

基于VMD-PE和优化相关向量机的 短期风电功率预测

武小梅, 林 翔, 谢旭泉, 谢海波

(广东工业大学自动化学院, 广州 510006)

摘 要: 针对风电功率序列非线性、非平稳性等特点,提出一种基于变分模态分解(VMD)-排列熵(PE)和混沌布谷鸟搜索算法(CCS)优化相关向量机的短期风电功率预测新方法。为降低风电功率序列非平稳性和减小计算规模,首先采用变分模态分解技术(VMD),将原始风电功率序列分解成一系列不同的子模态,利用排列熵(PE)分析其复杂度并重组得到子序列;然后采用CCS优化后的相关向量机(CCS-RVM)对各子序列进行提前24 h预测;最后将预测结果叠加得到最终预测值,并利用某风电场实际采集数据进行仿真验证。结果表明,所提预测模型能有效提高风电功率预测的准确性。

关键词: 风电功率; 预测模型; 变分模态分解; 相关向量机; 排列熵; 混沌布谷鸟搜索算法

中图分类号: TM614

文献标识码: A

0 引 言

由于风电本身具有间歇性与随机性,大规模的风电并网给调度运行工作提出更高的要求。风电对电网安全运行的不利影响日益突显,通过对风电功率的准确预测,可使调度员及时调整调度计划及风电机组控制方案,进而减少系统的备用容量,降低电力系统运行成本,提高电力系统的运行稳定性和供电可靠性^[1,2]。

由于单个预测模型在风电功率预测中会有局限性,无法取得最佳的预测性能,因此目前多采用建立组合预测模型来提高整体预测性能,而组合预测方法经常会用到信号分解方法。信号分解方法包括集合经验模式分解^[3]、小波包变换^[4]等,目的是将原始序列解析成一系列子模态以降低非平稳性,逐一对其预测并重组来实现最终预测。预测方法多采用基于人工智能的预测算法,如神经网络^[4,5]、支持向量机^[6,7]等。相关向量机^[8-10](relevance vector machine, RVM)是由Tipping基于总体贝叶斯框架下稀疏概率模型提出的一种机器学习算法,具有与支持向量机相同的优点,并且其核函数无梅西定理

的约束,可更灵活地选择核函数,但其核函数选取与参数优化是提高RVM算法精度的关键所在^[9]。已有学者提出采用粒子群算法^[9]与人工蜂群算法^[10]等优化算法对核参数进行优化,但都存在过早收敛的问题。本文采用一种新型的自适应信号分解方法——变分模态分解(variational mode decomposition, VMD)处理初始风电功率序列,由此提出一种基于VMD-排列熵与混沌布谷鸟搜索算法优化相关向量机的短期风电功率预测方法,并通过某风电场的实测数据验证本文方法有效性。

1 变分模态分解与排列熵

1.1 变分模态分解

变分模式分解^[11]是一种自适应信号分解新方法,2014年由Dragomiretskiy等提出。该方法把信号分解计算转到变分理论框架中,通过迭代计算求取变分模型得到的最佳解来确定每一分量的频率中心值及带宽,进而确保信号频域空间剖分及子分量分离,突显数据的局部特征,且具有良好的采样效应。变分问题构造步骤如下^[12,13]:

1) 采用Hilbert变换计算每个模态函数 $u_k(t)$ 的

收稿日期: 2016-08-03

基金项目: 中央财政支持地方高校发展专项资金(粤财教[2016]202号)

通信作者: 林 翔(1991—),男,硕士研究生,主要从事新能源发电预测应用研究。linxiang6022@163.com

解析信号以获得其单边频谱;

2) 通过各模态解析信号与所对应的中心频率 $e^{-j\omega_k t}$ 项混合, 将各模态的频谱调制到基频带;

3) 各模态带宽通过解调信号的高斯平滑法获取, 由此产生约束变分问题:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} & \sum_{k=1}^K u_k = f \end{aligned} \quad (1)$$

