

# 基于模糊信息粒化和最小二乘支持向量机的风电功率联合预测建模

王 恺<sup>1</sup>, 关少卿<sup>1</sup>, 汪令祥<sup>2</sup>, 王鼎奕<sup>2</sup>, 崔 垚<sup>1</sup>

(1. 国网安徽省电力公司合肥供电公司, 安徽 合肥 230022; 2. 阳光电源股份有限公司, 安徽 合肥 230088)

**摘要:** 提出一种基于模糊信息粒化和最小二乘支持向量机的风电功率平均值预测和风电功率波动范围预测的联合预测模型建模方法。该方法首先对训练样本进行模糊信息粒化, 根据需要提取各个窗口的有效分量信息, 即各窗口的最小值、大致平均值和最大值。其次应用最小二乘支持向量机对各个分量分别建立预测模型, 并使用自适应粒子群算法对各个分量模型进行优化。最后使用优化后的最小二乘支持向量机模型对风电功率平均值和风电功率波动范围进行联合预测。实例研究表明, 该联合预测模型可以有效进行风电功率平均值预测和风电功率波动范围预测的联合预测, 并能有效跟踪风电功率变化。

**关键词:** 风力发电; 功率预测; 模糊信息粒化; 最小二乘支持向量机; 联合预测

## A combined forecasting model for wind power prediction based on fuzzy information granulation and least squares support vector machine

WANG Kai<sup>1</sup>, GUAN Shaoqing<sup>1</sup>, WANG Lingxiang<sup>2</sup>, WANG Dingyi<sup>2</sup>, CUI Yao<sup>1</sup>

(1. State Grid Hefei Power Supply Company, Hefei 230022, China; 2. Sungrow Power Supply Co., Ltd., Hefei 230088, China)

**Abstract:** A combination prediction model modeling method for wind power average value prediction and wind power fluctuation range prediction is proposed, which is based on the fuzzy information granulation and least squares support vector machine (LSSVM). Firstly, fuzzy information granulation of the training samples is made, and effective component information of each window is extracted according to the need, namely the minimum, average and maximum value of each window. Secondly, LSSVM of the prediction models are established for each component, and then the adaptive particle swarm algorithm is used to optimize each component model. Finally, the optimized LSSVM model is used for combined forecast in terms of wind power average value and wind power fluctuation range. The case study shows that the combined prediction model can effectively predict wind power average value prediction and wind power fluctuation range, and accurately track the wind electric power change.

**Key words:** wind power; power prediction; fuzzy information granulation; least squares support vector machine; combined forecast

中图分类号: TM619 文献标识码: A 文章编号: 1674-3415(2015)02-0026-07

## 0 引言

风电的迅猛发展对于充分利用风能资源、实现节能减排目标十分有利。然而由于风电的随机波动性, 大容量风电场接入电网后, 增加了电网调频、调压以及调度运行等辅助服务负担, 并且严重威胁电力系统的安全稳定。风电功率的波动问题对电力系统造成的这一系列影响严重制约了风电的发展和风电在电力系统中的装机比例。

目前, 有研究人员对风电功率的波动性以及波动性对电网的影响做了一些研究。文献[1]对风电的波动特性进行了一些分析。文献[2]根据实测数据阐

述了风电功率波动的时空特性。文献[3]分析了不同时间尺度下风电功率波动对电网的影响程度。文献[4]考虑使用储能的方式来解决风电功率波动对电网的影响。上述研究大都是探讨未知风电波动趋势和波动范围的情况下风电波动对电网的影响, 如果能对风电功率的波动趋势和波动范围进行有效预测, 则可以提前评估风电功率波动对电网造成的影响, 可以进一步优化电力系统的旋转备用, 降低电力系统运行成本。同时为电网规划提供一定的技术支持。

目前研究人员对于风电功率预测的预测模型主要分为两种<sup>[5]</sup>: 基于物理方法的模型<sup>[6]</sup>和基于统计方法的模型。物理模型一般基于数值天气预报和风

