

基于 EMD 和 ABC-SVM 的光伏并网系统输出功率预测研究

高相铭¹, 杨世凤², 潘三博¹

(1. 安阳师范学院物理与电气工程学院, 河南 安阳 455000; 2. 天津科技大学电子信息与自动化学院, 天津 300222)

摘要: 针对光伏发电系统的输出功率具有非平稳性和随机性的特点, 提出一种基于经验模态分解(EMD)和人工蜂群算法(ABC)优化支持向量机(SVM)的光伏并网系统输出功率预测模型。首先根据预测日的天气预报数据, 构建相似日的 15 min 输出功率时间序列。然后, 将输出功率时间序列进行经验模态分解, 得到不同尺度下的固有模态分量 IMF_n 和趋势分量 Res , 针对每个 IMF 分量和趋势分量分别建立相应的支持向量机预测模型, 并对 SVM 模型参数进行人工蜂群算法寻优预处理。最后, 将每个模型预测的结果进行合成重构, 得到光伏并网系统输出功率的预测值。通过实际数据测试表明: 基于 EMD 和 ABC-SVM 的功率预测模型同单一 SVM 预测模型及未经优化的 EMD-SVM 预测模型相比, 具有更快的运算速度和更高的预测精度。

关键词: 光伏并网系统; 输出功率预测; 模型参数优化; 经验模态分解; 人工蜂群算法

A forecasting model for output power of grid-connected photovoltaic generation system based on EMD and ABC-SVM

GAO Xiangming¹, YANG Shifeng², PAN Sanbo¹

(1. School of Physics and Electrical Engineering, Anyang Normal University, Anyang 455000, China;

2. College of Electronic Information and Automation, Tianjin University of Science & Technology, Tianjin 300222, China)

Abstract: According to the output power of PV generation system having the characteristics of non-stationary and randomness, a forecasting model for grid-connected photovoltaic generation system output power is proposed based on EMD and SVM optimized by ABC algorithm. Firstly, the time series data of output power in the similar day with the interval of 15 minutes is built on the basis of weather forecast data of the forecast day. Then, the time series data of output power is decomposed into a series of components including some intrinsic mode components and a trend component under different scales by using EMD, and different SVM forecasting models are built for each intrinsic mode components and trend component, and the parameters of SVM model are optimized by ABC algorithm. Finally, the entire forecasting results are combined into the ultimate forecasting result of grid-connected photovoltaic generation system output power. The forecasting model is tested with the field data and the results show that the model based on EMD-ABC-SVM has higher accuracy and faster speed compared to single SVM model and EMD-SVM without optimization.

This work is supported by National Natural Science Foundation of China (No. U1204515).

Key words: grid-connected photovoltaic generation system; output power forecasting; parameter optimization of model; empirical mode decomposition; artificial bee colony algorithm

中图分类号: TM615

文章编号: 1674-3415(2015)21-0086-07

0 引言

随着并网光伏系统规模的日渐增加, 光伏系统具有的间歇性和不确定性等特征对公共电网所产生的不利影响逐渐显现^[1-2]。如果能够准确预测光伏系统的发电功率变化情况, 就能够实现电网的合理调

度和电力负荷的平衡配置, 从而保障公共电网系统的安全性和稳定性。目前, 对于光伏系统输出功率的预测大致有两种方法: 间接预测方法和直接预测方法。间接方法的关键是对光伏安装地的太阳辐照强度进行预测, 得到某一时刻的太阳辐照强度预测值后将其代入相应的出力模型即可得到光伏系统的输出功率预测值^[3-4]。直接预测方法则无需太阳辐照度的数据, 只需要采用光伏系统的历史数据和公众

基金项目: 国家自然科学基金项目(U1204515)

天气信息即可预测未来一小段时间内的光伏发电系统功率输出情况^[5-8]。有研究表明, 气象因素对光伏并网系统输出功率的影响是非常明显的, 如果两个时间段的气象条件相似, 其功率输出曲线就会有很大的相似度^[9-16]。因此, 可以通过选取相似日进行光伏并网系统输出功率预测^[12]。

以上各种光伏功率预测方法都有其各自特点, 但在应用时也都存在一定的局限性。目前, 采用单一预测方法所得到的光伏功率预测误差较大, 一般为 15%~30%, 原因在于光伏系统的输出功率受气象因素影响较大, 存在间歇性和不确定性, 另外预测方法本身的局限性也是造成误差较大的关键因素。多项研究表明, 在光伏系统发电功率预测中, 单一预测方法的精度已经无法满足预测精度的要求。而组合预测方法则能够取长补短, 综合多种预测方法的优点, 提高光伏系统发电功率的预测精度。

