

DOI: 10.7667/PSPC161805

基于 CEEMD 和膜计算优化支持向量机的风速预测

殷豪, 董朕, 陈云龙

(广东工业大学自动化学院, 广东 广州 510006)

摘要: 为提高预测的可靠性和准确性, 提出一个基于模态分解理论和膜计算优化算法的混合模型用于风速预测。与现有的风速预测方法相比, 该模型提高了预测精度。该模型包括3个主要步骤: 为了简化数据的复杂度, 通过互补集合经验模式分解(CEEMD)将原始风电功率时间序列分解成几个固有模态函数(IMFs); 对每个 IMF 分量单独建立膜计算优化算法优化支持向量机(MCO-SVR)的模型进行预测; 叠加全部 IMF 分量的预测值作为最终的预测结果。建立包括单一的支持向量回归机模型、不同分解方法以及相同的分解方法但使用不同的优化算法在内的9种基本模型, 来验证所提出的混合模型的优越性。实证研究表明, 所提出的混合模型在预测精度上显著优于其他的基本模型。

关键词: 互补经验模态分解; 膜计算优化算法; 支持向量回归机; 风速预测

Wind speed forecasting based on complementary ensemble empirical mode decomposition and support vector regression optimized by membrane computing optimization

YIN Hao, DONG Zhen, CHEN Yunlong

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

Abstract: To enhance prediction reliability and accuracy, a hybrid model based on the promising principle of mode decomposition and new algorithm called Membrane Computing Optimization (MCO) is introduced for wind speed forecasting. Compared with existing wind speed forecasting methods, this proposed model has improved the prediction accuracy. The proposed model involves three main steps: decomposing the original wind speed series into several Intrinsic Mode Functions (IMFs) via Complementary Ensemble Empirical Mode Decomposition (CEEMD) for simplifying the complex data, individually predicting each IMF with Support Vector Regression (SVR) optimized by MCO, and integrating all predicted IMFs for the ensemble result as the final prediction. Nine benchmark models, including single support vector regression models, different decomposition methods and models with the same decomposition method but optimized by different algorithms, are considered to verify the superiority of the proposed hybrid model. The empirical study indicates that the proposed hybrid model is remarkably superior to all considered benchmark models for its higher prediction accuracy.

Key words: complementary ensemble empirical mode decomposition; membrane computing optimization; support vector regression; wind speed forecasting

0 引言

为满足不断增长的全球电力需求, 可再生能源的使用有了明显的提升。风能作为一种新兴的可再生能源, 总装机容量近几年成倍增加。为满足电力需求, 风速和风力发电的预测方法对电力规划和主网调度有着重要意义。但是, 风速是一个复杂的

象参数, 因为它受像地球旋转、地球的地形特性、温度和气压等诸多因素的影响较大。风电功率的高度非线性主要是由风速的非线性和非平稳造成的。风电的不稳定性将成为风电系统与主电网结合的障碍之一。故提高风速/风电功率的预测精度对电网运行有着重要意义^[1]。

目前, 根据使用数据来源不同, 风速的主要预测方法包括两种, 即预测模型为物理^[2]和统计^[3-6](如时间序列法、人工神经网络(ANN)、模糊逻辑(FL)方法和支持向量机(SVM)等)的方法。物理方法需要

基金项目: 广东省科技计划项目(2016A010104016); 广东电网公司科技项目(GDKJQQ20152066)

大量的计算和详细的环境信息, 依赖于几个气象因素如温度、压力、障碍和表面粗糙度等, 这使得该方法非常复杂。时间序列法对历史数据进行分析, 建立一个能够描述风速时间序列特性的数学模型, 然后对风速进行预测, 目前该方法应用最为广泛, 其模型有自回归(AR)、移动平均(MA)和自回归移动平均(ARMA)等。FL^[7-8]方法预测能力较差, 难以准确预测风速和风电功率。与 AR 相比, ANN 在中长期风速预测中精度有明显提高, 但文献[9-10]中人工神经网络方法需要大量的时间进行模型训练, 可能陷入局部最优, 导致过拟合问题。SVM^[11-12]因其训练时间短、泛化能力强和精度高等优点而得到广泛应用, 但其同样具有局限性, 如: 内核的选择及核函数参数选择难的问题。

