数构建的 LSSVM 预测模型,可提高 LSSVM 预测精度.因此本文采用 ERBF 核函数作 EEMD-IGSA-LSSVM 的风电预测模型的基本核函数.

为检验使用表 2 的基于指数径向基函数(ERBF 核函数)最优参数组合构建 EEMD-IGSA-LSSVM 模型的预测性能.本文同时与目前 5

种已经在风电预测中应用的模型(LSSVM, GSA-LSSVM, EEMD-LSSVM、采用文献[9]方法的组合模型 EEMD-PSO-LSSVM 以及 EEMD-WNN) 进行对比分析。

表 1 各 IMF 序列的关联积分法参数
Tab.1 Parameters of correlation-integral for each subsequence component

各 IMF 子序列	插入维数 m	推迟时间 τ
IMF1	3	7
IMF2	8	6
IMF3	7	4
IMF4	8	11
IMF5	9	14
IMF6	4	16
IMF7	6	14
IMF8	5	13
R_s	3	5




图 5 EEMD-IGSA-LSSVM 模型的预测数据
Fig. 5 The predict results of EEMD-IGSA-LSSVM mole

表 2 8 种核函数的最优参数
Tab.2 Optimal parameters of eight kinds of kernel functions

核类型	惩罚因子	核参数最优值
ERBF	$\gamma=996.56$	$\sigma=4.7096$
RBF	$\gamma=5.1496$	$\sigma=0.4213$
POLY	$\gamma=0.3292$	$r=0.0021, d=7.8401=$
Sigmoid	$\gamma=774.01$	$a=2.2209, r-2.7411$
Gaussian	$\gamma=912.69$	$\sigma=0.4675$
Molrlet	$\gamma=17.583$	$\sigma=0.4728$
Mexican Hat	$\gamma=18.695$	$\sigma=0.5435$
Linear	$\gamma=151.149$	$\sigma=5.7062$

为更加方便地计算预测结果的数据,对全部的预测结果的脏数据进行了约束.约束方法:将预测的负功率按等于 0 处理,将预测相对值高于 1 的(即额定功率 850 kW),则按等于 1 处理.处理后预测结果和预测误差,分别如图 6 和图 7 所示;6 种模型的风电功率预测指标如表 4 所示.

表 3 8 种核函数的风功率预测模型的预测误差比较
Tab.3 Comparison of wind power prediction performance for eight kinds of kernel functions

核函数	误差指标		
	$e_{NMAE}/\%$	$e_{NRMSE}/\%$	$e_{MAE}/\%$
ERBF	2.7871	3.6012	9.4999
RBF	3.8709	4.8622	11.4050
POLY	4.9364	6.3853	18.3149
Sigmoid	5.3881	7.8494	18.5801
Gaussian	6.5256	5.4858	13.7851
Molrlet	4.4547	5.4593	12.9779
Mexican Hat	4.6174	5.7133	15.6839
Linear	4.7398	5.6703	16.4904

从图 6、图 7 和表 4 观察对比发现,6 种模型在预测风功率方面都表现出较好地效果,同时 6 种模型预测性能也有很大差异.

1)可以看出,提出的 EEMD-IGSA-LSSVM 组合模型是能够对原始的风电功率曲线进行有用的追踪、拟合,证明了模型是正确的.

2)可以看出, EEMD-IGSA-LSSVM 方法与单一的 LSSVM 法相比预测精度有了一定的提高,这证明 EEMD 分解可以降低风功率时间序列的非平稳性特征,提高了风功率预测的准确性,解决了预测效果不佳的问题.

3)与 GSA-LSSVM, EEMD-PSO-LSSVM 的对比,表明了 IGSA 算法选择出来的最优 LSSVM 参数,提升了预测精度的比例,同时也说明了该算法对风功率预测是有效的、可行的.

4)EEMD-IGSA-LSSVM 模型误差指标明显低于其余的 5 种模型,避免了选取核函数的盲目性和随意性,从而实现了非线性系统的精确建模和高精度预测.

综上,从预测精度方面,可以看出本文提出的基于 EEMD-IGSA-LSSVM 模型具有极高的预测精度和较好的预测性能,极具工程开发意义.