经验模态分解(EMD)已经在非线性随机时间序列的组合预测中得到了较多的成功应用, 这一类预测方法先将时间序列分解为多个不同频率的序列, 对不同的序列分别建立预测模型, 以减少不同特征信息间的相互影响, 最后将预测结果重构便可获得原始序列的预测值。本文将组合预测模型的思路引入光伏功率预测研究中, 综合运用不同算法的优点, 建立了基于 EMD 和 ABC-SVM 的光伏并网系统输出功率组合预测模型。该模型有效克服了采用单一模型时存在的泛化性能差、预测精度低、预测结果不稳定等缺陷, 并成功将人工蜂群优化算法和 EMD 方法成功应用于光伏并网系统输出功率的预测。

1 光伏系统输出功率相似日聚类选择方法

在进行光伏并网系统输出功率预测时, 通过从实际的历史数据中找出比较合理的相似日, 能够大大提高光伏系统输出功率的预测精度。

为了找出和预测日的天气类型、季节类型一致, 且气温和湿度也很相似的日期, 我们首先对天气类型和季节类型进行分类。将天气类型分为晴、晴转多云(多云转晴)、多云、阴、雨(雪)五种, 分别用 1、2、3、4、5 表示。将季节类型分为春夏秋冬四种类型: 3 月、4 月、5 月为春季, 6 月、7 月、8 月为夏季, 9 月、10 月、11 月为秋季, 12 月、1 月、2 月为冬季。然后根据预测日的季节类型将其同历史数据结合, 利用模糊 C-均值算法对其进行模糊聚类, 最终找到和预测日为同一类的相似日。大致步骤如下。

(1) 确定聚类指标。天气类型 w , 每日的最高温度 T^h 和最低温度 T^l , 每日的最大湿度 H^h 和最小湿度 H^l , 为了增加聚类样本的全面性, 我们取前两年

同季节的历史日期气象数据作为聚类样本集, 假设为 N 天; 样本集可以写为 $D=\{d_j|j=1, 2, \dots, N\}$, 其中 $d_j = \{w_j, T_j^h, T_j^l, H_j^h, H_j^l\}$; 同时确定聚类数 C 、模糊加权参数 m 、阈值 ε 和初始迭代步数 L 。

(2) 根据确定的参数 C , 随机选择 C 个向量作为聚类中心, 即 $v^0 = \{v_i | i=1, 2, \dots, C\}$ 。

(3) 计算隶属度矩阵 $U^L = [\mu_{ij}]_{C \times n}$, μ_{ij} 表示向量 d_j 对类 v_i 的隶属度, μ_{ij} 满足式(1)。

$$\mu_{ij} = \begin{cases} \sum_{k=1}^C \left(\frac{r_{ij}}{r_{kj}} \right)^{\frac{2}{m-1}}, & \text{if } r_{ij} \neq 1 \\ 1, & \text{if } r_{ij} = 1 \end{cases} \quad (1)$$

其中: $1 \leq i \leq C$, $1 \leq j \leq n$; r_{ij} 表示 d_j 与聚类中心 v_i 的相似度; 其中 s 为向量的维数。

(4) 根据式(2)计算聚类中心 V^{L+1} 。

$$v_i = \frac{\sum_{j=1}^n (\mu_{ij})^m x_j}{\sum_{j=1}^n (\mu_{ij})^m}, 1 \leq i \leq C \quad (2)$$

(5) 判断是否满足终止条件, 如果 $\|V_{L+1} - V_L\| \leq \varepsilon$, 则算法终止, 得到划分矩阵 U 和聚类中心 v 。否则, 转向步骤(4)继续运算, 直到满足终止条件。

聚类完成后, 根据划分矩阵 U 可以得到处于同一类别中的预测日以及与其相似的历史日期。

2 基于 EMD 和 ABC-SVM 的光伏并网系统输出功率预测模型

2.1 光伏并网系统输出功率信号的 EMD 分解

经验模态分解的实质是基于局部特征尺度对一个非线性、非平稳信号进行平稳化处理, 将不同尺度的波动或趋势从原来的复杂信号中逐级分解出来, 形成一系列具有不同特征尺度的固有模态函数(Intrinsic Mode Function, IMF)和一个趋势量^[13-15]。相比小波变换, 经验模态分解不但具有多分辨特性, 还克服了小波变换中存在的分解尺度确定和小波基选取的困难。