以上这些单一的预测方法已很难满足对风速预测精度的要求, 故“分解与集成”方法的提出, 在一定程度上可以弥补上述缺点。分解与集成的主要思想如下: 首先, 使用经验模式分解(EMD)、小波分解或傅里叶分解将原始时间序列分解成一些独立的分量; 其次, 对各分量分别建立预测方法进行预测; 第三, 叠加全部分量的预测结果得到实际预测值。一些实例研究证实, 分解集成模型可以有效捕捉到数据内部变化规律, 提高预测精度。例如文献[13]利用经验模态分解(EMD)分解和人工神经网络建立风速预测模型, 比单一预测模型表现出更高的预测精度。文献[14]用聚类经验模式分解(EEMD)将风速时间序列分解成若干固有模态函数(IMFs), 然后建立最小二乘支持向量回归(LSSVR)模型对各 IMF 进行预测, 叠加全部 IMF 的预测结果作为风速的最终预测值。但无论是 EMD 还是 EEMD 均存在缺陷, 无法达到最佳的分解效果。

本文提出一种基于互补集合经验模态分解(CEEMD)和支持向量回归机(SVR)的短期风速预测模型。首先, 采用 CEEMD 将原始序列分解为多个固有模态分量。然后, 对各个分量分别建立 SVR 模型进行预测。同时, 采用膜计算优化算法优化支持向量机(MCO-SVR)的参数以提高预测精度。最后, 叠加全部分量的预测值得到实际预测结果。实验结果表明: CEEMD 能很好地解决 EMD 的模态混叠问题, 消除 EEMD 受添加噪声信号造成的序列重构误差; 膜计算优化算法能汲取不同算法的优点, 获得更加优质的参数寻优能力; 所提模型能取得较高精度的短期风速预测结果。

1 互补经验模态分解原理

EMD 系列分解方法是处理非线性和非平稳

的数据而特别建立的, 与传统方法相比(即傅里叶分解和小波分解), EMD 系列分解方法表现出经验、直观和自适应的特点。一般来说, 传统的分解方法只会对满足某些特征的数据进行分解时才会表现良好。例如, 小波分解要求是非平稳而线性的数据, 而傅里叶分解主要应用于平滑周期性数据。考虑到风速的非平稳性和非线性的特点, 本文选用 CEEMD 的分解方法, CEEMD 由 Yeh 等人研发^[15], 旨在提高 EMD 和 EEMD 分解方法的性能。EMD 通过筛选过程将原始序列分解成多个 IMF 分量, 筛选过程需要多次迭代, 直到满足一定形式结束准则后停止。但是, EMD 在分解过程中会出现模态混叠问题。为解决这个问题, 文献[16]提出了 EEMD 分解方法, EEMD 通过向原始数据中添加白噪声, 在本质上解决了模态混叠问题。与 EMD 相比, 虽然 EEMD 的分解能力有很大的提高, 并显著增加算法的稳定性, 但它不能完全消除所添加的白噪声。CEEMD 则向原始序列中加入正负成对形式的白噪声, 这样既能保证拥有与 EEMD 一样的分解效果, 又可以减少由添加白噪声造成的序列重构误差。CEEMD 的分解原理可简述如下。

EMD 假定时间序列由不同的振荡模式共同组成, 这些复杂特征隐藏在时间序列数据中。这种伴随振荡函数或 IMFs 将被 EMD 从原始数据提取出来。因此, 原始数据序列 $x(t)$ 可以分解成几个固有模态分量和余量。

$$x(t) = \sum_{i=1}^m c_i(t) + r_m(t) \quad (1)$$

式中: m 是 IMF 总数; $c_i(t)$ 第 i 个 IMF 分量; $r_m(t)$ 是余量。IMFs 应该满足以下两个要求: 1) 极值的数目(包括最大值和最小值)和零交叉点的数量应相等, 或最多相差一个; 2) 最大值和最小值的包络线平均值应为零。重复这些步骤, 直到最后一个数据系列 $r(t)$ 不能再被分解则筛选过程结束。为克服由 EMD 产生的模态混合缺陷, EEMD 向原始时间序列中加入白噪声信号, 加入的白噪声必须符合以下的统计规律^[15]。

$$\varepsilon_m = \frac{\varepsilon}{\sqrt{N}} \quad (2)$$

式中: N 是添加白噪声的集合数; ε 是附加噪声的标准差; ε_m 是最终标准偏差, 通常定义为原时间序列和分解得到的 IMFs 分量的区别。CEEMD 则通过向时间序列中加入正负成对的白噪声来克服 EEMD 缺点, 获得互补的 IMFs。下面的 3 个步骤简要说明了该算法的主要原理。