图 6 6 种方法的风电功率预测值与实际值对比
Fig. 6 Comparison of actual wind power of six models and the predicted results

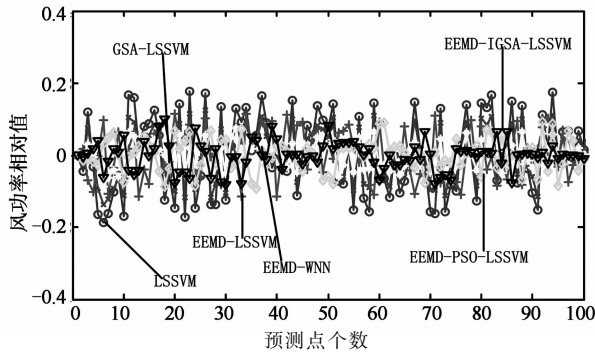


图 7 6 种方法的风电功率预测误差曲线
Fig. 7 Curves of wind power prediction error of six models

表 4 6 种预测模型的风功率误差性能指标
Tab. 4 The wind power of error indexes of the six models

预测模型	e_{NMAE} /%	e_{NRMSE} /%	e_{MAE} /%
LSSVM	9.600	11.042	18.686
GSA-LSSVM	6.455	7.437	13.677
EEMD-LSSVM	5.780	6.698	11.589
EEMD-PSO-LSSVM	3.205	4.158	9.246
EEMD-WNN	3.305	4.332	8.789
EEMD-IGSA-LSSVM	2.041	2.202	7.081

6 结 论

1) EEMD 法可以明显提高分解结果的规律性和平稳性,为进一步预测提供基础。

2) 对比文中所选的 8 种核函数所建的 IGSA-LSSVM 模型,可以得出基于指数径向基函数(ERBF 核函数)的 LSSVM 风功率模型预测性能指标相对较小,预测精确性也相对于其他 7 种核函数建立模型要好,亦能为 LSSVM 模型选择核函数方向提供一种新的借鉴。

3) 选择指数径向基函数(ERBF 核函数)作为核函数,根据改进搜索算法优化参数的思路进行 LSSVM 模型的预测,从结果上与单一模型相比分析得知,这种新型建模方式一定程度上削减了风电功率预测的精度,取得了更好地风电功率预测效果。

4) 与另外的 5 种模型进行对比研究,可以清楚地发现 EEMD-IGSA-LSSVM 模型可以提高风电功率的预测精度,能够明显地改善预测效果。因为预测模型需要采用 IGSA 算法来优化 LSSVM 的参数,所以在实现过程中,存在时间的花费相比于单一预测的时间长,硬件实现有一定难度的缺点,这也是今后需要研究改进的方向。

参考文献

[1] BLONBOUI R, MONJOLY S, DORVILLE J F. An adaptive short-term prediction scheme for wind energy storage management[J]. Energy Convers Manage, 2011;52:2412-2418.

[2] 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 Shuang-lei, WANG Wei-sheng, LIU Chun, et al. [J]. Proceedings of the Csee,2010,30(2):1-6. (In Chinese)

[3] PEIYUAN C, PEDERSEN T, BAK J B, et al. ARIMA-based time series model of stochastic wind power generation [J]. IEEE Transactions on Power Systems, 2010, 25 (2): 667-676.

[4] 蔡凯,谭伦农,李春林,等. 时间序列与神经网络法相结合的短期风速预测[J]. 电网技术,2008,32(8):82-90.
CSAI Kai, TAN Lun-nong, LI Chun-lin, et al. Short-time wind forecasting combing time series and neural network method[J]. Power System Technology, 2008, 32(8): 82-90. (In Chinese)

[5] LOUKA P, GALANIS G, SIEBERT N, et al. Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2008, 96 (12): 2348-2362.

[6] SANCHO S, EMILIO G, ANGEL M, et al. Short term wind speed prediction based on evolutionary support vector regression algorithms[J]. Expert Systems with Applications, 2011, 38(4):4052-4057.

[7] 杜颖,卢继平,李青,等. 基于最小二乘支持向量机的风电场短期风速预测[J]. 电网技术,2008,32(15):62-66.
DU Ying, LU Ji-ping, LI Qing, et al. Short-term wind speed forecasting of wind farm based on least square-support vector machine [J]. Power Grid Technology, 2008, 32(15): 62-66. (In Chinese)

[8] 曾杰,张华. 基于最小二乘支持向量机的风速预测模型[J]. 电网技术,2009,18:144-147.
CENG Jie, ZHANG Hua. Wind speed forecast based on least squares support vector machine (SVM) model [J]. Power System Technology, 2009, 19:144-147. (In Chinese)

[9] 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(4):237-245.
WANG He, HU Zhi-jian, ZHANG Li-hui, et al. Based on clustering empirical mode decomposition and least squares support vector machine (SVM) of short-term wind speed forecasting models [J]. Journal of Electrotechnics, 2014 (4):237-245. (In Chinese)