电区域的地理信息, 统计方法则不考虑这些物理信息, 而是利用统计学的办法, 直接建立起相关输入与输出功率之间的一种非线性的“黑箱”映射预测模型。物理方法预测不需要大量的风电场运行数据, 比较适合新建的风电场, 然而物理预测需要风电场区域的地形、障碍物、等高线等相关的模型和数据, 建模过程比较复杂, 相对于基于统计方法的预测模型来说预测精度较差, 一般在新建风电场中使用较多; 而基于统计方法的预测效果则相对较好, 文献[7]使用带限幅环节的差分自回归滑动平均模型对风电功率序列进行预测建模; 文献[8-9]建立了基于神经网络的预测模型; 文献[10-12]建立了基于支持向量机的风电功率组合预测模型; 文献[13-16]则考虑使用交叉熵理论对三种统计预测模型进行优化组合。

上述模型各具特点, 然而这些风电功率预测模型大都是对风电功率平均值进行预测, 关于风电功率波动趋势和波动范围的预测问题, 目前还有待开展更深入的研究。本文基于实测数据, 探讨基于信息粒化技术和最小二乘支持向量机的风电功率平均值和风电功率波动范围的联合预测模型的建模与研究。首先使用模糊信息粒化技术对大量训练数据进行有效提取; 其次在提取的有效数据基础上分别建立最小二乘支持向量机的模型, 并使用自适应粒子群算法对各个模型进行优化; 然后使用优化后的模型对风电功率平均值和风电功率的波动范围进行联合预测。研究结果分析表明, 该模型可以有效地进行风电功率平均值和风电功率波动范围的联合预测。

## 1 模糊信息粒化

信息粒化就是将一个整体分解为一个个的部分进行研究, 每个部分为一个信息粒。信息粒化这一概念最早是由Lotfi A. Zadeh(L.A. Zadeh)教授提出的<sup>[17]</sup>。Zadeh教授指出: 信息粒是一些元素的集合, 这些元素由于难以区别、或相似、或接近或某种功能而结合在一起。对于风电功率预测来说, 可以根据预测的需要把相应的时间段的数据作为一个信息粒来进行研究。通过信息粒化技术来提取各个信息粒的有效信息。

信息粒化的主要模型有三种: 基于粗糙集理论的模型<sup>[18]</sup>; 基于商空间理论的模型<sup>[17]</sup>; 基于模糊集理论的模型<sup>[19]</sup>; 本文采用基于W. Pedrycz的模糊粒化方法<sup>[20]</sup>。模糊信息粒就是以模糊集形式表示的信息粒。用模糊集方法对预测序列进行模糊粒化。模糊信息粒化主要分为两个步骤: 窗口的划分和信息的模糊化。窗口的划分就是把整个的预测序列根据需要分割成若干小的子序列, 每一个子序列作为

一个操作窗口; 信息的模糊化其实是一个有效信息提前的过程, 就是采用一定的规则对产生的每一个窗口的信息进行模糊化, 生成一个个模糊集, 也就是模糊信息粒。窗口的划分需要根据预测的需要来进行, 而模糊化的过程重点, 则是建立一个合理的模糊集, 使其能够取代原来窗口中的有用信息<sup>[21-23]</sup>。

考虑单窗口问题, 即对于给定的时间序列  $X$ , 把整个时序  $X$  看成是一个窗口进行模糊化。模糊化的任务是在  $X$  上建立一个模糊粒子  $P$ , 也就是一个能够合理描述  $X$  的模糊概念  $G$  (以  $X$  为论域的模糊集合), 确定了  $G$  也就确定了模糊粒子  $P$ :  $g \triangleq xisG, x \in X$ , 所以模糊化过程本质上就是确定一个  $G$  的隶属函数  $A$  的过程, 即  $A = \mu_G$ , 通常粒化时首先需要确定模糊概念的基本形式, 然后确定具体的隶属函数。常用的模糊粒子形式有: 三角型、梯形、高斯型、抛物型等。根据本文研究的需要, 采用三角型, 其隶属函数可表示为

$$A(x, a, m, b) = \begin{cases} 0, & x < a \\ \frac{x-a}{m-a}, & a \leq x \leq m \\ \frac{b-x}{b-m}, & m < x \leq b \\ 0, & x > b \end{cases} \quad (1)$$

