

DOI: 10.7667/PSPC161082

# 基于 AMD-ICSA-SVM 的超短期风电功率组合预测

李燕青, 袁燕舞, 郭通

(河北省输变电设备安全防御重点实验室(华北电力大学), 河北 保定 071003)

**摘要:** 针对风机出力的随机性、波动性和不确定性, 提出了一种基于解析模态分解(AMD)和改进布谷鸟优化支持向量机(ICSA-SVM)参数的超短期风电功率组合预测方法。首先, 利用解析模态分解将风功率序列分解为不同频率范围的分量, 减小不同频率范围间的相互影响。然后针对各序列特点, 采用改进布谷鸟方法分别寻找各自支持向量机的惩罚因子参数和核函数参数, 以提高单个模型的预测精度。最后对预测结果进行叠加和误差分析。仿真算例表明, 所提出的方法可以很好地跟踪风电功率的变化, 有效地提高风电功率预测精度。

**关键词:** 解析模态分解; 改进布谷鸟; 支持向量机; 组合预测

## Combination ultra-short-term prediction of wind power based on AMD-ICSA-SVM

LI Yanqing, YUAN Yanwu, GUO Tong

(Hebei Provincial Key Laboratory of Power Transmission Equipment Security Defense,  
North China Electric Power University, Baoding 071003, China)

**Abstract:** A combination ultra-short-term prediction method of wind power based on analytical mode decomposition (AMD) and improved cuckoo search algorithms optimized support vector machines (ICSA-SVM) is proposed to treat with the randomness, volatility and uncertainty of wind power. Firstly, the wind power is decomposed into components with different frequencies by using AMD to reduce the influence between different frequencies. Then, according to the characteristic of each sequence, different penalty parameters and kernel function parameters are found by using ICSA to improve the forecasting accuracy of single model. Finally, the prediction results are superimposed for error analysis. Simulation results show that the proposed strategy can track the change of wind power better and improve the forecasting accuracy of wind power effectively.

**Key words:** analytical mode decomposition (AMD); improved cuckoo search algorithms (ICSA); support vector machines (SVM); combination prediction

## 0 引言

随着经济社会的快速发展, 能源需求与日俱增, 风能作为一种重要的清洁能源, 成为能源结构中必不可少的一部分。但风电固有的随机性、波动性和不确定性却给电力系统带来了诸多挑战, 这就意味着风电功率的准确预测将会对风能发展有着重大意义。

当前常用的风电功率预测方法包括物理方法、统计学方法和空间相关性方法。物理方法<sup>[1]</sup>指通过求解大气运动的动力热力和物理过程方法, 预报未来天气的变化。采用数值天气预报(Numerical Weather Prediction, NWP)数据, 从“当前”时刻的三维大气要素场(温度、湿度、风)出发, 积分算出

未来时刻的三维大气要素场, 进而进行风电功率预测。统计学方法<sup>[2-3]</sup>通常使用风电场历史测量数据及周边风电场测量数据构造统计学习模型, 进行风电功率预测, 目前主要包括持续预测法<sup>[4]</sup>、时间序列法<sup>[5]</sup>、卡尔曼滤波法<sup>[6]</sup>和智能方法<sup>[7]</sup>等。空间相关性方法<sup>[8-9]</sup>指利用风电场以及与之相近其他地点的风速风向等信息, 运用几个地点风速之间的空间相关性, 考虑物理影响因素进行风速预测, 进而预测风电功率。由于风能具有波动性和特殊的周期性特点, 将风能看作不同频率分量叠加的组合预测方法将会成为未来风电功率预测的发展方向。

组合预测指针对各模型自身的特点, 通过优势互补思想建立组合模型, 提高预测精度<sup>[10-11]</sup>。目前关于风电信号分解的方法有小波分解、经验模态分

解等, 文献[12]提出了采用小波分解和最小二乘支持向量机的短期风速预测方法, 但是小波分解需要事先确定小波基和分解层数, 且分解缺乏自适应性。文献[13-15]采用了经验模态分解(Empirical Mode Decomposition, EMD)及其改进的方法对风电信号进行分解和重构, 但是 EMD 方法的可分辨频率范围有限, 特别是对于包含密集模态的多分量信号, EMD 会出现模态混叠现象。解析模态分解是 Genda Chen 等<sup>[16-17]</sup>提出的一种新的信号分解方法, 该方法可以从信号中分离出各种频率成分的信号, 但前提是需要确定信号里的各个频率成分, 进而确定截止频率值进行 AMD 分解。AMD 分解目前大量应用在机械故障诊断<sup>[18]</sup>、桥梁动态响应<sup>[19]</sup>等领域, 目前还未应用到电力领域。

对信号进行分解以后, 选取适当的预测方法至关重要。支持向量机学习方法在解决小样本、非线性和高维数等问题上得到了广泛的应用, 具有较好的回归预测能力<sup>[20-24]</sup>。而核函数参数和惩罚系数的确定将对支持向量机预测模型的优劣产生很大影响, 当前文献确定参数的主要方法是交叉验证与网格搜索法, 但是寻优速度和精度均不理想。布谷鸟算法(Cuckoo Search, CS)是一种新的元启发式算法, 可以不用将所有参数寻历一遍就可以找到参数最优解, 从而提高了支持向量机的学习能力<sup>[25]</sup>。但是, 由于标准 CS 算法寻优路径依赖于随机游走策略, 且采用了固定发现概率, 将会降低寻优效率和寻优精度。