对光伏输出功率时间序列 $x(t)$ 实施经验模态分解的步骤如下。

(1) 找出由多个相似日光伏输出功率组成的信号序列中的所有极大值点, 用三次样条函数插值拟合出序列的上包络线 $e_u(t)$; 找出输出功率时间序列的所有极小值点, 同样用三次样条函数插值拟合出序列的下包络线 $e_l(t)$ 。

(2) 计算出上下包络线的平均值, 作为平均包络

线 $e_v(t)$ ；用原始输出功率时间序列 $x(t)$ 减去平均包络线 $e_v(t)$ ，得到一个新的数据序列 $h_1(t)$ 。 $h_1(t)$ 一般来讲仍是一个不平稳的时间序列，应按照上述过程对其重复处理。假设经过 k 次处理后， $h_{1k}(t)$ 满足了 IMF 的条件，则得到了第一个 IMF 分量 $imf_1(t)$ ，且 $imf_1(t) = h_{1k}(t)$ ，它包含了原始的输出功率时间序列中变化周期最短的分量。

(3) 将原始输出功率时间序列 $x(t)$ 减去第一个 IMF 分量 $imf_1(t)$ ，得到一个去掉高频成分的输出功率时间序列 $r_1(t)$ 。对 $r_1(t)$ 继续进行上述平稳化处理，可以得到其余的所有 IMF 分量及一个趋势量 Res 如式(3)。

$$\begin{cases} r_2(t) = r_1(t) - imf_2(t) \\ r_3(t) = r_2(t) - imf_3(t) \\ \vdots \\ Res(t) = r_{M-1}(t) - imf_M(t) \end{cases} \quad (3)$$

最后可以得到光伏输出功率时间序列 $x(t)$ 分解后的形式为

$$x(t) = \sum_{i=1}^M imf_i(t) + Res(t) \quad (4)$$

式中： $imf_i(t)$ 表示光伏输出功率时间序列 $x(t)$ 的固有模态函数分量； $Res(t)$ 表示原始信号序列的平均趋势量。即原始光伏输出功率时间序列可以分解为一系列的固有模态函数分量和一个平均趋势量之和。

以河南某高校新能源光伏并网发电工程技术中心的 10 kW 光伏并网系统实际输出功率为例，对 20 个相似日内间隔为 15 min 的输出功率时间序列进行 EMD 分解，结果如图 1 所示，输出功率时间序列被分解为 7 个 IMF 分量和一个趋势量。

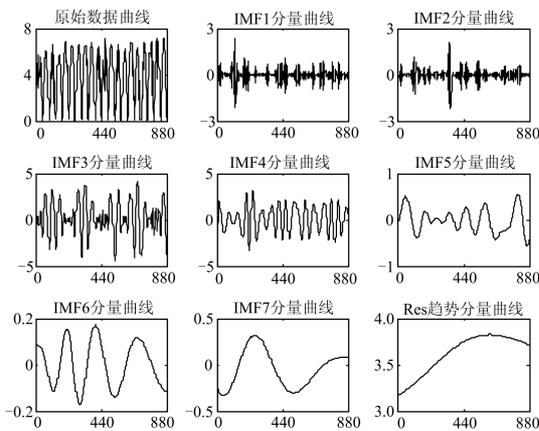


图 1 10 kW 光伏系统输出功率的 15 min 时间序列 EMD 分解图

Fig. 1 Decomposition graph of 15 min series data of 10 kW PV generation system output power by EMD

2.2 基于 EMD 和 ABC-SVM 的光伏功率预测模型构建

光伏并网系统输出的非线性和非平稳性较强的功率序列信号经过 EMD 分解后，得到若干个彼此间影响甚微的基本模态分量，从而简化了信号序列中特征信息的干涉或耦合，降低了信号的非平稳性。在此基础上，本文拟构建一种人工蜂群算法优化支持向量机(SVM)的光伏并网系统输出功率预测模型。

2.2.1 人工蜂群优化算法

人工蜂群(Artificial Bee Colony, ABC)算法是一种模拟蜂群采蜜过程的群体智能优化算法^[16]。算法中的人工蜂群被分为采蜜蜂、观察蜂和侦查蜂 3 种不同的工种，三种蜜蜂根据各自的分工协同完成采蜜过程各阶段任务，并通过对蜜源的收集与共享从而找到最佳蜜源的位置。在人工蜂群算法中，最佳蜜源位置对应于问题的最优解，蜜源内包含的花蜜量对应于问题的解的适应度值。