其中, $\{u_k\}$ 、 $\{\omega_k\}$ ——子信号及其中心频率的集合; K ——子信号的总数; $\delta(t)$ ——狄拉克分布。

求解以上约束变分问题需加入二次惩罚项 α 和拉格朗日乘子 $\lambda(t)$, 转换为非约束性变分问题, α 使重构信号精度在高斯噪声情况下得以保持, 而 $\lambda(t)$ 使约束条件保证严格性, 改进后可表示为:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \end{aligned} \quad (2)$$

VMD 中采用了交替方向乘子法 (alternate direction method of multipliers, ADMM) 解决 (2) 式变分问题, 通过交替更新 u_k^{n+1} 、 ω_k^{n+1} 、 λ_k^{n+1} 求解改进后拉格朗日表达式“鞍点”, 迭代求解步骤见文献 [11]。

VMD 算法步骤如下:

1) 初始化 $\{\hat{u}_k^1\}$, $\{\hat{\omega}_k^1\}$, $\{\hat{\lambda}^1\}$, 迭代次数 n 设 1。

2) 根据式 (3) 和式 (4) 更新 u_k 和 ω_k 。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

3) 通过式 (5) 更新拉格朗日乘子 λ :

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau [\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega)] \quad (5)$$

4) 根据式 (6) 判断收敛性, 若不收敛则 n 加 1, 并回到步骤 2), 否则停止迭代, 得到分解结果。

$$\sum_{k=1}^K \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \varepsilon \quad (6)$$

1.2 排列熵

排列熵 (permutation entropy, PE) [14] 作为一种衡

量时间序列复杂性的测度方法, 因其抗干扰能力强、计算简便等特点被广泛应用于序列复杂度和非线性分析中。由于时间序列的微小变化都会影响排列熵的熵值, 因此其熵值可以作为时间序列复杂度分析的重要指标。具体排列熵计算步骤见文献 [14]。

2 相关向量机及优化

2.1 相关向量机

相关向量机 [8] 是 Tipping 提出的一种与支持向量机相似的稀疏概率模型, 在贝叶斯框架下实现样本的训练学习, 在先验参数的结构基础上采用主动相关决策模型移除不相关点, 进而得到稀疏化模型。

若给定的训练样本输入集 $\{\mathbf{x}_n, \mathbf{t}_n\}_{n=1}^N$, N 为样本数量, t 为标量输出, RVM 回归模型可定义为:

$$\mathbf{t}_i = \sum_{j=1}^N w_j K(\mathbf{x}, \mathbf{x}_j) + w_0 + \varepsilon \quad (7)$$

式中, ε ——服从 $N(0, \sigma^2)$ 分布的各独立样本误差; 权值向量 $\mathbf{w} = (w_0, w_1, \dots, w_N)^T$; w_0 ——权值初值; $K(\mathbf{x}, \mathbf{x}_j)$ ——核函数; \mathbf{x} ——相关向量。

相关向量机的学习训练就是求解给定样本所对应权值向量 \mathbf{w} 的后验分布。与支持向量机相比较, 相关向量机的稀疏性决定了核函数的运算量大大减少, 更由于核函数无需满足梅西定理的限制, 可灵活地选择核函数类型而被广泛地运用。然而, 相关向量机中核参数的选择方法众多, 但仍无统一准则。研究表明, 核参数的选取对预测结果至关重要 [9]。

2.2 组合核函数构造

相关向量机是基于核学习的模式识别技术, 而由于不同核函数适用于不同情况, 从而可构建不同的 RVM 预测模型, 根据核函数特性主要把核函数分为全局和局部核函数, 全局核主要是多项式核, 局部核则是径向基核。组合核函数主要是通过不同核函数相结合, 利用两者优势互补, 使新的核函数具有更优性能 [9]。为了改善相关向量机的泛化能力, 采用多项式核与径向基核线性组合的方式构造一种组合核函数, 该组合核函数表达式为:

$$K_{\min} = \mu K_{\text{poly}} + (1 - \mu) K_{\text{rbf}}, \quad \mu \in (0, 1) \quad (8)$$