本文提出了一种基于解析模态分解和改进 CS 算法优化支持向量机的风电功率超短期组合预测模型, 该方法首先利用 AMD 将风功率分解为一系列不同频率的分量, 然后针对每组序列自身特点构造不同的支持向量机模型, 采用 ICSSA 方法选取最优惩罚因子参数和核函数参数, 最后对各个分量进行预测和叠加, 以期得到较好的预测效果。

## 1 解析模态分解

解析模态分解是由 Genda Chen 等提出的新的信号分解方法, 可以实现对具有紧密间隔频率分量的信号进行分解, 并且能够在一定程度上对频率混叠、窄带信号以及信号间歇性波动进行较好的处理, 但是需要知道原始信号的频率成分。

对于任意由  $n$  个信号分量  $x_i(t)(i=1, 2, \dots, n)$  组成的原始信号  $x(t)$  如式(1)。

$$x(t) = \sum_{i=1}^n x_i(t) \quad (1)$$

式中,  $x_i(t)$  对应的时变频率为  $\omega_i(t)$ , 则有二分频率  $\omega_{bi} \in (\omega_i, \omega_{i+1})(i=1, 2, \dots, n-1)$ , 可以将信号分为两个信号和, 如式(2)。

$$x(t) = s_1(t) + \bar{s}_1(t) = \dots = s_i(t) + \bar{s}_i(t) = \dots = s_n(t) + \bar{s}_n(t) \quad (2)$$

对式(2)进行傅里叶变换, 得到式(3)。

$$x(\omega) = \hat{s}_1(\omega) + \hat{\bar{s}}_1(\omega) = \dots = \hat{s}_i(\omega) + \hat{\bar{s}}_i(\omega) = \dots = \hat{s}_n(\omega) + \hat{\bar{s}}_n(\omega) \quad (3)$$

$s_i(t)$ 、 $\bar{s}_i(t)$  对应的傅里叶变换分别为  $\hat{s}_i(\omega)$ 、 $\hat{\bar{s}}_i(\omega)$ , 且频率范围分别为  $|\omega| < \omega_{bi}$  和  $|\omega| > \omega_{bi}$ 。 $s_i(t)$  的表达式如式(4)所示。

$$s_i(t) = \sin(\omega_{bi}t)H[x(t)\cos(\omega_{bi}t)] - \cos(\omega_{bi}t)H[x(t)\sin(\omega_{bi}t)] \quad (4)$$

式中:  $H[\ ]$  为 Hilbert 变换;  $s_i(t)$  是频率小于  $\omega_{bi}$  的信号;  $\bar{s}_i(t)$  是频率大于  $\omega_{bi}$  的信号。AMD 分解示意图如图 1 所示。

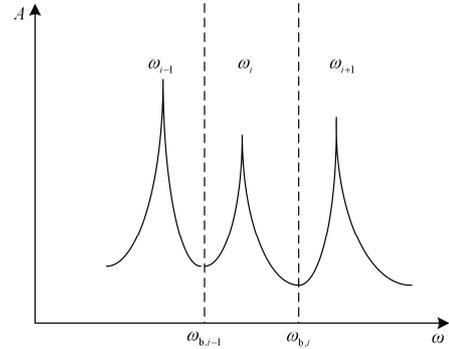


图 1 AMD 分解示意图

Fig. 1 Sketch diagram of AMD method

根据有关解析模式分解的文献可证明如下:

$$\hat{s}_i(\omega) = \begin{cases} 0 & |\omega| > \omega_{bi} \\ x(\omega) & |\omega| < \omega_{bi} \\ x(\omega)/2 & |\omega| = \omega_{bi} \end{cases} \quad (5)$$

$$\hat{\bar{s}}_i(\omega) = x(\omega) - \hat{s}_i(\omega) = \begin{cases} x(\omega) & |\omega| > \omega_{bi} \\ 0 & |\omega| < \omega_{bi} \\ x(\omega)/2 & |\omega| = \omega_{bi} \end{cases} \quad (6)$$

即  $\hat{s}_i(\omega)$  具有低通性质,  $\hat{\bar{s}}_i(\omega)$  具有高通性质。故可得式(7)。

$$x_i(t) = s_i(t) - s_{i-1}(t) \quad (7)$$

其中,  $s_0(t) = 0$ 。根据上述 AMD 分解原理, 设计如图 2 所示的自适应低通滤波器, 从而可以分离出频率低于截止频率的低频信号和高于截止频率的高频信号。