初始化完成后，采蜜蜂对相应的已知蜜源(问题的原始解)的邻域进行搜索并找到一个新蜜源(问题的新解)，新蜜源的位置(被优化问题的参数值)按公式(5)确定。

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (5)$$

式中： ϕ_{ij} 为 $[-1, 1]$ 之间的随机数，它控制了 x_{ij} 邻域的生成范围； $k \in \{1, 2, \dots, SN\}$ 、 $j \in \{1, 2, \dots, D\}$ 是随机选择的下标，且 k 不等于 i 。

SN 个采蜜蜂完成搜索任务后全部返回蜂巢，将搜索到的蜜源信息与观察蜂共享；观察蜂根据各个蜜源的花蜜数量(解的适应度函数值)并按照公式(6)选择蜜源。从公式可以看出，花蜜数量越多的蜜源越容易被选中。

$$p_i = \frac{fit_i}{\sum_{n=1}^N fit_n} \quad (6)$$

式中，参数 fit_i 代表第 i 个蜜源的适应度值。

随后，观察蜂将对选中的蜜源邻域进行搜索并按照公式(5)确定一个新蜜源的位置，并采用类似于采蜜蜂的新蜜源取舍方式，判断是否用新蜜源取代旧蜜源。如果蜜源 x_i 被更新 $limit$ 次后仍无法得到改进，该蜜源将被舍弃，同时其对应的采蜜蜂也将变为侦查蜂，侦查蜂将按式(7)重新确定一个新蜜源：

$$x_i = x_{\min} + rand(0, 1)(x_{\max} - x_{\min}) \quad (7)$$

ABC 算法所特有的劳动分工和协作机制使蜜蜂按照不同的搜索策略相互协作、共同完成寻优工作，具有较强的全局寻优能力。该算法在相关研究

中已经表现出优于遗传算法、蚁群算法和粒子群算法的性能^[17-18]。

2.2.2 ABC 算法优化选择 SVM 模型参数

支持向量机(SVM)是一种基于结构风险最小化原则、以统计学习理论为基础的机器学习方法,已经在非线性回归预测、数据挖掘等领域得到了成功应用。SVR 中的惩罚系数 C 、不敏感度系数 ε 以及核函数参数 σ^2 决定着算法的精度和泛化性能,但是目前对于这三个参数的选取仍然缺乏有效的解决方案。针对此问题,本文采用了人工蜂群算法优化选择 SVM 参数的方法。该方法的程序流程如图 2 所示。

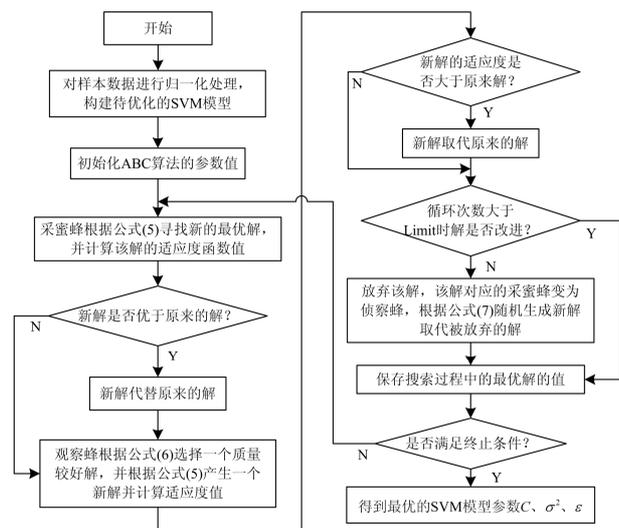


图 2 ABC 算法优化 SVM 参数的程序流程图

Fig. 2 Program flow chart of SVM parameter optimization using ABC algorithm

通过多次的实际测试发现:用于光伏系统输出功率预测时,ABC 算法的参数做如下初始化设置,可以使 EMD-SVM 预测模型达到理想的预测精度和泛化能力。蜂群规模 $N=160$;采蜜蜂的个数和观察蜂的个数相等,都为 80;初始蜜源(被优化问题的初始解)的个数也为 80;一个蜜源最多更新次数为 90 次;算法的最大循环次数为 150。

2.2.3 光伏并网系统功率预测模型构建过程

首先根据预测日的天气预报数据,构建相似日的 15 min 输出功率时间序列;然后将输出功率时间序列进行经验模态分解,得到不同尺度下的固有模态分量 IMF_n 和趋势分量 Res ,针对每个 IMF 分量和趋势分量分别建立相应的支持向量机预测模型,模型的输入为预测日的天气类型 w 、最高温度 T^h 、最低温度 T^l 、最大湿度 H^h 、最小湿度 H^l 和预测日