1) 向原始时间序列中对加入正负成对的白噪声并生成两种由附加噪声和时间序列混合而成的序

列 M_1 和 M_2 。

$$\begin{cases} M_1 = X + NE \\ M_2 = X - NE \end{cases} \quad (3)$$

式中: NE 是添加白噪声; X 是时间序列; M_1 是时间序列和正噪声的总和; M_2 是时间序列和负噪声的总和。

2) 通过 EMD 将 M_1 和 M_2 分别分解为各自互补的含有正负白噪声的 IMF 成对分量。

3) 将每对含正负白噪声的分量整合在一起作为最终的 IMF 分量。在这种方法中, 添加的成对的正负白噪声被抵消掉^[17]。

2 支持向量回归机

SVM 是由 Vapnik 等人在 20 世纪 90 年代基于结构风险最小化原理(Structural Risk Minimization, SRM)所提出的, SRM 源于统计学习理论(SLT)^[18]。支持向量机的思想是将输入变量映射到一个具有非线性映射函数的高维特征空间中, 然后在特征空间中进行线性回归或分类。SVR 是 SVM 在回归问题中的应用, 其原理可简述如下。

给定一组训练样本为 $as(x_i, y_i) \in R^n \times R$, $i=1, \dots, l$, x_i 是输入向量, y_i 是 x_i 相应的输出, l 是样本数量。SVR 的特征函数通常被写为

$$f(x) = w * \varphi(x) + b \quad (4)$$

式中: $\varphi(\cdot): R^n \rightarrow R^n$ 是从原空间提取特征构成的核空间映射函数; w 是权重矩阵; b 是偏差。通过利用不敏感损失函数 ε , SVR 可以实现高维空间的线性回归。此外, 结构风险最小化原理被用来降低模型的复杂度, 它可被描述为

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \hat{\xi}_i) \\ \text{s.t. } (w * \varphi(x_i) + b) - y_i \leq \varepsilon + \xi_i \\ y_i - (w * \varphi(x_i) + b) \leq \varepsilon + \hat{\xi}_i \\ \xi_i, \hat{\xi}_i \geq 0, i=1, \dots, l \end{cases} \quad (5)$$

式中: ξ_i 、 $\hat{\xi}_i$ 是训练集的输入误差; $C (C > 0)$ 是控制训练误差成本的惩罚系数, 通常用来平衡经验误差项和规则项; ε 是用来表示允许训练损失的不敏感损失函数。

对于非线性回归的情况下, 可以通过一个核函数 $K(x_i, x)$ 将它们转换成线性回归的情况。可以得到非线性映射为

$$f(x) = \sum_i^l (\alpha_i - \hat{\alpha}_i) K(x_i, x) + b \quad (6)$$

对于这个方程的几个内积核函数得到了广泛的应用, 本文采用径向基(RBF)核函数, 它可以被描述为

$$K(x_i, x) = \exp\{-\|x - x_i\|/2\delta^2\} \quad (7)$$

因此, 使用 SVR 预测时需要选择的学习参数包括式(5)中的 C 和式(7)中 RBF 核函数的核参数 δ , 本文使用膜计算来实现这两个参数的优化选择。

3 膜计算优化算法

膜计算是从生物细胞以及由细胞组成的组织和器官的功能与结构中抽象出来的计算模型。本文在膜计算理论研究基础上, 提出一种膜计算优化算法(MCO)用于 SVR 的参数优化问题。膜计算优化算法包含 CSO 和 PSO 两种独立算法交叉寻优, 寻优过程包括占优解竞争保留和伪劣解淘汰机制。

3.1 纵横交叉算法

纵横交叉算法(CSO)算法包括横向交叉和纵向交叉两个算子, 每迭代一次将交替执行两种交叉算子, 纵横两种交叉机制保证了 CSO 具有较强的全局收敛能力。

3.1.1 横向交叉操作

执行交叉算子前先对种群中所有粒子进行两两不重复随机组合, 若父代粒子 $X(i)$ 和 $X(j)$ 的第 d 维进行横向交叉, 则粒子更新方式如式(8)、式(9)所示。

$$MS_{hc}(i, d) = r_1 \cdot X(i, d) + (1 - r_1) \cdot X(j, d) + c_1 \cdot (X(i, d) - X(j, d)) \quad (8)$$

$$MS_{hc}(j, d) = r_2 \cdot X(j, d) + (1 - r_2) \cdot X(i, d) + c_2 \cdot (X(j, d) - X(i, d)) \quad (9)$$

$$i, j \in N(1, M), \quad d \in N(1, D)$$

式中: r_1 、 r_2 为 $[0, 1]$ 的随机数; c_1 、 c_2 为 $[-1, 1]$ 的随机数; M 为粒子规模; D 为变量维数; $X(i, d)$ 、 $X(j, d)$ 表示父代粒子 $X(i)$ 和 $X(j)$ 的第 d 维; $MS_{hc}(i, d)$ 、 $MS_{hc}(j, d)$ 表示 $X(i, d)$ 和 $X(j, d)$ 在横向交叉后各自的第 d 维子代。