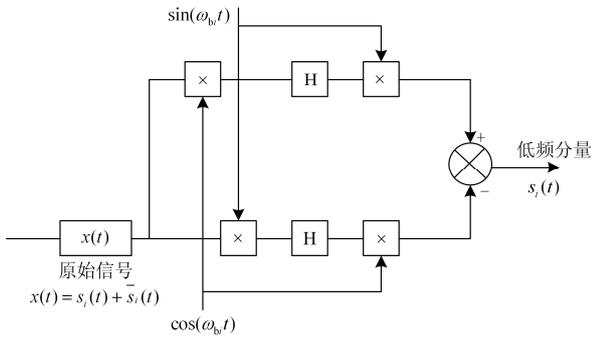


图 2 基于 AMD 分解的时频低通滤波器框图

Fig. 2 Block diagram of a time-frequency low pass filter with AMD method

## 2 风电功率信号频谱分析

根据上节分析, AMD 分析方法可以快速有效地提取出需要信号, 但是必须知道原信号的频率成分, 故必须对风电功率信号进行频谱分析。对一个非周期性连续时间信号  $x(t)$ , 其傅里叶变换可以表示为

$$X(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (8)$$

但在实际的控制系统中得到的是连续信号  $x(t)$  的离散采样值  $x(nT)$ 。故需利用  $x(nT)$  来计算  $x(t)$  的频谱。有限长离散信号  $x(n)(n=0, 1, \dots, N-1)$  的离散傅里叶变换可以表示为

$$X(k) = \sum_{n=0}^{N-1} x(n)W_N^{kn} \quad (9)$$

式中:  $k=0, 1, \dots, N-1$ ;  $W_N = e^{-j\frac{2\pi}{N}}$ 。计算过程中需要  $N^2$  次复数乘法和  $N(N-1)$  次复数加法, 当  $N$  较大时, 计算量将会很大, 为此我们采用了快速傅里叶变换(Fast Fourier Transformation, FFT)。

将  $x(n)$  分解为偶数与奇数两个序列之和。

$$x(n) = x_1(n) + x_2(n) \quad (10)$$

式中:  $x_1(n)$  为偶数序列;  $x_2(n)$  为奇数序列。长度都为  $N/2$ , 则

$$X(k) = \sum_{n=0}^{\frac{N}{2}-1} x_1(n)W_N^{2kn} + \sum_{n=0}^{\frac{N}{2}-1} x_2(n)W_N^{(2n+1)k} \quad (11)$$

式中,  $k=0, 1, \dots, N-1$ , 推导可得式(12)、式(13)。

$$X(k) = X_1(k) + W_N^k X_2(k) \quad (12)$$

$$X(k + \frac{N}{2}) = X_1(k) - W_N^k X_2(k) \quad (13)$$

式中,  $k=0, 1, \dots, N/2-1$ 。FFT 利用了  $W_N$  的对称性

和周期性, 其计算量减少为  $(N/2)\log_2^N$  次乘法和  $N\log_2^N$  次加法, 当  $N$  值较大时, FFT 算法优越性明显, 图 3 为一个完整的 8 点 FFT 运算流程图。通过 FFT 运算可以得到信号的频谱图, 根据波形的频谱, 就可以确定信号中的频率成分。

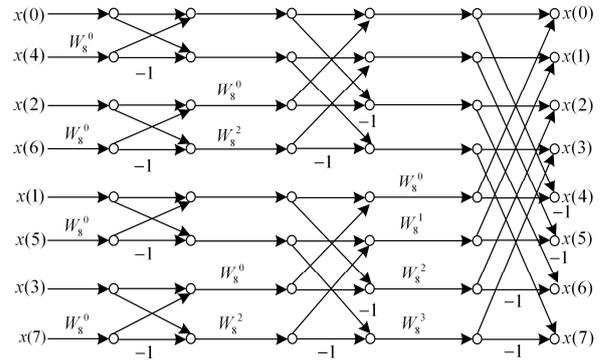


图 3 完整的 8 点 FFT 运算流程图

Fig. 3 Operation flow chart of FFT with complete 8 point

## 3 改进 CS 优化 SVM 参数

### 3.1 SVM 回归理论

假设有训练样本集  $\{x_i, y_i\}(i=1, 2, \dots, l)$ ,  $x_i \in R^n$ ,  $y_i \in R$ ,  $x_i$  为输入变量,  $y_i$  为输出变量,  $i$  为样本个数。 $f(x)$  是经过样本集合训练而建立的回归估计函数, 如式(14)所示。

$$f(x) = \omega \cdot \Phi(x) + b \quad (14)$$

式中:  $\omega \in R^n$ ;  $x \in R^n$ ;  $b \in R$ ;  $\Phi(x)$  为非线性映射函数, 其将样本映射到高维特征空间。

假设训练样本都能在精度  $\varepsilon$  下无误差地用线性函数拟合, 添加一个松弛变量  $\xi_i$ , 附加引入一个惩罚系数  $C$ , 则寻找  $\omega$  和  $b$  的问题转化为式(15)。

$$\begin{cases} \min \Phi(\omega, \xi) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \xi_i \\ \text{s.t.} \begin{cases} y_i - \omega \cdot \Phi(x_i) - b \leq \varepsilon + \xi_i \\ \omega \cdot \Phi(x_i) + b \leq \varepsilon + \xi_i \\ \xi_i \geq 0 \end{cases} \end{cases} \quad (15)$$

引入拉格朗日函数, 整理转化为对偶问题, 最终求得回归函数如式(16)所示。

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x \cdot x_i) + b \quad (16)$$