式中:  $x$  是论域中的变量;  $a$ 、 $m$  和  $b$  是参数。 $a$ 、 $m$  和  $b$  分别对应每个窗口都得到的 3 个模糊粒化后的变量:  $LOW$ ,  $R$  和  $UP$ 。对于单个模糊粒子而言,  $LOW$  参数描述了该粒子原始数据变化的最小值,  $R$  参数描述了该粒子相应的原始数据变化的大体平均水平,  $UP$  参数描述了原始数据变化的最大值。

## 2 最小二乘支持向量机及优化

### 2.1 LSSVM 回归预测基本原理

最小二乘支持向量机回归的基本原理是通过一定的非线性映射将输入数据映射到高维特征空间, 然后在高维空间中构造最优线性回归函数。按结构风险最小化(Structure Risk Minimization, SRM)原则, 最小二乘支持向量机(LSSVM)的训练目标可表示为式(2)。

$$\begin{cases} \min \left( \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^l e_i^2 \right) \\ \text{s.t. } \omega^\top \phi(x_i) + b + e_i = y_i \quad i = 1, \dots, l \end{cases} \quad (2)$$

式中:  $\gamma$  为正则化参数, 控制对误差的惩罚程度;  $\omega$  是权值向量;  $\phi(x_i)$  为核函数;  $b$  为偏移量;  $e_i$  为误差变量。

引入Lagrange乘子  $\alpha_i$ ,  $\alpha_i \in R^{l \times 1}$ , 构造式(2)对

偶的Lagrange多项式:

$$\min J = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^l e_i^2 - \sum_{i=1}^l \alpha_i (\omega^\top \phi(x_i) + b + e_i - y_i) \quad (3)$$

由Karush-Kuhn-Tucker(KKT)条件可得式(4)。

$$\frac{\partial J}{\partial \omega} = \frac{\partial J}{\partial e_i} = \frac{\partial J}{\partial b} = \frac{\partial J}{\partial \alpha_i} = 0 \quad (4)$$

式(4)可以写成如式(5)的线性方程组,消去式(5)中的 $\omega$ 和 $e$ ,使方程组(5)只与 $b$ 和 $\alpha_i$ 有关,这样方程组(5)就转化为如式(6)的方程组。

$$\begin{bmatrix} I & 0 & 0 & -Z^\top \\ 0 & 0 & 0 & \vec{L}^\top \\ 0 & 0 & \gamma I & -I \\ Z & \vec{L} & I & 0 \end{bmatrix} \begin{bmatrix} \omega \\ b \\ e \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ y \end{bmatrix} \quad (5)$$

式(5)中:  $\vec{L} = [1, 1, \dots, 1]^\top$ ,  $e = [e_1, e_2, \dots, e_l]^\top$ ,  $y = [y_1, y_2, \dots, y_l]^\top$ ,  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_l]^\top$ ,  $Z = [\phi(x_1), \dots, \phi(x_l)]^\top$ 。

$$\begin{bmatrix} 0 & \vec{L}^\top \\ \vec{L} & ZZ^\top + \gamma^{-1}I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式(6)中:  $ZZ^\top$ 是一个 $l \times l$ 的方阵,  $ZZ^\top = k(x_i, x_j)$ 。 $k(x_i, x_j)$ 为最小二乘支持向量机的核函数,不同的核函数可以生成不同的最小二乘支持向量机<sup>[24]</sup>。考虑到风电功率预测模型的严重非线性特征,本文选择RBF径向基函数为核函数,表达式为

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (7)$$

式中,  $\sigma$ 为核宽度。通过式(6)的求解,可以得到支持向量系数 $\alpha_i$ 和偏移量 $b$ ,进而得到最小二乘支持向量机的回归模型为

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (8)$$

在最小二乘支持向量机的回归模型中,惩罚参数 $\gamma$ 和核参数 $\sigma^2$ 是影响最小二乘支持向量机性能最大的两个参数。文献[24]使用细菌趋药性算法对最小二乘支持向量机的参数进行了优化,并用于短期负荷预测;文献[25]则使用自适应遗传算法对最小二乘支持向量机的参数进行了优化。文献[26]使用带收缩因子的粒子群算法对最小二乘支持向量机进行了优化。为了提高文中模型的预测精度,同时避免人为选择参数的盲目性,本文采用非线性惯性权值的自适应粒子群算法对这两个参数进行优化。