3.1.2 纵向交叉操作

粒子的每一维代表一个变量, 不同变量的取值范围会有差异, 故交叉前需对每一维进行归一化处理, 然后依交叉概率 P_v 对全部粒子不同维之间执行纵向交叉。为了使陷入局部最优的某一维从中跳出, 但同时又不破坏其他正常维, 故每次纵向交叉只需产生一个子代即可。若父代粒子 $X(i)$ 的第 d_1 维和第 d_2 维执行纵向交叉, 则粒子更新方式如式(10)所示。

$$MS_{vc}(i, d_1) = r \cdot X(i, d_1) + (1-r) \cdot X(i, d_2) \quad (10)$$

$$d_1, d_2 \in N(1, D), r \in [0, 1], i \in N(1, M)$$

式中, $MS_{vc}(i, d_1)$ 表示粒子 $X(i)$ 的第 d_1 维和第 d_2 维在纵向交叉后的子代。

3.2 粒子群算法

粒子群算法(PSO)以种群中粒子作为优化目标的一个解, 通过计算每个解的适应度值来选取全局最优粒子, 依据最优粒子的位置来确定其他粒子的飞行方向和距离, 依此来更新全部粒子的位置进行寻优。粒子更新迭代过程中产生个体最优极值和全局最优极值, 个体最优极值是个体寻优过程中的最优解, 全局最优极值则是全部粒子寻优过程中的最优解。其更新公式为

$$v_{id}^{k+1} = w \cdot v_{id}^k + c_1 \cdot r_1 \cdot (p_{id}^k - x_{id}^k) + c_2 \cdot r_2 \cdot (p_{gd}^k - x_{id}^k) \quad (11)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (12)$$

式中: r_1, r_2 为[0,1]之间均匀分布的随机数; c_1, c_2 为加速因子; w 为惯性权重; v 是粒子的飞行速度 ($v_{\min} < v_i < v_{\max}$); x 表示粒子; p_{gd} 和 p_{id} 分别表示全局最优极值和个体最优极值。

3.3 MCO 优化 SVR 参数步骤

MCO 结构图如图 1 所示, 参数优化步骤如下:

1) 初始化两种算法的参数, 种群大小 M , 最大迭代次数 $Maxgen$ 。

2) 开始膜计算, 将种群中全部粒子转换成 SVR 的学习参数 C 和 σ , 然后对样本数据进行训练, 用式(13)即适应度函数对每个粒子进行适应度评价, 两种算法轮流独立运行, 每种算法迭代 10 次后, 分别记录两种算法中当前表现最好的 3 个解和全局最优解(称为占优解)以及表现最差的 3 个解(称为伪劣解)。

3) 分别将两种算法中当前表现最好的 3 个解和全局最优解传输到中间细胞中, 对比这 8 个占优解, 选出 3 个表现更好的作为新的占优解。

4) 将两种算法中的伪劣解用新的 3 个占优解替换, 以此来淘汰伪劣解。

5) 是否满足结束条件, 是, 迭代终止并将适应度值最好的一组解转换为支持向量回归机对应的 C 和 σ ; 否, 转 2), 进入下一次膜计算。

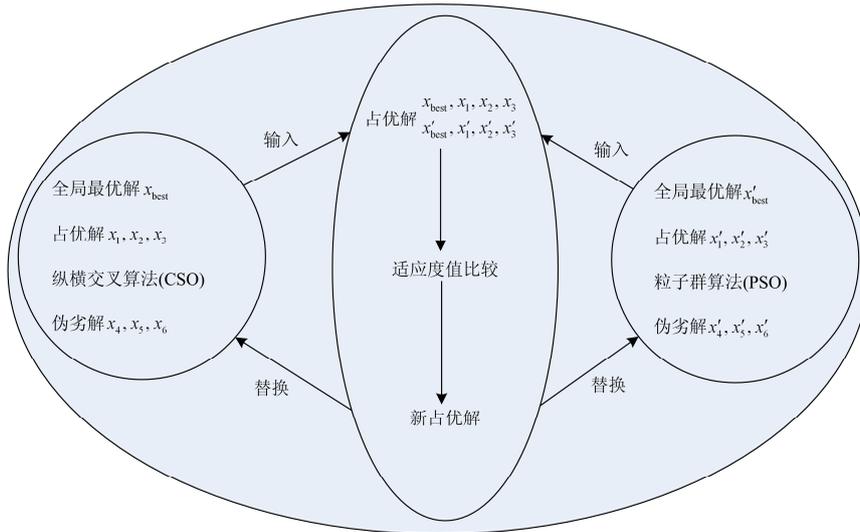


图 1 膜计算优化算法的结构图

Fig. 1 Structure of membrane computing optimization

PSO 算法具有前期收敛速度快和局部搜索能力强的优点, 但算法后期容易陷入局部最优; CSO 则表现出优良的全局收敛能力, 通过纵向交叉算子有效避免了局部最优, 但算法前期收敛速度较慢, 局部搜索能力差。膜计算能够很好地汲取两种算法的优点, 算法前期依靠 PSO 较快的收敛速度获得全局最优解, 后期则依靠 CSO 的纵向交叉算子有效避免局部最优, 使算法的寻优能力得到很大程度的加强。