$$K_{\text{poly}} = [(x \cdot x_i) + 1]^d \quad (9)$$

$$K_{\text{rbf}} = \exp(-\|x - x_i\|^2 / 2\sigma^2) \quad (10)$$

式中, K_{poly} —— 多项式核; K_{rbf} —— 径向基核; μ —— 权重参数; δ —— 径向基核参数; d —— 多项式核参数。

2.3 混沌布谷鸟搜索算法

2.3.1 布谷鸟搜索算法

布谷鸟搜索(cuckoo search, CS)算法是通过模拟布谷鸟的寄生繁衍及 Levy 飞行模式寻觅问题最优解^[15]。采用 Levy 飞行来更新解,并根据发现概率 P_a 对一部分解进行丢弃与更新。假设 x_k^t 为第 k 个鸟巢在第 t 代的鸟巢位置, Levy(λ) 为 Levy 随机搜索路径,并且服从 Levy 分布,更新公式如下:

$$\begin{cases} x_k^{(t+1)} = x_k^{(t)} + \alpha \oplus \text{Levy}(\lambda), 1 \leq k \leq N \\ \text{Levy} \sim u = t^{-\lambda}, 1 \leq \lambda \leq 3 \end{cases} \quad (11)$$

式中, k —— 鸟巢元素序号; N —— 鸟巢元素总数量; t —— 迭代次数; α —— 步长系数; \oplus —— 点乘算符。

CS 算法虽然有良好的全局搜索能力,但也存在局部搜索能力低与后期搜索效率低的缺点。基于 CS 算法的不足,提出采用早熟收敛判断准则,在 CS 算法每次迭代后进行早熟收敛判断,若算法进行早熟状态,此时算法不直接进入下次迭代,而是引入混沌局部搜索算子对种群进行再一次的搜索。

2.3.2 早熟收敛判断准则

借鉴粒子群早熟收敛判断方法^[6],在布谷鸟搜索算法中引入群体适应度方差作为算法迭代过程中早熟收敛判断准则,定义如下:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N \left(\frac{f_i - f_{\text{avg}}}{f} \right)^2 \quad (12)$$

$$f = \begin{cases} 1, & \text{其他} \\ \max |f_i - f_{\text{avg}}|, & \max |f_i - f_{\text{avg}}| > 1 \end{cases} \quad (13)$$

式中, f_i —— 第 i 个鸟巢的适应度; f —— 定标因子; f_{avg} —— 种群鸟巢的平均适应度。 σ^2 越小,群体中鸟巢的聚集程度越大,种群趋近于收敛,若 σ^2 小于某一给定值,则认为出现早熟收敛。当 $\sigma^2 < \varphi$ 时,本文通过增加混沌搜索的方法避免早熟现象出现。

2.3.3 混沌局部搜索算子

为了提高算法精度,避免陷入局部极值,本文将混沌搜索策略^[16]融入标准 CS 算法中,当算法运行过程陷入局部早熟时,采用混沌搜索算法在群体最佳鸟巢附近搜索,这样既不会干扰 CS 算法搜索机制,又能使算法远离局部最优区域,实现全局搜

索与局部搜索相结合,从而提高了 CS 的搜索精度。采用 Logistic 方程映射产生混沌序列,即:

$$x_{j+1} = \eta \cdot x_j (1 - x_j) \quad (14)$$

式中, η —— 控制参数,当 η 在 $[3.57, 4]$ 时,系统处于混沌区域; x_j —— 变量; j —— 迭代次数。

混沌布谷鸟搜索算法中 CS 算法主要用于全局搜索,而混沌搜索算法则根据 CS 算法搜索结果进行局部搜索。混沌搜索算法详细步骤参考文献^[17]。

2.4 CCS优化相关向量机

由于相关向量机核参数选择是影响相关向量机预测性能的主要因素,因此优化算法的收敛性对本文预测算法的精度会有直接影响。研究发现,参数 δ 、 μ 、 d 的选择对相关向量机的风电功率预测精度会有一定的影响^[9,10]。核宽度 δ 、 d 分别定义了径向基核与多项式核的高维特征空间 $\phi(x)$ 的结构,过大或过小均会降低模型的泛化性能, μ 确定了局部核与全局核的比例,其值大小也会影响模型的泛化性能。采用 CCS 算法优化相关向量机的基本思想是用 CCS 算法寻找最优参数 δ 、 μ 、 d 的过程。CCS-RVM 的实现过程流程图如图 1 所示。