式中:  $\alpha_i$  和  $\alpha_i^*$  是拉格朗日因子;  $K(x \cdot x_i) = \Phi(x)\Phi(x_i)$  为核函数。本文核函数选用高斯径向基核函数, 其表达式如式(17)所示。

$$K(x, y) = \exp\left(-\frac{|x - y|^2}{\sigma^2}\right) \quad (17)$$

式中,  $\sigma^2$  即为核函数参数。建立 SVM 模型的关键在于寻找适当的惩罚因子参数  $C$  和核函数参数  $\sigma^2$ 。本文采用了改进 CS 算法寻找最优参数。

### 3.2 CS 算法及其改进

CS 算法是一种采用 Levy-flights 的飞行搜索方式, 既可以加快局部搜索效率, 又可以确保系统不会陷入局部最优解。标准 CS 算法需做如下假设:

(1) 每只布谷鸟每次只产一个蛋, 随机放入某个鸟巢; (2) 存有布谷鸟蛋最好的鸟巢将会保留到下一代; (3) 鸟巢数量为确定值  $n$ , 且布谷鸟蛋被发现的概率为固定值  $P_a$ 。

假设已知  $x_{k,i}$ , 则采用 Levy-flights 随机游动策略生成新解  $x_{k+1,i}$  的过程如式(18)所示。

$$x_{k+1,i} = x_{k,i} + \alpha_0 \frac{\Phi \times \mu}{|\nu|^{\lambda}} (x_{k,i} - x_{k,best}) \quad (18)$$

式中:  $x_{k,i}$  表示第  $k$  代第  $i$  个解;  $\alpha_0(x_{k,i} - x_{k,best})$  表示步长, 用以控制算法搜索的范围,  $\alpha_0 = 0.01$ ,  $x_{k,best}$

表示第  $k$  代最优解;  $\frac{\Phi \times \mu}{|\nu|^{\lambda}}$  为 Levy 随机搜索路径,  $\mu, \nu$  服从标准正态分布,  $\lambda = 1.5$ ,  $\Phi$  取值如式(19)所示。

$$\Phi = \left\{ \frac{\Gamma(1 + \lambda) \times \sin\left(\frac{\pi \times \lambda}{2}\right)}{\Gamma\left[\left(\frac{1 + \lambda}{2}\right) \times \lambda \times 2^{\frac{\lambda - 1}{2}}\right]} \right\}^{\frac{1}{\lambda}} \quad (19)$$

式中,  $\Gamma$  为标准的 Gamma 函数。根据布谷鸟蛋固定发现概率  $P_a$  丢弃一部分解, 同时按照式(20)产生同等数量的新解。

$$x_{k+1,j} = x_{k,j} + \gamma(x_{k,j} - x_{k,e}) \quad (20)$$

式中:  $\gamma$  是缩放因子, 服从(0,1)区间均匀随机分布;  $x_{k,j}$  和  $x_{k,e}$  表示第  $k$  代的两个随机解。

为了进一步提高 CS 算法的寻优效率和寻优精度, 本文从以下两个方面进行改善。

1) 由于 CS 算法寻优路径采取随机游走策略, 步长大小不定。步长较大时, 可以保证搜出全局最优解, 但其搜索精度会降低; 步长较小时, 搜索精度提高, 但会降低全局最优搜索能力。为此, 我们可以根据适应值  $f$  的不同, 自适应动态调整补偿控制向量, 使搜索速度和搜索精度同时提高。具体策略如下。

(a) 设规模为  $n$  的群体中第  $k$  代第  $i$  个个体  $x_{k,i}$  的适应值为  $f_i$ , 鸟巢种群的平均适应值为  $f_a = (f_1 + f_2 + \dots + f_n)/n$ , 最优个体的适应值是  $f_{best}$ , 最差个体的适应值是  $f_{worst}$ 。然后将优于  $f_a$  的鸟巢的适应值求平均得到  $f'_a$ 。将种群分为  $f_i < f'_a$ 、 $f'_a < f_i < f_a$ 、 $f_a < f_i$  三组, 分别对每组的步长控制向量的各个分量按照如下方法进行更新。

(b) 将适应值  $f_i < f'_a$  的鸟巢归为第一组, 其所对应的步长控制向量分量更新如式(21)所示。

$$\alpha_{k+1,i} = \alpha_{k,i} \times \frac{1}{1 + \left| \frac{f_i - f'_a}{f_{best} - f'_a} \right|} \quad (21)$$

(c) 将适应值  $f'_a < f_i < f_a$  的鸟巢归为第二组, 其所对应的步长控制向量分量保持不变。

(d) 将适应值  $f_a < f_i$  的鸟巢归为第三组, 其所对应的步长控制向量分量更新如式(22)所示。

$$\alpha_{k+1,i} = \alpha_{k,i} \times \left(1 + \left| \frac{f_i - f_a}{f_{worst} - f_a} \right|\right) \quad (22)$$

2) 引入布谷鸟蛋动态发现概率代替固定发现概率, 使得算法在搜索后期更多地产生新个体, 有效避免产生局部最优解。随着寻优质量的逐步提高, 适当增加发现概率  $P_a$ , 使得在进化后期越容易产生新的个体, 避免算法陷入局部最优解。本文采用正弦递增策略实现  $P_a$  的动态变化, 如式(23)所示。

$$P_a = (P_{a,max} - P_{a,min}) \times \sin\left(\frac{\pi}{2} \times \frac{k-1}{K-1}\right) + P_{a,min} \quad (23)$$