4 基于 CEEMD-MCO-SVR 的风速预测模型

4.1 适应度函数的选取

选取均方误差公式作为粒子的适应度函数, 表达式为

$$fit = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (13)$$

式中: y_j 为实际值; \hat{y}_j 为预测输出值。

4.2 误差评价函数的选取

为了有效和全面地评价各预测模型的准确率, 预测误差评价函数采用平均绝对误差 (Mean Absolute Error, MAE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 和均方根误差 (Root of the Mean Squared Error, RMSE)。

$$E_{MA} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (14)$$

$$E_{MAP} = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (15)$$

$$E_{RMS} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (16)$$

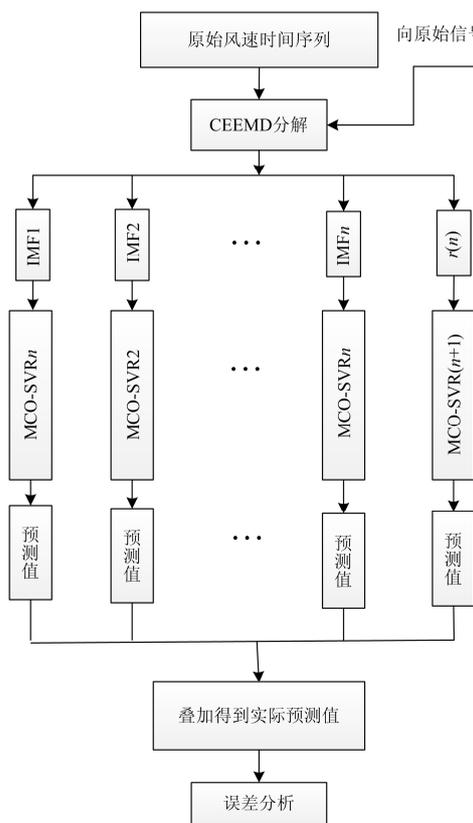


图 2 基于 CEEMD-MCO-SVR 的风速预测模型结构图

Fig. 2 Model structure of wind speed forecasting based on CEEMD-MCO-SVR

5 算例及结果分析

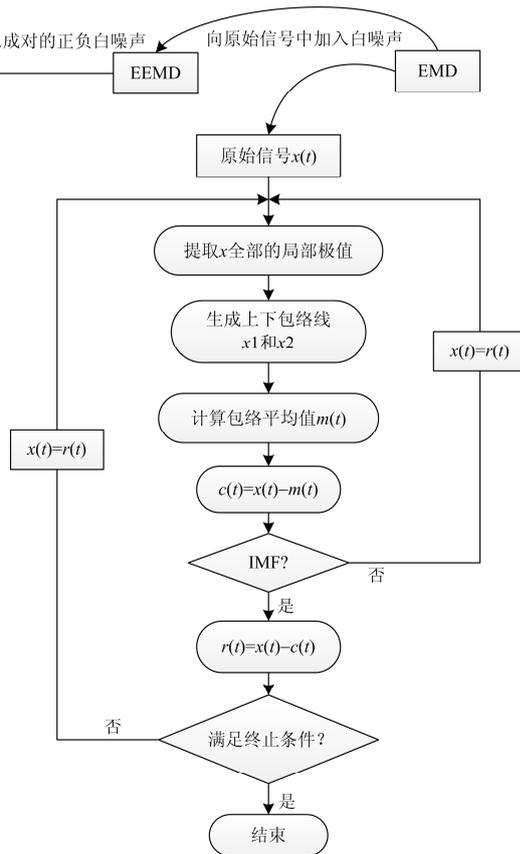
以荷兰某风电场的历史实测风速为例, 该风速数据为 1 h 一个采样点, 共 700 h 数据, 取其中前

式中: N 为测试样本数; y_t 为 t 时刻的实际风速值; \hat{y}_t 为 t 时刻的预测风速值。

4.3 建模过程

本文先是构建 CEEMD-SVR 模型, 通过 CEEMD 将原始风速时间序列进行分解, 然后通过支持向量回归机分别对各个分量进行预测。同时为提高预测 SVR 模型预测精度, 采用膜计算优化算法来优化 SVR 的学习参数。建模流程图如图 2 所示。具体步骤如下:

- 1) 使用互补集合经验模态分解降低风速序列的非平稳性, 得到分量 (IMF1-IMFn) 和余量 $r_N(t)$ 。
- 2) 对全部分量分别建立 MCO-SVR 模型进行预测。
- 3) 最后叠加全部子序列的预测值得到实际预测结果。
- 4) 结果误差分析。



600 h 数据样本作为训练集, 后 100 h 作为预测模型的验证数据。通过交叉验证的方式选取输入维数为 6 维, 进行 6 步预测仿真实验, 即选取连续 6 个采样点的数据作为训练样本, 后 6 个点的数据作为输

出来建立预测模型。为验证所提模型的有效性，共建立包括本文 CEEMD-MCO-SVR 模型以及 SVR、EMD-SVR、EEMD-SVR、CEEMD-SVR、CEEMD-GA-SVR、CEEMD-DE-SVR、CEEMD-QPSO-SVR、CEEMD-CSO-SVR 共 9 种模型进行对比实验。其中，GA 为遗传算法，DE 为差分进化算法，QPSO 为量子粒子群算法。

5.1 数据分解

本文所建立的 CEEMD-MCO-SVR 预测模型的第一步就是采用 CEEMD 将风速时间序列分解成多个从高频到低频分布的模态分量。其中，集合数 N 为 300，在每个集合成员中添加白噪声的标准偏差设置为 0.4。原始风速信号的 CEEMD 分解结果如图 3 所示。

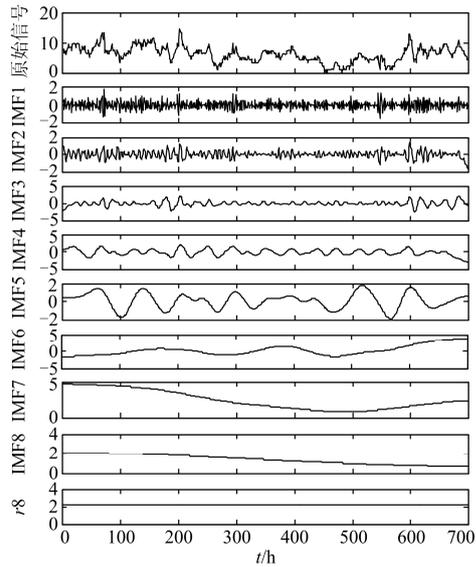


图 3 风速时间序列 CEEMD 分解结果

Fig. 3 Decomposition results of wind speed series by CEEMD

5.2 基于 CEEMD-MCO-SVR 的预测模型结果分析

对第 4 节 CEEMD 分解得到的 IMF s 和余量分别建立多种预测模型进行预测，SVR 的优化参数 $C \in [1,1000]$ ， $\sigma \in [0.1,10]$ 。4 种算法的种群大小设为 30，最大迭代次数设为 100 代。GA 中交叉概率设为 0.5，变异概率设为 0.1。DE 中缩放因子取 0.6，交叉因子取 0.2。QPSO 中收缩-扩张系数： $\beta_1 = 1$ ， $\beta_2 = 0.5$ 。MCO 中两种算法参数设置如下：PSO 采用动态惯性权重， w 可表示为 $w = w_{\max} - (w_{\max} - w_{\min}) \cdot i / Maxgen$ ， $w_{\max} = 0.9$ ， $w_{\min} = 0.4$ ，加速因子 $c_1 = 2$ ， $c_2 = 2$ ；CSO 中纵向交叉概率 P_v 设为 0.8。全部模型的误差分析如表 1 所示。不同分解方法的预测结果如图 4 所示。不同算法的预测结果如图 5 所示。

表 1 预测结果分析

Table 1 Analysis of the forecasting results

模型	$E_{MA}/(m/s)$	$E_{MAP}/\%$	$E_{RMS}/(m/s)$	t_{\max}/s
SVR	1.2471	17.89	1.5539	0.116
EMD-SVR	0.9512	13.84	1.2734	0.548
EEMD-SVR	0.7551	11.54	1.1241	1.102
CEEMD-SVR	0.6945	10.45	1.0236	1.615
CEEMD-GA-SVR	0.6519	8.91	0.9976	378.8
CEEMD-DE-SVR	0.6025	8.26	0.9530	156.46
CEEMD-QPSO-SVR	0.5402	7.57	0.8801	102.36
CEEMD-CSO-SVR	0.5093	6.97	0.7932	183.65
CEEMD-MCO-SVR	0.4547	6.64	0.6144	136.27