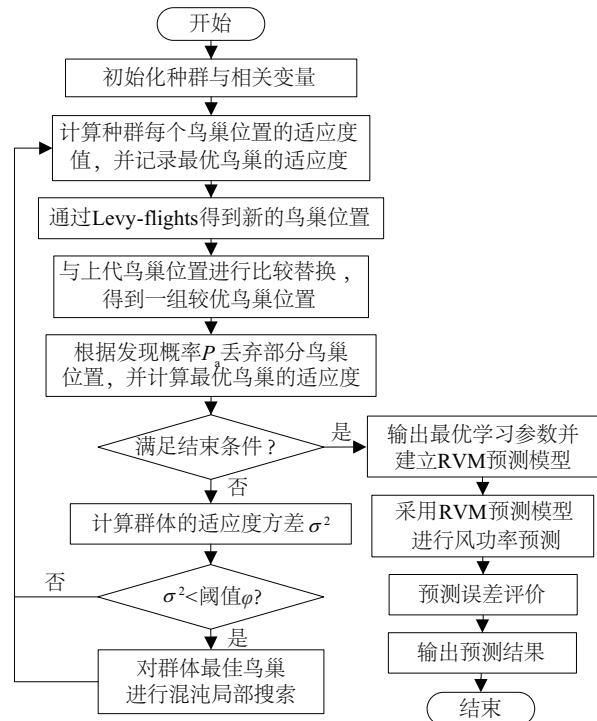


图1 CCS-RVM流程图

Fig. 1 Flow chart of CCS-RVM

算法步骤如下:

步骤 1: 设定 RVM 核参数 δ 、 μ 、 d 取值范围, 鸟巢个数、迭代次数与混沌局部搜索次数, 发现概率 P_a , 步长系数, 进行实数编码, 初始化种群 X 。

步骤 2: 评价种群中个体适应度, 保存种群最优个体适应度, 选取 RVM 模型预测结果的归一化均方根误差 e_{NRMSE} 作为适应度函数, 公式详见 4.3 节。

步骤 3: 按照式 (11) 进行鸟巢位置 Levy 飞行模式更新, 得到新的一组鸟巢 X_i , 并评价鸟巢适应度值。

步骤 4: 根据步骤 3 得到的适应度评价结果, 与其父代鸟巢 X_{i-1} 进行比较, 保留一组更优鸟巢 K_{i-1} 。

步骤 5: 比较随机数 r 与发现概率 P_a , 若 $r > P_a$, 则随机更新 K_{i-1} 中鸟巢位置; 若 $r < P_a$, 则保留 K_i 中原有鸟巢位置, 获得一组新的鸟巢 K_i , 与鸟巢 K_{i-1} 进行比较, 保留最优鸟巢存于 X_i 中。

步骤 6: 判断算法终止条件是否满足, 若满足, 执行步骤 8; 否则执行步骤 7。

步骤 7: 根据式 (12) 评价群体适应度方差, 若 $\sigma^2 < \varphi$, 则对群体最优鸟巢执行混沌局部搜索操作, 而后执行步骤 2; 否则直接执行步骤 2。

步骤 8: 将 X_i 中适应度最好的一组鸟巢位置转换成参数 δ 、 μ 、 d , 并传给 RVM 预测模型。

3 建模流程

3.1 风电功率预测模型建模流程

本文采用 VMD-PE-CCS-RVM 预测模型, 首先对风电功率进行 VMD 分解, 根据各子模态的排列熵分析结果进行子序列重组, 并与风速数据结合形成 RVM 输入、输出样本集。采用 CCS 算法优化各子序列 RVM 模型参数, 把最优的 RVM 预测模型应用于各子序列的预测中, 并把各子序列预测结果相加得到最终预测值, 建模过程如图 2 所示。

3.2 输入变量选取与预处理

根据关联性分析, 风速与功率耦合程度较高, 因此选取风速作为模型输入变量之一。由于风电功率预测的输入变量主体为功率, 只需对功率数据进行 VMD 分解, 而风速数据无需分解, 只需加入到分解后子序列数据中, 所以将原始数据集分成 2 类,