式中:  $K$  为算法的最大进化代数;  $k$  为当前进化代数;  $P_{a,max}$  和  $P_{a,min}$  为  $P_a$  的控制参数。

## 4 风电功率超短期组合预测

由于风机出力的随机性和波动性, 采用单一的预测方法难以取得较好的结果, 本文提出了一种基于 AMD-ICSA-SVM 的风电功率超短期组合预测方法。首先对数据进行 AMD 分解, 根据需求产生一系列不同频率尺度的分量; 然后针对各分量特点采用改进布谷鸟选取预测模型的惩罚因子参数和核函数参数, 分别建立各自合适的 SVM 预测模型; 最后将各分量预测值进行叠加。具体预测步骤如下。

1) 采用快速傅里叶变换得到分析信号的频谱图, 确定截止频率;

2) 利用 AMD 方法对原始输出功率进行提取;

3) 分别对各分量建立 SVM 回归预测模型, 采用改进布谷鸟寻找最优惩罚因子参数和核函数参数, 得到各分量预测值;

- 4) 对各个预测分量进行叠加;
  - 5) 与实际数据进行误差分析.
- 具体流程图如图4所示.

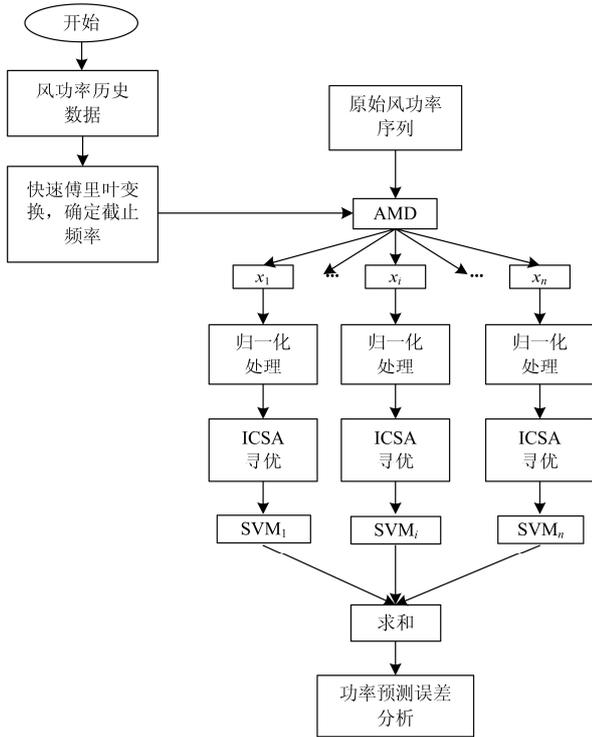


图 4 AMD-ICSA-SVM 组合预测流程图

Fig. 4 Flowchart of AMD-ICSA-SVM combined prediction

### 5 仿真算例

以内蒙古某99 MW风电场为例, 本文采集了该风电场2014年全年的实际输出功率数据, 采样时间间隔为15 min, 对采样数据进行快速傅里叶变换, 得到如图5所示的幅频特性曲线.

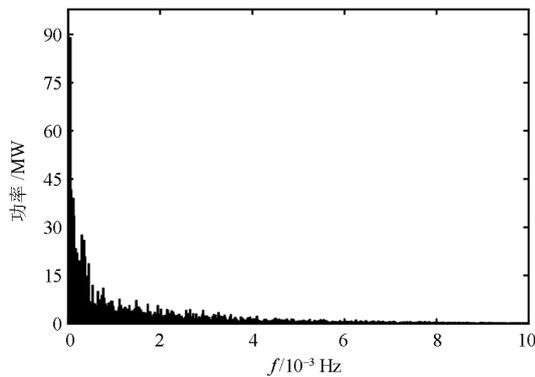


图 5 某 99 MW 风电场全年风机出力幅频特性曲线

Fig. 5 Curve of amplitude frequency characteristics of wind power in the whole year at a 99 MW wind farm

由图5分析, 本文将风电场输出功率分为低频出力( $0 \sim 10^{-4}$  Hz)、中频出力( $10^{-4} \sim 10^{-3}$  Hz)和高频出力( $10^{-3} \sim 4 \times 10^{-3}$  Hz)。 $4 \times 10^{-3}$  Hz以上风机出力由于能量太低, 本文忽略不计。故可以确定采用AMD分解的截止频率分别为 $10^{-4}$  Hz、 $10^{-3}$  Hz和 $4 \times 10^{-3}$  Hz。通过AMD分解, 可得如图6所示的各分量出力情况。