最近一周的相似日的相应 IMF 分量或者趋势分量 Res 对应值,模型的输出为功率预测值。为提高 SVM 模型的预测精度,对 SVM 参数进行人工蜂群算法寻优预处理;最后,将每个模型预测的结果进行合成重构,得到光伏并网系统输出功率的预测值。其流程图如图 3 所示。

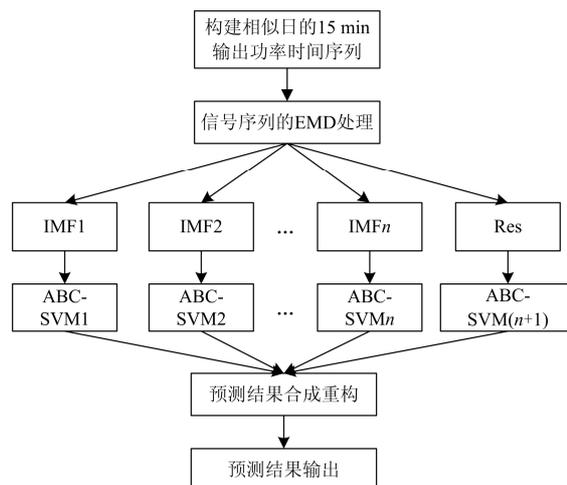


图 3 EMD-ABC-SVM 光伏功率预测模型构建

Fig. 3 PV system output power forecasting model construction based on EMD-ABC-SVM

3 预测实例与结果分析

3.1 数据预处理

为了验证基于 EMD 和 ABC-SVM 的光伏系统输出功率预测模型的性能,本文采用 Matlab 软件完成模型的构建,并以河南某高校工程技术中心实际运行的 10 kW 光伏并网系统为测试平台对预测模型进行了测试和分析。测试中所用的训练数据和验证数据均采用光伏并网系统输出功率的实测值与当地气象数据记录。测试中主要选择了季节类型为夏季的 2014 年 6、7、8 三个月的实际功率数据作为研究对象,将数据按照天气类型分为 5 类:晴天、晴转多云、多云、阴天、雨(雪),数据为每 15 min 记录一次。在本实例中以一天为一个时段,根据安阳本地的日照特性,夏季的光伏系统实际有电量输出的时间每天约为 11 h 左右,本文选择每个时段为 11 h,每隔 15 min 采样一次发电功率数据,每个时段的气象参数为该时段的气温和天气类型,得到模型的输入变量为 $X = (x_1, x_2, \dots, x_n)$,其中 n 为 52, $x_1 \sim x_{44}$ 代表了距预测日最近的那个相似日的每 15 min 采样一次的 44 个数据; $x_{45} \sim x_{48}$ 代表相似日的最高气温、最低气温、最大湿度、最小湿度; $x_{49} \sim x_{52}$ 代表预测日的最高气温、最低气温、最大湿度、最小湿

度。模型的输出变量为预测日内的 44 个输出功率值。

根据前面所述的方法对 7、8、9 月份的天气类型进行相似日聚类分析，将其分为 5 种典型天气类型。取天气类型为晴天的 20 个相似日的数据作为训练数据集，以 8 月 28 日和 8 月 29 日两天的数据作为测试集。按照上一小节的 EMD-ABC-SVM 功率预测模型构建方法进行操作：首先对 20 个相似日的输出功率序列进行 EMD 分解，得到 7 个 IMF 分量和 1 个 Res 分量，如图 1 所示；针对每个分量分别构建一个 SVM 功率预测模型，并采用人工蜂群算法进行每个 SVM 模型的参数寻优处理，步骤如图 2 所示；参数优化后的 SVM 模型即可采用测试集进行性能测试。

3.2 预测结果与分析

采用 EMD-ABC-SVM、EMD-SVM 和单一 SVM 三种预测模型分别对 8 月 28 日、29 日两天的光伏并网系统输出功率进行预测，预测结果图 4 和图 5 所示。三种模型中，EMD-ABC-SVM 为针对原始信号经 EMD 分解后得到的多个 IMF 分量和一个 Res 分量所建立的多个经 ABC 算法优化的 SVM 预测模型；为了验证 ABC 算法的有效性，我们同时建立了 SVM 的参数没有经过优化选择的 EMD-SVM；而单一 SVM 模型则是直接对原始序列进行预测。