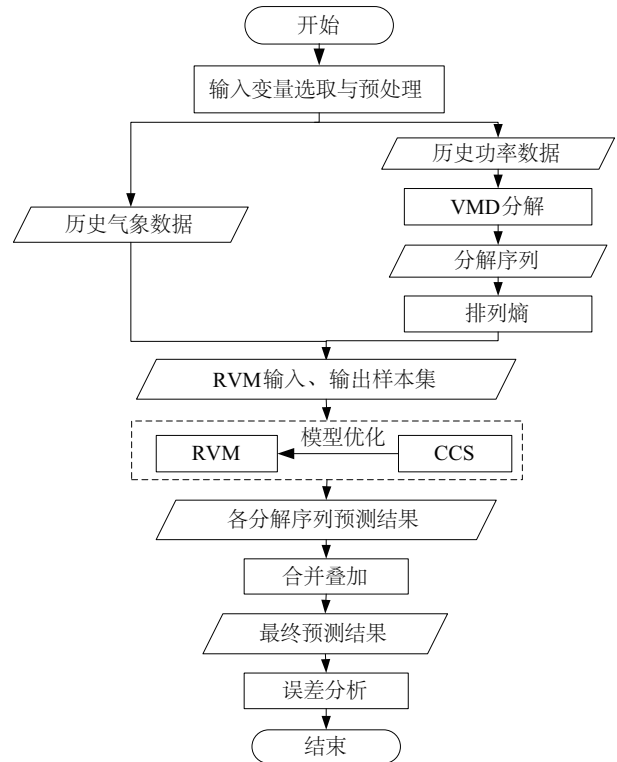


图2 风电功率预测流程图

Fig. 2 Wind power prediction flow chart

历史气象数据作为一类, 包括风速的历史气象数据, 另一类是历史功率数据。预处理步骤主要是去除样本数据异常点, 并对原始数据进行归一化处理, 本文将原始数据规划到 $[0, 1]$ 之间, 公式为:

$$f: x \rightarrow y = \frac{(x_i - x_{\min})}{x_{\max} - x_{\min}} \quad (16)$$

式中, $x, y \in \mathbf{R}^n$, $x_{\min} = \min(x)$ 、 $x_{\max} = \max(x)$, $y_i \in [0, 1]$, $i = 0, 1, 2, \dots, n$ 。

4 算例与分析

4.1 数据来源

以广东某风电场 1 号风力机 2011 年 11 月 1~25 日的实际采集数据为研究对象, 包括风速和输出功率实时数据。考虑到系统每 1 min 采集 1 次数据, 在 1 h 内将 15 min 的数据求取平均值, 每天 24 h, 总共 96 个点。在实际建模过程中, 选取 11 月 1~24 日数据作为 RVM 模型的训练集, 最后 1 d 数据作为模型的测试集。为计算方便, 将功率数据进行归一化预处理, 原始风电功率序列如图 3 所示。




图3 风电功率序列

Fig. 3 Wind power time series

4.2 VMD-PE处理

VMD需事先给定模态数 K ,模态数过多会导致模态重复或产生额外的噪声,过少会导致模态欠分解。由于各模态中心频率值都不相同,采用中心频率值确定模态数 K 。首先 K 值范围取8~12,然后对不同 K 值逐一进行分解,检验每个 K 值对应的各模态中心频率,若出现中心频率值相近模态,视为过分解,经过反复试验, K 值取10为宜。

若利用RVM预测模型直接对每一个模态进行预测,会增加计算规模,为减小计算规模,利用排列熵理论对每一模态进行复杂度分析,根据分析得到的排列熵值进行合并叠加,计算结果如图4所示。




图4 各模态的排列熵

Fig. 4 Permutation entropy of each mode component

从图4可知,模态1和模态2的排列熵值呈现出一定程度的相似性,差值为0.03,说明2种模态生成新模式的概率相近,可把两者合并成一个新的子序列作为RVM新的输入。模态3的PE值明显有别于其他模态,可单独作为一个新子序列,同理