## 2.2 粒子群算法及改进

粒子群算法是一种基于鸟类捕食行为的群智能寻优算法,粒子群算法初始化一群随机粒子,然后通过迭代寻找最优解。 $(pbest)P_i$ 为第 $i$ 个粒子经历过的最优位置, $(gbest)P_g$ 为群体经历的最优位置,在每一次迭代中,粒子通过个体极值 $(pbest)P_i$ 和全局极值 $(gbest)P_g$ 来更新自己的速度和位置,更新公式为

$$v_{i,j}(t+1) = \omega \cdot v_{i,j}(t) + c_1 \cdot \text{rand} \cdot (p_{i,j} - x_{i,j}(t)) + c_2 \cdot \text{rand} \cdot (P_{g,i} - x_{i,j}(t)) \quad (9)$$

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1), j = 1, \dots, d \quad (10)$$

式中: $\omega$ 为惯性权值系数; $c_1$ 和 $c_2$ 是加速因子; $\text{rand}$ 为0到1之间的随机数。

在上述参数中, $\omega$ 为粒子群算法中最重要一个一个参数, $\omega$ 的选择是影响算法搜索行为和性能的关键所在;较大的 $\omega$ 具有较强的全局收敛能力,而较小 $\omega$ 的则有较强的局部收敛能力。因此,随着迭代次数的增加,惯性权重应不断减少,从而使得微粒群算法在初期具有较强的全局收敛能力,而晚期具有较强的局部收敛能力。本文采用基于Sigmoid函数的非线性递减惯性权值<sup>[27]</sup>。 $\omega$ 如式(11)所示。

$$\omega = \left(1 + \exp\left(\frac{(\ln 1.5 + \ln 19)t}{t_m}\right) - \ln 19\right)^{-1} \quad (11)$$

式中: $t$ 为当前迭代次数, $t_m$ 为最大允许迭代次数。文献[25]证明了使用基于Sigmoid函数的惯性权值的粒子群算法性能要优于采用其他几种惯性权值的粒子群算法。

## 2.3 改进的粒子群算法优化LSSVM过程

改进的粒子群优化最小二乘支持向量机的一般步骤如下。

### 1) 粒子群算法的参数初始化

首先确定最小二乘支持向量机的惩罚参数 $\gamma$ 和核参数 $\sigma^2$ 范围,文中设定 $\gamma \in [0, 1000]$ ,  $\sigma^2 \in [0, 100]$ ;其次确定自适应粒子群算法的相关参数,这些参数包括:粒子数目40,维数2,学习因子 $c_1 = 1.5$ 和 $c_2 = 1.5$ ,最大迭代次数 $t_m = 200$ 。然后在最小二乘支持向量机的惩罚参数 $\gamma$ 和核参数 $\sigma^2$ 范围内随机初始化粒子群。

### 2) 根据式(11)计算自适应权重

3) 以回归误差平方和最小为适应度,计算并比较适应度。记录各粒子的最佳位置和全局最佳位置。

### 4) 根据式(9)、式(10)更新粒子的速度和位置。

5) 判断终止条件,满足条件则输出结果,否则转向步骤2)。

### 3 风电功率联合预测模型建模

风电功率具有很强的波动性和间歇性特征, 因此对于风电功率的预测不能只局限于对风电平均功率的预测研究, 应该进行风电功率平均值和风电功率波动范围预测的联合研究。而模糊信息粒化在以粒子为单元的信息处理中具有突出的优势, 尤其适用于对风电平均功率和功率波动的分析和研究。而带收缩因子的粒子群算法可以对最小二乘支持向量机进行优化, 同时避免了人为选择参数的盲目性, 可以提高模型的预测精度。鉴于此, 本文提出一种基于模糊信息粒化和最小二乘支持向量机(FIG-LSSVM)的风电平均功率和波动范围的联合预测模型。相关建模流程如图 1 所示, 具体步骤如下。

1) 样本数据的提取和模糊信息粒化处理, 首先提取样本数据, 其次确定窗口大小, 最后根据式(1)对样本数据进行模糊信息粒化。

2) 分别对信息粒化后得到的  $LOW$ (最小值),  $R$ (平均值)和  $UP$ (最大值)进行归一化整理, 归一化公式如式(12)所示。

$$p_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

式中:  $p_i$  是训练样本中某一变量数据  $x_i$  归一化后的数据;  $x_{\min}$  为样本中该组数据的最小值;  $x_{\max}$  为样本中该组数据的最大值。