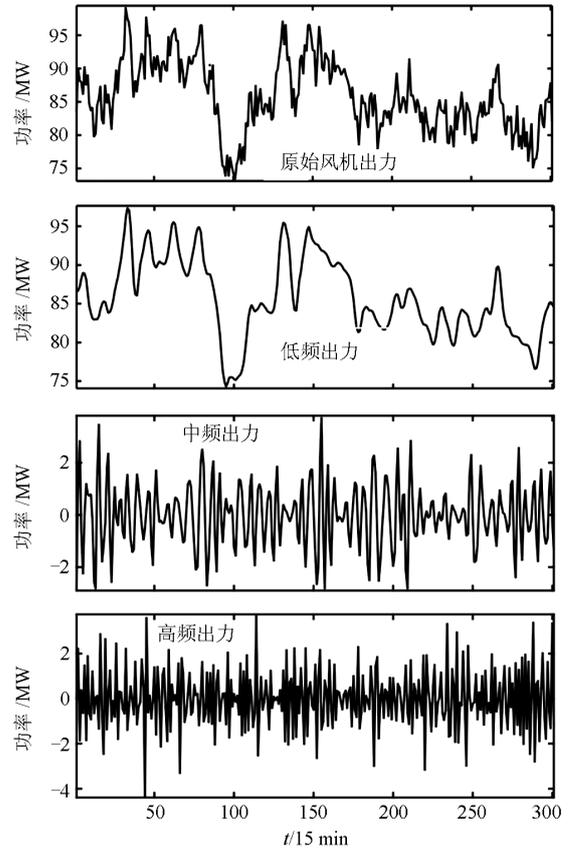


图 6 基于 AMD 分解的风机出力各分量出力图

Fig. 6 Output diagram of wind turbine output based on AMD decomposition

本文从以上300组数据中选取前275组数据, 其中前250组数据作为训练样本, 后25组数据作为测试样本, 构造SVM预测模型, 分别对高、中、低频分量进行建模回归和预测。设鸟巢数为50, 最大迭代次数为50, 最大发现概率为0.6, 最小发现概率为0.25, SVM核函数选择为高斯径向基函数, 其参数 $\sigma^2$ 搜索范围为 $10^{-6} \sim 10^6$ , 惩罚因子参数C搜索范围为 $10^{-6} \sim 10^6$ 。对数据归一化处理后, 采用ICSA-SVM通过Matlab平台仿真进行对比分析, 通过仿真得到高、中、低频分量的预测值, 各分量预测值及其叠加的最终预测值与实际值的对比如图7所示。

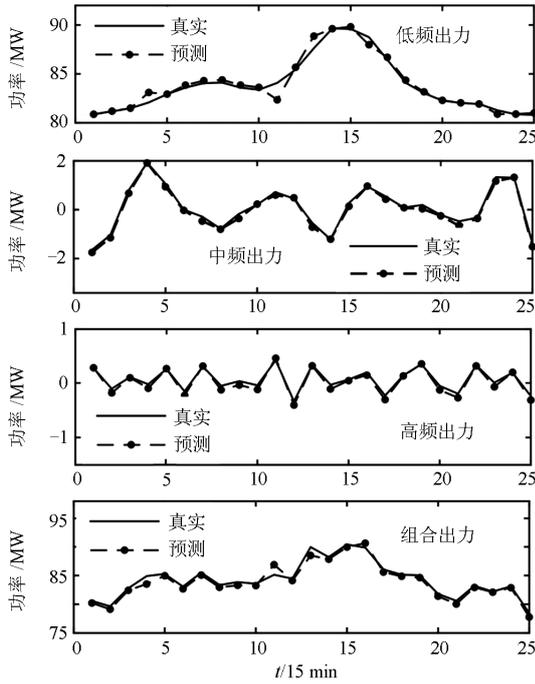


图 7 各分量预测与实际出力对比图

Fig. 7 Comparison of each component forecast and actual output

为了衡量本文方法预测的有效性, 本文分别对采用网格搜索法优化 SVM 参数(Grid Search Method Optimized Support Vector Machines, GSM-SVM)、布谷鸟算法优化 SVM 参数(Cuckoo Search Algorithms Optimized Support Vector Machines, CSA-SVM)和 ICOSA-SVM 进行对比分析, 并采用均方根误差  $e_{RMSE}$ 、平均绝对误差  $e_{MAE}$  和方差相关系数  $r$  对三种分析指标进行评价, 其对应公式如式(24)一式(26)所示。

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2} \quad (24)$$

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i| \quad (25)$$

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(\hat{x}_i - \bar{\hat{x}})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 (\hat{x}_i - \bar{\hat{x}})^2}} \quad (26)$$

式中:  $x_i$  为功率实际值;  $\hat{x}_i$  为功率预测值;  $\bar{x}$  为实际功率平均值;  $\bar{\hat{x}}$  为预测功率平均值;  $N$  为样本数。