由图 4 和图 5 可以看出：三种预测模型中 EMD-ABC-SVM 预测精度最高，说明经过 EMD 分解后的 IMF 分量减少了非平稳性和随机性对 SVM 模型的影响，ABC 算法的参数寻优使 SVM 模型具有最佳的性能；一天内，早晨 7:00~9:00、下午 16:00~18:00 这两个时间段内的预测误差都比较大，但是早晨和晚上的实际发电量在一天内的总发电量中占有的比例较小，因此，并不影响预测模型的实际应用效果。

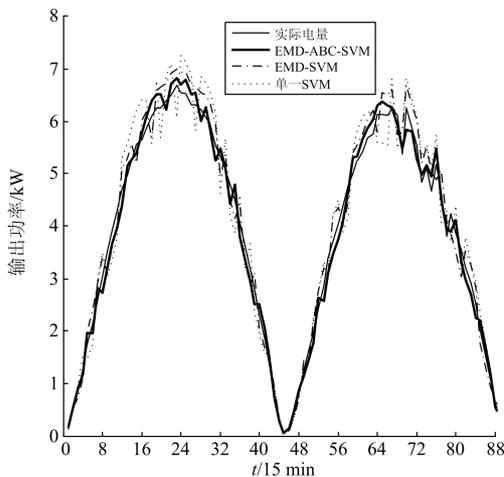


图 4 不同预测模型的预测结果曲线

Fig. 4 Predicted results curves of different models

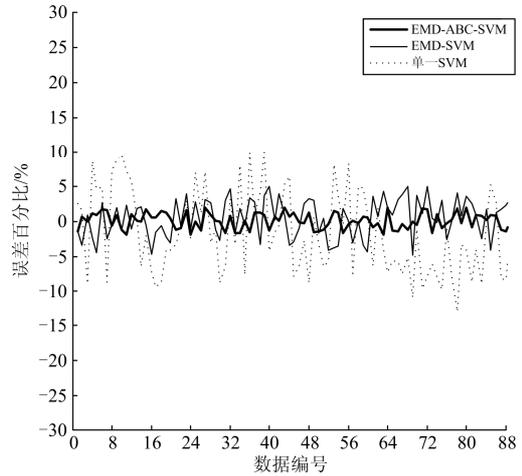


图 5 不同预测模型的预测误差曲线

Fig. 5 Error curves of different models

为了全面验证模型的性能，又分别对不同的天气类型下的光伏并网系统输出功率情况进行了预测，包括晴天、晴转多云、多云、阴天等四种典型的天气类型。模型的性能分别采用平均相对误差 *MAPE* 和均方根误差 *RMSE* 进行比较和判断。不同预测模型的预测 *MAPE* 和 *RMSE* 误差比较结果如表 1 所示。

从表 1 中所列数据可以看出：不同的天气类型对各种预测模型都有不同程度的影响。晴天情况下，三种模型都有不俗的表现，其中 EMD-ABC-SVM 预测效果最好，*MAPE* 和 *RMSE* 的误差只有 6.35% 和 7.59%，即使是未采用 EMD 分解的单一 SVM 模型，其预测误差也在 15% 以下。而在多云和晴转多云的情况下，预测效果不很理想，EMD-ABC-SVM 模型的 *RMSE* 误差最大达到了 14.16，而未采用 EMD 分解的单一 SVM 模型最大误差达到了 21.27%，这主要是由于多云和晴转多云的天气状态变化频繁、随机性增加而造成的结果。不同预测模型，在相同的天气类型下表现也各不相同。EMD-ABC-SVM 模型在各种天气类型下的预测误差都是最小的，其根本原因在于原始的输出功率序列在 EMD 分解后分别建立不同的 ABC-SVM 模型，从而减少了功率信号的随机干扰，降低了功率信号中不同特征信息间的相互影响，加之 SVM 模型的参数经过 ABC 算法的优化选择，达到了最佳的工作状态。因此，即使在随机性较强的多云和晴转多云的天气条件下，其性能也比未优化参数的 EMD-SVM 和未经 EMD 分解处理的单一 SVM 要更胜一筹。

就运算时间而言，EMD-ABC-SVM 占有明显的

优势, 原因在于该模型事先采用了人工蜂群算法进行支持向量机参数的优化选择, 最优的参数已经设置完成, 模型在预测时无需进行交叉检验的步骤, 所以大大节省了运算时间。