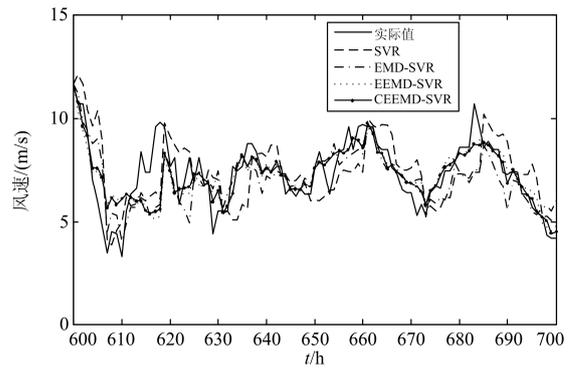


图 4 不同分解方法的风速预测曲线

Fig. 4 Wind speed prediction curves of different decomposition methods

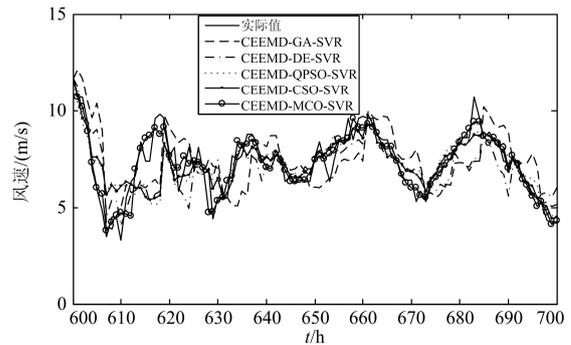


图 5 不同算法模型的风速预测曲线

Fig. 5 Wind speed prediction curves of different algorithm models

由表 1 可以看出：组合模型与单一的 SVR 模型相比，预测精度均有一定程度的提高，这主要是因为分解后的各 IMF 分量反映了原始风速信号的内在变化规律，风速信号的非平稳性有效降低。EEMD-SVR 模型与 EMD-SVR 模型相比，前者的各项误差指标分别减小了 0.1961 m/s、2.3%、0.1493 m/s，说明 EEMD 有效解决了 EMD 的模态混叠问题，

分解得到更有规律性的模态分量。CEEMD-SVR 模型与 EEMD-SVR 模型相比,前者的误差指标分别减小了 0.0606 m/s、1.09%和 0.1 m/s,说明 CEEMD 分解有效消除了 EEMD 分解过程中添加的白噪声对预测结果的影响,提高了预测精度。从模型预测时间对比可知, MCO 的耗时虽然较 QPSO 增加了 33.91 s,但相对于其他几种算法耗时明显减少。对比不同算法预测模型的误差指标可以看出,使用算法优化 SVR 的参数有效提高了模型的预测精度,其中,本文所提膜计算优化算法的各项误差指标在所有算法中均表现最好, E_{MAP} 较 GA、DE、QPSO、CSO 分别降低了 1.94%、1.29%、0.6%、0.33%,说明膜计算有效汲取了 PSO 的局部搜索能力和 CSO 的全局搜索能力,优化选取的参数更加优良,有效提高了 SVR 模型的泛化能力和预测精度。

由图 4 可以看出:分解后的预测模型与单一的预测模型相比,预测结果能准确捕捉风速信号的变化规律,预测曲线更接近于真实值。由图 5 可知:CEEMD-MCO-SVR 模型在所有模型中表现最好,尤其是在风速突变的拐点,表现出更高的预测精度,如在时间点 610 h 附近的预测值与实际值的拟合度较其他模型更高,充分说明 MCO 优化 SVR 得到的学习参数更加优良,提高了模型的预测精度和泛化能力。

6 结论

1) 针对单一风速预测模型预测精度低以及集合经验模态分解的不足,提出采用互补集合经验模态分解来降低风速信号的非线性和非平稳性。实验结果表明,互补集合经验模态分解有效消除了集合经验模态分解添加的白噪声对分解结果的影响,提高了预测精度。

2) 针对支持向量机参数选择难和常规智能算法容易陷入局部最优的问题,提出一种新颖的膜计算优化算法来优化支持向量回归机的学习参数。算例结果表明,与常规智能算法相比,膜计算优化算法能有效汲取 PSO 的局部搜索能力和 CSO 的全局搜索能力,具有较快的收敛速度,优化得到的学习参数更加优良,进一步提高了预测精度。

参考文献

[1] 袁铁江,晁勤,李义岩,等. 大规模风电并网电力系统经济调度中风电场出力的短期预测模型[J]. 中国电机工程学报, 2010, 30(13): 23-27.
YUAN Tiejang, CHAO Qin, LI Yiyang, et al. Short-term wind power output forecasting model for economic

dispatch of power system incorporating large-scale wind farm[J]. Proceedings of the CSEE, 2010, 30(13): 23-27.