通过仿真, 得到分别采用三种不同方法寻优参数时的风电功率预测对比图和风电功率预测误差对比图, 如图 8、图 9 所示。

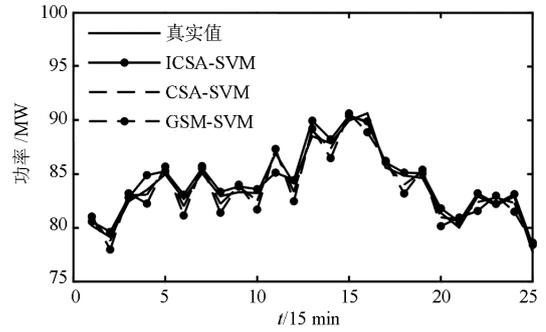


图 8 采用三种方法寻优时风电功率预测对比图

Fig. 8 Comparison results of wind power prediction using three methods

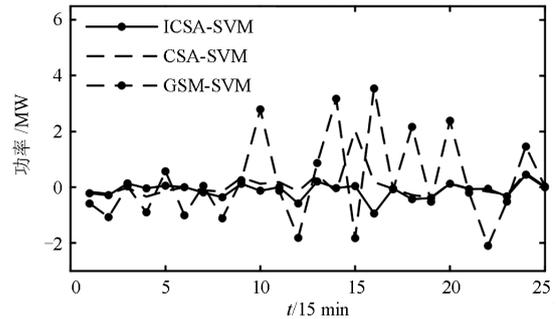


图 9 采用三种方法寻优时风电功率预测误差对比图

Fig. 9 Comparison results of wind power prediction error using three methods

三种预测模型预测评价指标和收敛时间对比如表 1 所示。

表 1 采用三种方法风电功率预测指标对比

Table 1 Comparison of wind power prediction indexes using three methods

预测模型	$e_{RMSE}/MW$	$e_{MAE}/MW$	$r$	$t/s$
GSM-SVM	2.038	1.096	0.941	27
CSA-SVM	0.507	0.306	0.960	95
ICOSA-SVM	0.356	0.209	0.998	38

由图 8、图 9 和表 1 可知, 采用 ICOSA-SVM 方法的组合风功率预测模型能够得到更好的预测指标, 其  $e_{RMSE}$ 、 $e_{MAE}$  和  $r$  指标都比其他两种方法更好, 通过改进的布谷鸟算法, 收敛时间大大减小。虽然 GSM-SVM 比 ICOSA-SVM 收敛速度快, 但 GSM-SVM 预测效果并不好, ICOSA-SVM 预测时间能够满足实际工程需求。

## 6 结论

1) 针对超短期风电功率预测问题, 提出了一种基于解析模态分解和改进布谷鸟优化支持向量机参数的组合预测方法。通过引入解析模态分解, 可以

有效地解决小波分解需要事先确定小波基和分解层数的问题和经验模态分解出现模态混叠的问题。

2) 本文提出了一种改进的布谷鸟算法, 通过引入动态调整步长控制向量和动态发现概率提高算法的寻优速度和寻优精度, 寻找支持向量机的最优惩罚因子参数和核函数参数, 并将其应用到风电场超短期风功率预测中。仿真结果表明, ICSA-SVM 比 CSA-SVM 收敛速度大大提高, 且能得到很好的预测效果。

### 参考文献

- [1] 杨正瓴, 冯勇, 熊定方, 等. 基于季风特性改进风电功率预测的研究展望[J]. 智能电网, 2015, 3(1): 1-7.  
YANG Zhengling, FENG Yong, XIONG Dingfang, et al. Research prospects of improvement in wind power forecasting based on characteristics of monsoons[J]. Smart Grid, 2015, 3(1): 1-7.
- [2] JUNG J, BROADWATER R P. Current status and future advances for wind speed and power forecasting[J]. Renewable and Sustainable Energy Reviews, 2014, 31(2): 762-777.
- [3] 钱政, 裴岩, 曹利宵, 等. 风电功率预测方法综述[J]. 高电压技术, 2016, 42(4): 1047-1060.  
QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [4] RAJAGOPALAN S, SANTOSO S. Wind power forecasting and error analysis using the autoregressive moving average modeling[J]. Power & Energy Society General Meeting, PES: IEEE, 2009: 1-6.
- [5] 李卫, 席林. 一种新的风电场风速时间序列建模及超短期预测方法[J]. 电网与清洁能源, 2015, 31(9): 78-82.  
LI Wei, XI Lin. A new modeling and ultra-short term forecasting method for wind speed time series of wind farm[J]. Power System and Clean Energy, 2015, 31(9): 78-82.
- [6] 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.  
XIU Chunbo, REN Xiao, LI Yanqing, et al. Short-term prediction method of wind speed series based on Kalman filtering fusion[J]. Transactions of China Electrotechnical Society, 2014, 29(2): 253-259.
- [7] CHITSAZ H, AMJADY N, ZAREIPOUR H. Wind power forecast using wavelet neural network trained by improved clonal selection algorithm[J]. Energy Conversion & Management, 2015, 89(1): 588-598.
- [8] 叶林, 赵永宁. 基于空间相关性的风电功率预测研究综述[J]. 电力系统自动化, 2014, 38(14): 126-135.  
YE Lin, ZHAO Yongning. A review on wind power prediction based on spatial correlation approach[J]. Automation of Electric Power Systems, 2014, 38(14): 126-135.
- [9] 杨正瓴, 杨钊, 张玺, 等. 基于季风提高空间相关性预测的优化延迟时间[J]. 电力系统保护与控制, 2016, 44(15): 33-38.  
YANG Zhengling, YANG Zhao, ZHANG Xi, et al. Improving optimal lag time of spatial correlation prediction by characteristics of monsoon[J]. Power System Protection and Control, 2016, 44(15): 33-38.
- [10] 谷云东, 张素杰, 冯君淑. 大用户电力负荷的多模型模糊综合预测[J]. 电工技术学报, 2015, 30(23): 110-115.  
GU Yundong, ZHANG Sujie, FENG Junshu. multi-model fuzzy synthesis forecasting of electric power loads for larger consumers[J]. Transactions of China Electrotechnical Society, 2015, 30(23): 110-115.
- [11] 李昆鹏, 万健如, 朱琳. 永磁同步电机瞬时功率预测控制[J]. 电工技术学报, 2015, 30(1): 38-44.  
LI Kunpeng, WAN Jianru, ZHU Lin. Predictive instantaneous power control for permanent magnet synchronous motors[J]. Transactions of China Electrotechnical Society, 2015, 30(1): 38-44.
- [12] 王晓兰, 王明伟. 基于小波分解和最小二乘支持向量机的短期风速预测[J]. 电网技术, 2010, 34(1): 179-184.  
WANG Xiaolan, WANG Mingwei. Short-term wind speed forecasting based on wavelet decomposition and least square support vector machine[J]. Power System Technology, 2010, 34(1): 179-184.
- [13] 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 CSEE, 2011, 31(31): 102-108.
- [14] 张翌晖, 王贺, 胡志坚, 等. 基于集合经验模态分解和改进极限学习机的短期风速组合预测研究[J]. 电力系统保护与控制, 2014, 42(10): 29-34.  
ZHANG Yihui, WANG He, HU Zhijian, et al. A hybrid short-term wind speed forecasting model based on ensemble empirical mode decomposition and improved extreme learning machine[J]. Power System Protection and Control, 2014, 42(10): 29-34.
- [15] 张娜, 王守相, 王亚旻. 基于掩模经验模态分解的风速组合预测模型[J]. 中国电力, 2014, 47(5): 129-135.  
ZHANG Na, WANG Shouxiang, WANG Yamin. Wind