表 1 不同预测模型在不同天气类型下的预测误差及耗时比较

Table 1 Prediction error and running time comparison between different models and different types of weather

天气类型	EMD-ABC-SVM			EMD-SVM			单一 SVM		
	MAPE/%	RMSE/%	运算时间/s	MAPE/%	RMSE/%	运算时间/s	MAPE/%	RMSE/%	运算时间/s
晴天	6.35	7.59	6.56	9.73	10.46	103.43	12.89	13.74	14.33
晴转多云	12.38	13.05	6.68	15.26	17.03	106.75	18.44	20.63	16.76
多云	13.55	14.16	7.05	17.03	18.52	104.98	19.68	21.27	17.42
阴天	10.89	12.07	7.87	13.95	14.83	107.86	16.66	18.72	18.04

4 结论

本文将人工蜂群优化算法和经验模态分解方法相结合, 并将其成功应用于光伏并网系统输出功率短期预测领域。通过模糊 C-均值筛选同一季节类型的相似日; 采用 EMD 方法对输出功率序列进行经验模态分解, 得到 n 个不同尺度下的固有模态分量 IMF 和 1 个趋势分量 Res , 针对每个分量分别建立相应的 SVM 预测模型, 并对 SVM 模型参数进行人工蜂群算法寻优预处理; 最后, 将每个模型预测的结果进行合成重构, 得到光伏并网系统输出功率的预测值。通过实际数据测试表明: EMD-ABC-SVM 预测模型的效果优于单一 SVM 预测模型及未经优化的 EMD-SVM 预测模型。本文提出的方法提高了光伏并网系统输出功率的预测精度, 降低了光伏发电功率的随机性对公共电网安全、可靠运行带来的影响, 为电网电能优化调度提供了一种有效的方法。

参考文献

[1] 姚致清, 于飞, 赵倩, 等. 基于模块化多电平换流器的大型光伏并网系统仿真研究[J]. 中国电机工程学报, 2013, 33(36): 27-33.
YAO Zhiqing, YU Fei, ZHAO Qian, et al. Simulation research on large-scale PV grid-connected systems based on MMC[J]. Proceedings of the CSEE, 2013, 33(36): 27-33.

[2] 陈权, 李令冬, 王群京, 等. 光伏发电并网系统的仿真建模及对配电网电压稳定性影响[J]. 电工技术学报, 2013, 28(3): 241-247.
CHEN Quan, LI Lingdong, WANG Qunjing, et al. Simulation model of photovoltaic generation grid-connected system and its impacts on voltage stability in distribution grid[J]. Transactions of China Electrotechnical Society, 2013, 28(3): 241-247.

[3] 宋小会, 郭志忠, 郭华平, 等. 一种基于森林模型的光伏发电功率预测方法研究[J]. 电力系统保护与控制, 2015, 43(2): 13-18.
SONG Xiaohui, GUO Zhizhong, GUO Huaping, et al. A new forecasting model based on forecast for photovoltaic power generation[J]. Power System Protection and Control, 2015, 43(2): 13-18.

[4] 王飞, 米增强, 杨奇逊, 等. 基于神经网络与关联数据的光伏电站发电功率预测方法[J]. 太阳能学报, 2012, 33(7): 1172-1177.
WANG Fei, MI Zengqiang, YANG Qixun, et al. Power forecasting approach of PV plant based on ANN and relevant data[J]. Acta Energiæ Solaris Sinica, 2012, 33(7): 1172-1177.

[5] 陈世慧, 阮大兵. 光伏发电有功功率预测及其在电网频率控制中的应用[J]. 电力系统保护与控制, 2013, 41(20): 125-129.
CHEN Shihui, RUAN Dabing. Prediction of photovoltaic power and its application in power grid frequency control[J]. Power System Protection and Control, 2013, 41(20): 125-129.

[6] 蒋浩, 洪丽, 张国江. 主成分分析结合神经网络的光伏发电量预测[J]. 电力系统及其自动化学报, 2013, 25(6): 101-105.
JIANG Hao, HONG Li, ZHANG Guojiang. PV generation system forecasting model based on neutral network and principal components analysis[J]. Proceedings of the CSU-EPSSA, 2013, 25(6): 101-105.

[7] SHI J, LEE W J, LIU Y, et al. Forecasting power output of photovoltaic systems based on weather classification and support vector machines[J]. IEEE Transactions on Industry Applications, 2012, 48(3): 1064-1069.