[2] 李莉,刘永前,杨勇平,等. 基于 CFD 流场预计算的短期风速预测方法[J]. 中国电机工程学报, 2013, 33(7): 27-32.
LI Li, LIU Yongqian, YANG Yongping, et al. Short-term wind speed forecasting based on CFD pre-calculated flow fields[J]. Proceedings of the CSEE, 2013, 33(7): 27-32.

[3] TORRES J L, GARCÍA A, BLAS M D, et al. Forecast of hourly average wind speed with ARMA models in Navarre (Spain)[J]. Solar Energy, 2005, 79(1): 65-77.

[4] 姜言,黄国庆,彭新艳,等. 基于 GARCH 的短时风速预测方法[J]. 西南交通大学学报, 2016, 51(4): 663-669.
JIANG Yan, HUANG Guoqing, PENG Xinyan, et al. Method of short-term windspeed forecasting based on generalized autoregressive conditional heteroscedasticity model[J]. Journal of Southwest Jiaotong University, 2016, 51(4): 663-669.

[5] 张文,胡从川,阙波,等. 一种实时校正的改进 BP 神经网络超短期风速预测模型[J]. 电网与清洁能源, 2016, 32(9): 118-122.
ZHANG Wen, HU Congchuan, QUE Bo, et al. An ultra-short-term wind speed prediction model based on improved BP neural network with real-time correction[J]. Power System and Clean Energy, 2016, 32(9): 118-122.

[6] 袁翀,戚佳金,王文霞,等. 采用正则化极限学习机的短期风速预测[J]. 电网与清洁能源, 2016, 32(11): 62-68.
YUAN Chong, QI Jiajin, WANG Wenxia, et al. Short-term wind speed forecasting using regularization extreme learning machine[J]. Power System and Clean Energy, 2016, 32(11): 62-68.

[7] LIU Hui, TIAN Hongqi, LI Yanfei. Comparison of new hybrid FEEMD-MLP, FEEMD-ANFIS, wavelet packet-MLP and wavelet packet-ANFIS for wind speed predictions[J]. Energy Conversion and Management, 2015, 89: 1-11.

[8] JUNG JAESUNG, BROADWATER R P. Current status and future advances for wind speed and power forecasting[J]. Renewable and Sustainable Energy Reviews, 2014, 31: 762-777.

[9] 吴忠强,贾文静,吴昌韩,等. 基于 PSO-BSNN 的短期风速预测[J]. 电力系统保护与控制, 2015, 43(15): 36-41.
WU Zhongqiang, JIA Wenjing, WU Changhan, et al. Short-term wind speed forecasting based on PSO-BSNN[J]. Power System Protection and Control, 2015, 43(15): 36-41.

- [10] 范高峰, 王伟胜, 刘纯, 等. 基于人工神经网络的风电功率预测[J]. 中国电机工程学报, 2008, 28(34): 118-123.
FAN Gaofeng, WANG Weisheng, LIU Chun, et al. Wind power prediction based on artificial neural network[J]. Proceedings of the CSEE, 2008, 28(34): 118-123.
- [11] 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.
- [12] 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.
- [13] LIU H, CHEN C, TIAN H Q, et al. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks[J]. Renewable Energy, 2012, 48: 545-556.
- [14] 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.
- [15] YEH J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method[J]. Adv Adapt Data Anal, 2010, 2: 135-156.
- [16] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Adv Adapt Data Anal, 2008, 1: 1-41.
- [17] TANG L, DAI W, YU L, et al. A novel CEEMD-based EELM ensemble learning paradigm for crude oil price forecasting[J]. Int J Info Tech Dec Mak, 2015, 14: 141-169.
- [18] ZHANG X L, WANG P, LIANG D K, et al. A soft self-repairing for FBG sensor network in SHM system based on PSO-SVR model reconstruction[J]. Opt Commun, 2015, 343: 38-46.

收稿日期: 2016-10-29; 修回日期: 2017-02-14

作者简介:

殷豪(1972—), 女, 硕士, 副教授, 研究方向为电力系统稳定与控制; E-mail: 3403446@qq.com

董朕(1990—), 男, 通信作者, 硕士研究生, 研究方向为人工智能算法在电力系统中的应用; E-mail: 735824318@qq.com

陈云龙(1991—), 男, 硕士研究生, 研究方向为电力系统经济调度与负荷预测。E-mail: 2546377373@qq.com

(编辑 葛艳娜)