- speed forecasting modelling by combination of masking signal based empirical mode decomposition and GA-BP neural network[J]. *Electric Power*, 2014, 47(5): 129-135.
- [16] CHEN G, WANG Z. A signal decomposition theorem with Hilbert transform and its application to narrowband time series with closely spaced frequency components[J]. *Mechanical Systems and Signal Processing*, 2012, 28: 258-279.
- [17] FELDMAN M. A signal decomposition or low pass filtering with Hilbert transform[J]. *Mechanical Systems and Signal Processing*, 2011, 25(8): 3205-3208.
- [18] 时培明, 苏翠娇, 赵娜, 等. 基于解析模态分解的机械故障诊断方法[J]. *中国机械工程*, 2016, 27(5): 674-679.  
SHI Peiming, SU Cuijiao, ZHAO Na, et al. Fault diagnosis method for rotating machinery based on AMD[J]. *China Mechanical Engineering*, 2016, 27(5): 674-679.
- [19] 李苗, 任伟新, 胡异丁, 等. 基于解析模态分解法的桥梁动态应变监测数据温度影响的分离[J]. *振动与冲击*, 2012, 31(21): 6-10.  
LI Miao, REN Weixin, HU Yiding, et al. Separating temperature effect from dynamic strain measurements of a bridge based on analytical mode decomposition method[J]. *Journal of Vibration and Shock*, 2012, 31(21): 6-10.
- [20] 颜晓娟, 龚仁喜, 张千锋. 优化遗传算法寻优的 SVM 在短期风速预测中的应用[J]. *电力系统保护与控制*, 2016, 44(9): 38-42.  
YAN Xiaojuan, GONG Renxi, ZHANG Qianfeng. Application of optimization SVM based on improved genetic algorithm in short-term wind speed prediction[J]. *Power System Protection and Control*, 2016, 44(9): 38-42.
- [21] 方必武, 刘涤尘, 王波, 等. 基于小波变换和改进萤火虫算法优化 LSSVM 的短期风速预测[J]. *电力系统保护与控制*, 2016, 44(8): 37-43.  
FANG Biwu, LIU Dichen, WANG Bo, et al. Short-term wind speed forecasting based on WD-CFA-LSSVM model[J]. *Power System Protection and Control*, 2016, 44(8): 37-43.
- [22] 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.
- [23] 孙丙香, 高科, 姜久春, 等. 基于 ANFIS 和减法聚类的动力电池放电峰值功率预测[J]. *电工技术学报*, 2015, 30(4): 272-280.  
SUN Bingxiang, GAO Ke, JIANG Jiuchun, et al. Research on discharge peak power prediction of battery based on ANFIS and subtraction clustering[J]. *Transactions of China Electrotechnical Society*, 2015, 30(4): 272-280.
- [24] 路小娟, 董海鹰. 太阳能热发电集热系统终端受限非线性模型预测控制[J]. *热力发电*, 2015, 44(10): 63-67.  
LU Xiaojuan, DONG Haiying. Predictive control of nonlinear model for heat collecting system with terminal limit in solar thermal power generation system[J]. *Thermal Power Generation*, 2015, 44(10): 63-67.
- [25] RAJABIOUN R. Cuckoo optimization algorithm[J]. *Applied Soft Computing*, 2011, 11(8): 5508-5518.

收稿日期: 2016-07-15; 修回日期: 2016-08-24

作者简介:

李燕青(1974—), 男, 博士, 教授, 主要研究方向为先进输变电技术, 电力系统分析与控制, 新能源发电与智能电网等; E-mail: hdlyq@163.com

袁燕舞(1991—), 男, 通信作者, 硕士研究生, 主要研究方向为风电预测, 混合储能平抑新能源并网波动。E-mail: 3061576301@qq.com

(编辑 魏小丽)