[10] 尚万峰,赵升吨,申亚京. 遗传优化的最小二乘支持向量机在开关磁阻电机建模中的应用[J]. 中国电机工程学报,

- 2009,12;65-69.
- SHANG Wan-feng, ZHAO Sheng-dun, SHEN Ya-jing. Application of LSSVM optimized by genetic algorithm to modeling of switched reluctance motor [J]. Proceedings of the Csee, 2009, 12;65-69. (In Chinese)
- [11] 姜慧研,宗茂,刘相莹.基于ACO-SVM的软件缺陷预测模型的研究[J].计算机学报,2011,34(6):1148-1154.
- JIANG Hui-yan,ZONG Mao,LIU Xiang-ying. Research of software defect prediction model based on ACO-SVM[J]. Chinese Journal of Computers, 2011,34(6):1148-1154. (In Chinese)
- [12] 高昆仑,刘建明,徐茹枝,等.基于支持向量机和粒子群算法的信息网络安全态势复合预测模型[J].电网技术,2011,35(4):176-182.
- GAO Kun-lun,LIU Jian-ming,XU Ru-zhi, *et al.* A hybrid security situation prediction model for information network based on support vector machine and particle swarm optimization[J]. Power System Technology,2011,35(4):176-182. (In Chinese)
- [13] RASHEDI E, NEZAMABADI-POUR H, SARYAZDI S. GSA: A gravitational search algorithm [J]. Information-Science, 2009, 179(13): 2232-2248.
- [14] ZHANG W, NIU P, LI G, *et al.* Forecasting of turbine heat rate with online least squares support vector machine based on gravitational search algorithm [J]. Knowledge-Based Systems, 2013, 39(2):34-44.
- [15] 桑丙玉,王德顺,杨波,等.平滑新能源输出波动的储能优化配置方法[J].中国电机工程学报,2014,34(22):3700-3706.
- SANG Bing-yu,WANG De-shun,YANG Bo, *et al.* Optimal allocation of energy storage system for smoothing the output fluctuations of new energy [J]. Proceedings of the CSEE,2014,34(22):3700-3706. (In Chinese)
- [16] MONFARED M, RASTEGAR H, KOJABADI H M. A new strategy for wind speed forecasting using artificial intelligent methods[J]. Renewable Energy, 2009, 34(5): 845-848.
- [17] HUANG N E, SHEN Z, LONG S R. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings of the Royal Society Soc Land, 1998,454(1971): 903-995.
- [18] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009,1(1): 1-41.
- [19] 王丽婕,廖晓钟,高爽,等.并网型大型风电场风力发电功率-时间序列的混沌属性分析[J].北京理工大学学报,2007,27(12):1077-1080.
- WANG Li-jie, LIAO Xiao-zhong, GAO Shuang, *et al.* Wind power grid type large wind farms-time series of chaotic properties analysis [J]. Journal of Beijing Institute of Technology,2007,27(12):1077-1080. (In Chinese)
- [20] 张雪清,梁军.风电功率时间序列混沌特性分析及预测模型研究[J].物理学报,2012,61(19):190507.
- ZHANG Xue-qing, LIANG Jun. Chaotic characteristics analysis and prediction model study on wind power time series[J]. Acta Physica Sinica,2012,61(19):190507. (In Chinese)
- [21] 陆振波,蔡志明,姜可宇.基于改进的C-C方法的相空间重构参数选择[J].系统仿真学报,2007,19(11):2527-2538.
- LU Zhen-bo, CAI Zhi-ming, JIANG Ke-yu. Determination of embedding parameters for phase space reconstruction based on improved C-C method[J]. Journal of System Simulation,2007,19(11):2527-2538. (In Chinese)
- [22] GUO X, YANG J, WU C, *et al.* A novel LS-SVMs hyperparameter selection based on particle swarm optimization [J]. Neurocomputing,2008,71(16/18):3211-3215.
- [23] ZHANG X, LIU X, WANG Z J. Evaluation of a set of new ORF kernel functions of SVM for speech recognition [J]. Engineering Applications of Artificial Intelligence, 2013, 26(10):2574-2580.
- [24] 戴娟.引力搜索算法的改进及其应用研究[D].苏州:江南大学控制理论与控制工程学院,2014.
- DAI Juan. The improved and applied research of gravitational search algorithm [D]. Suzhou: Control Theory and Control Engineering Southern Yangtze University, 2014. (In Chinese)