其余模态处理结果如表1所示,各新子序列如图5所示。

表1 各模态分量的合并结果

Table 1 Combination result of each mode component

新序列号	原模态序列号	新序列号	原模态序列号
1	1,2	4	5
2	3	5	6,10
3	4	6	7,8,9




图5 风电功率序列VMD-PE处理结果

Fig. 5 Wind power subsequences processed by VMD-PE

4.3 预测模型的评价标准

本文选用国际上普遍采用的归一化绝对平均误差 e_{NMAE} 和归一化均方根误差 e_{NRMSE} 作为预测误差评价指标,定义为:

$$e_{NMAE} = \frac{1}{P_{cap}} \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \times 100\% \quad (17)$$

$$e_{NRMSE} = \frac{1}{P_{cap}} \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \times 100\% \quad (18)$$

式中, m 、 y_i 、 \hat{y}_i ——样本数,实际值和预测值; P_{cap} ——风力机的额定容量。

4.4 预测结果与对比分析

为了验证本文所述方法的效果,本文采用4.2节中经VMD-PE处理形成的6个子序列与预处理后形成的风速数据形成预测样本集,留最后1d数据作测试集,其他作训练集。选用2.4节中提出的CCS-RVM预测算法逐一为6个子序列建立预测模型。为进行不同模型的公平对比,种群规模均取

30,最大迭代次数设为 100。CCS 中,步长系数为 0.01,概率 P_a 为 0.25,混沌局部搜索次数 10 次,阈值 φ 为 5×10^{-5} ;PSO 中,学习因子取 2,惯性权重取 1。本文方法各子序列预测结果如图 6 所示。




图6 各子序列预测结果
Fig. 6 Forecasting results of each subsequence

从图 6 中可观察到各子序列预测值与实测值,前 3 个子序列预测值都能对实测值实现良好地跟随,而后 3 个子序列预测值对实测值跟踪效果不佳。由于 4.2 节中对子序列进行重组时,从序列 1 到序列 6,排列熵值逐渐增大,复杂度随之增加,预测难度相应不断增大,各序列预测误差逐渐增大,后 3 个子序列归一化绝对平均误差分别为:3.14%、2.72%和 4.49%,序列 6 的预测效果最差,可认为 VMD-PE-CCS-RVM 模型的误差主要源于序列 6。

为检验 VMD-PE-CCS-RVM 模型最终的预测效果,把 6 个子序列预测结果进行叠加得到最终预测值,并与基于 EEMD 组合模型作比较。其中,EEMD 组合模型与本文方法最优预测结果如图 7 所示,各预测模型的训练时间与测试误差如表 2 所示。

由图 7 和表 2 分析可知,在 EEMD-PE 与 VMD-PE 各自的组合模型中,基于 CCS 优化的组合模型预测精度均高于基于 PSO 优化的组合模型,说明 CCS 优化相关向量机核参数,能有效提高相关向量机泛化能力,具有更高的预测精度。对比 2 种信号分解组合模型,经 VMD 分解处理后预测精度高于




图7 本文风电功率预测结果
Fig. 7 Wind power forecasting results

表2 各预测模型的训练时间与测试误差
Table 2 Training time and testing errors of each prediction model

预测模型	$e_{NMAE}/\%$	$e_{NRMSE}/\%$	训练时间/s
EEMD-RVM	10.22	12.70	11
EEMD-CCS-RVM	9.21	11.31	1154
EEMD-PE-PSO-RVM	9.19	11.16	610
EEMD-PE-CCS-RVM	8.95	10.85	697
VMD-RVM	9.72	11.51	13
VMD-CCS-RVM	7.42	9.44	1283
VMD-PE-PSO-RVM	8.10	10.27	717
VMD-PE-CCS-RVM	7.07	9.08	765

EEMD 分解处理后的预测精度,特别是功率波动较大的时间段更具有明显的优势,因此采用 VMD 分解处理更有利于降低风电功率预测的误差。其中,VMD-PE-CCS-RVM 模型的预测结果是所列举的组合预型中预测效果最佳的,不仅从预测模型的误差指标中可看出该模型误差最小, e_{NRMSE} 与 e_{NMAE} 分别仅为 9.08%和 7.07%,而且该模型的训练时间远小于 VMD-CSS-RVM 模型,说明了采用排列熵理论分析模态分量复杂度,重组子序列的方法不会降低模型的预测精度,却使模型的训练时间大大缩短。