[8] 于炳霞, 谭志萍, 崔方, 等. 光伏发电功率预测自适应

- 建模方法研究[J]. 电网与清洁能源, 2013, 29(1): 70-73.
YU Bingxia, TAN Zhiping, CUI Fang, et al. An adaptive modeling study on photovoltaic power prediction[J]. Power System and Clean Energy, 2013, 29(1): 70-73.
- [9] 丁明, 王磊, 毕锐. 基于改进 BP 神经网络的光伏发电系统输出功率短期预测模型[J]. 电力系统保护与控制, 2012, 40(11): 93-99.
DING Ming, WANG Lei, BI Rui. A short-term prediction model to forecast output power of photovoltaic system based on improved BP neural network[J]. Power System Protection and Control, 2012, 40(11): 93-99.
- [10] 倪瑞雪, 郑大鹏, 许峰, 等. 光伏阵列输出特性的仿真研究[J]. 电力电子技术, 2013, 47(3): 33-35.
NI Ruixue, ZHENG Dapeng, XU Feng, et al. Simulation study on PV array output characteristics[J]. Power Electronics, 2013, 47(3): 33-35.
- [11] 姚致清, 张茜, 刘喜梅. 基于 PSCAD/EMTDC 的三相光伏并网发电系统仿真研究[J]. 电力系统保护与控制, 2010, 38(17): 76-81.
YAO Zhiqing, ZHANG Qian, LIU Ximei. Research on simulation of a three-phase grid-connected photovoltaic generation system based on PSCAD/EMTDC[J]. Power System Protection and Control, 2010, 38(17): 76-81.
- [12] 白俊良, 梅华威. 改进相似度的模糊聚类算法在光伏阵列短期功率预测中的应用[J]. 电力系统保护与控制, 2014, 42(6): 84-90.
BAI Junliang, MEI Huawei. Improved similarity based fuzzy clustering algorithm and its application in the PV array power short-term forecasting[J]. Power System Protection and Control, 2014, 42(6): 84-90.
- [13] 王贺, 胡志坚, 陈珍, 等. 基于集合经验模态分解和小波神经网络的短期风功率组合预测[J]. 电工技术学报, 2013, 28(9): 137-144.
WANG He, HU Zhijian, CHEN Zhen, et al. A hybrid model for wind power forecasting based on ensemble empirical mode decomposition and wavelet neural networks[J]. Transactions of China Electrotechnical Society, 2013, 28(9): 137-144.
- [14] 许丹, 于龙, 王玉梅. 基于用最小二乘法改进的 EMD 与能量熵融合的断路器机械故障诊断方法[J]. 高压电器, 2014, 50(8): 99-103.
XU Dan, YU Long, WANG Yumei. Mechanical fault diagnosis method for circuit breaker based on the combination of energy entropy and improved EMD by using the least square method[J]. High Voltage Apparatus, 2014, 50(8): 99-103.
- [15] 臧怀刚, 李清志. 改进的 EMD 方法在局部放电信号提取中的应用[J]. 电力系统及其自动化学报, 2014, 26(11): 78-81.
ZANG Huaigang, LI Qingzhi. Application of improved EMD method on extraction of partial discharge signal[J]. Proceedings of the CSU-EPSCA, 2014, 26(11): 78-81.
- [16] KARABOGA D, OZTURK C. A novel clustering approach: artificial bee colony (ABC) algorithm[J]. Applied Soft Computing, 2011, 11(1): 652-657.
- [17] 高相铭, 刘付斌, 杨世凤. 基于极限学习机的供水管网故障智能诊断方法[J]. 计算机工程与设计, 2013, 34(8): 2887-2891.
GAO Xiangming, LIU Fubin, YANG Shifeng. Intelligent fault diagnosis of water supply network based on ELM[J]. Computer Engineering and Design, 2013, 34(8): 2887-2891.
- [18] HORNC M H, JLANG T W. Image vector quantization algorithm via honey bee mating optimization[J]. Expert Systems with Applications, 2011, 38(3): 1382-1392.

收稿日期: 2015-01-23; 修回日期: 2015-03-25

作者简介:

高相铭(1976-), 男, 博士, 讲师, 研究方向为新能源光伏发电技术, 故障诊断等; E-mail: acbcgao@163.com

杨世凤(1959-), 男, 博士, 教授, 博士生导师, 研究方向为新能源技术, 智能检测理论与应用等;

潘三博(1974-), 男, 博士, 副教授, 硕士生导师, 研究方向为可再生能源光伏发电及储能技术, 高效率电力电子变换器、谐振逆变器。

(编辑 葛艳娜)