为进一步验证 VMD-PE-CCS-RVM 模型在不同季节预测效果,选取夏季与冬季 2 种极端场景,2011 年 6 月、12 月对应夏季与冬季 2 种场景,分别对每个场景进行提前 3 天预测,预测结果如图 8 所示,预测误差评价如表 3 所示。

由图 8 与表 3 分析可知,在 2 种极端季节场景

下,本文方法的预测结果均能够很好地跟踪到实测功率曲线,在风电波动较大的冬季预测效果稍弱。相反地,风电波动较小的夏季预测效果最好,归一化均方根误差与归一化绝对平均误差最小均达到7.17%和5.78%。从总体上看,不论是夏季还是冬季,归一化均方根误差均小于14%,可说明本文所提的预测模型具有较强的泛化性能。




图8 夏冬季节场景风电功率预测结果

Fig. 8 Wind power forecasting results of two seasonal scenarios

表3 夏冬季节场景误差评价

Table 3 Errors evaluation of two seasonal scenarios

预测天	$e_{NMAE}/\%$		$e_{NRMSE}/\%$	
	夏季	冬季	夏季	冬季
1	5.89	9.91	7.83	11.51
2	8.10	10.01	9.40	12.97
3	5.78	11.09	7.17	13.24

5 结 论

本文提出一种基于变分模态分解(VMD)-排列熵(PE)和混沌布谷鸟搜索算法(CCS)优化相关向量机的短期风电功率预测方法,其主要结论如下:

1)针对风电功率序列的非平稳性,采用VMD方法处理初始风电功率序列,利用排列熵对分解得到的子模态进行复杂度分析,以排列熵值为依据进行子序列重组,降低预测模型的计算规模。

2)针对相关向量机核参数难以确定的问题,提出采用混沌布谷鸟搜索算法来优化相关向量机核参数。利用CCS算法全局搜索能力强、收敛精度高的优点,为重组后子序列分别构建CCS-RVM的预测模型,以提高风电预测精度。

3)通过实际风电场运行数据验证本文方法的有效性,实验结果表明,本文方法不仅提高了预测精度,而且缩短了数据样本的学习时间,从整体上提高预测精度和预测效率,具有很好的应用潜力。

[参考文献]

- [1] Foley A M, Leahy P G, Marvuglia A, et al. Current methods and advances in forecasting of wind power generation[J]. Renewable Energy, 2012, 37(1): 1—8.
- [2] Yuan Xiaoming. Overview of problems in large-scale wind integrations[J]. Journal of Modern Power Systems & Clean Energy, 2013, 1(1): 22—25.
- [3] 王 贺, 胡志坚, 张翌辉, 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.
- [3] 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.
- [4] 孟安波, 卢海明, 胡函武, 等. 混合小波包与纵横交叉算法的风电预测神经网络模型[J]. 太阳能学报, 2015, 36(7): 1645—1651.
- [4] Meng Anbo, Lu Haiming, Hu Hanwu, et al. Hybrid wavelet packet-CSO-ENN approach for short-term wind power forecasting [J]. Acta Energiæ Solaris Sinica, 2015, 36(7): 1645—1651.
- [5] 徐青山, 郑维高, 卞海红, 等. 考虑游程检测法重构的EMD-Elman风电功率短时组合预测[J]. 太阳能学报, 2015, 36(12): 2852—2859.
- [5] Xu Qingshan, Zheng Weigao, Bian Haihong, et al. Short term forecast of wind power based on empirical mode decomposition and elman neural network considering runs-test reconstruction [J]. Acta Energiæ

- Solaris Sinica, 2015, 36(12): 2852—2859.
- [6] 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.
- [6] 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.
- [7] 王爽心, 李 涛, 孙东旭, 等. 基于小世界优化的支持向量机风电功率预测[J]. 太阳能学报, 2015, 36(3): 720—726.
- [7] Wang Shuangxin, Li Tao, Sun Dongxu, et al. Wind power forecasting based on small-world optimization and support vector machine[J]. Acta Energiæ Solaris Sinica, 2015, 36(3): 720—726.
- [8] Tipping M E. Sparse bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research, 2001, 1(3): 211—244.
- [9] 段 青, 赵建国, 马 艳. 优化组合核函数相关向量机电力负荷预测模型[J]. 电机与控制学报, 2010, 14(6): 33—38.
- [9] Duan Qing, Zhao Jianguo, Ma Yan. Relevance vector machine based on particle swarm optimization of compounding kernels in electricity load forecasting[J]. Electric machines and Control, 2010, 14(6): 33—38.
- [10] Fei Shengwei W, He Yong. Wind speed prediction using the hybrid model of wavelet decomposition and artificial bee colony algorithm-based relevance vector machine[J]. International Journal of Electrical Power & Energy Systems, 2015, 73: 625—631.
- [11] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531—544.
- [12] 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.
- [12] Liu Changliang, Wu Yingjie, Zhen Chenggang. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering[J]. Proceedings of the CSEE, 2015, 35(13): 3358—3365.
- [13] Zhang Yachao, Liu Kaipei, Qin Liang, et al. Deterministic and probabilistic interval prediction for short-term wind power generation based on variational mode decomposition and machine learning methods[J]. Energy Conversion & Management, 2016, 112: 208—219.
- [14] 李 军, 李 青. 基于CEEMDAN-排列熵和泄漏积分ESN的中期电力负荷预测研究[J]. 电机与控制学报, 2015, 19(8): 70—80.
- [14] Li Jun, Li Qing. Medium term electricity load forecasting based on CEEMDAN-permutation entropy and ESN with leaky integrator neurons[J]. Electric machines and Control, 2015, 19(8): 70—80.
- [15] Wang Jianzhou, Jiang He, Wu Yujie, et al. Forecasting solar radiation using an optimized hybrid model by cuckoo search algorithm[J]. Energy, 2015, 81: 627—644.
- [16] 刘自发, 葛少云, 余贻鑫. 基于混沌粒子群优化方法的电力系统无功最优潮流[J]. 电力系统自动化, 2005, 29(7): 53—57.
- [16] Liu Zifa, Ge Shaoyun, Yu Yixin. Optimal reactive power dispatch using chaotic particle swarm optimization algorithm[J]. Automation of Electric Power Systems, 2005, 29(7): 53—57.
- [17] 李 兵, 蒋慰孙. 混沌优化方法及其应用[J]. 控制理论与应用, 1997, 14(4): 613—615.
- [17] Li Bing, Jiang Weisun. Chaos optimization method and its application[J]. Control Theory and Applications, 1997, 14(4): 613—615.

SHORT-TERM WIND POWER FORECASTING BASED ON VARIATIONAL MODE DECOMPOSITION-PERMUTATION ENTROPY AND OPTIMIZED RELEVANCE VECTOR MACHINE

Wu Xiaomei, Lin Xiang, Xie Xuquan, Xie Haibo

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: According to the nonlinearity and non-stationarity of wind power series, a novel short-term wind power forecasting approach based on variational mode decomposition (VMD)-permutation entropy and relevance vector machine optimized by chaotic cuckoo search algorithm (CCS-RVM) is proposed in the paper. In order to reduce the influence of non-stationary effects of the wind power series and computational scale, firstly, the wind power series is decomposed into a series of different sub-modes by using variational mode decomposition (VMD). The permutation entropy (PE) value for each sub-mode is used to analyze its complexity. The sub-modes can be recombined to obtain a set of subsequences. Secondly, different prediction models based on relevance vector machine optimized by chaotic cuckoo search algorithm (CCS) are used to predict every subsequence 24 hours ahead. Finally, these forecasting results of subsequences are combined to obtain final forecasting result. Taking the actual collecting data of a certain wind farm as an example, the simulation results illustrate that the proposed prediction model can effectively improve the wind power forecasting accuracy.

Keywords: wind power; forecasting model; variational mode decomposition; permutation entropy; relevance vector machine; chaotic cuckoo search algorithm