使用归一化后的数据分别建立最小二乘支持向量机的模型, 并使用自适应粒子群算法对各个模型进行参数优化, 得到各模型优化后的参数。具体优化过程见 2.3 节。

3) 使用各模型优化后的 LSSVM 参数求解出 LSSVM 回归模型中的参数  $\alpha_i$  和  $b$ , 然后将求解得

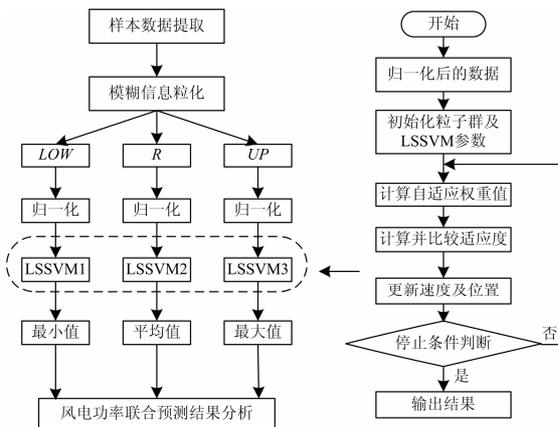


图 1 联合预测模型建模流程图

Fig. 1 Flowchart of combined prediction

到的参数代入回归函数式(8)中, 从而构建出风电功率预测的最小二乘支持向量机模型。

4) 使用各预测模型预测下一个窗口的  $LOW$ (最小值),  $R$ (平均值)和  $UP$ (最大值)。

5) 对预测结果进行分析。

针对联合预测的特点, 考虑采用均方根误差<sup>[1]</sup>(Root Mean Square Error, RMSE)、平均相对误差<sup>[1]</sup>(Mean Relative Error, MRE)、平均绝对误差(Mean Absolute Error, MAE)和各时间点最大预测误差(Maximum Prediction Error, MPE)四种误差评价指标对联合预测结果进行性能分析。

### 4 实例仿真

本文以广西金紫山风电场某号机组2010年11月的实测输出功率数据为样本数据, 进行以1个小时为单元的风电功率平均值和风电功率波动范围的联合预测研究。以11月1日到11月29日的数据为训练样本模型来预测11月30日凌晨第一个小时的平均功率及功率波动范围。由于样本的采样周期为10 min, 所以一共有4 176组数据。提取的训练样本的时间序列如图 2 所示。

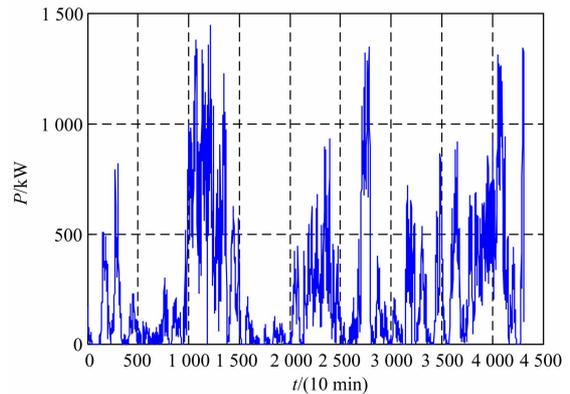


图 2 输出功率时间序列

Fig. 2 Time series of wind power

对训练数据进行模糊信息粒化。以一个小时(6个)为一个窗口将训练集利用式(1)进行模糊信息粒化, 粒化后的各个分量如图 3 所示。图中:  $LOW$  表示各个窗口的最小值,  $R$  表示大致平均值,  $UP$  表示最大值。

以  $LOW$ (每小时输出功率最小值)为例建立最小二乘支持向量机的预测模型, 首先对  $LOW$  值进行归一化整理, 使用式(12)进行, 归一化处理后的值如图 4 所示, 然后使用改进的自适应粒子群算法来优化  $LOW$  的最小二乘支持向量机模型, 优化过程中的适应度曲线如图 5 所示。得到的最小二乘支持向量机的参数为:  $\gamma = 138.3041$ ,  $\sigma^2 = 0.0164$ , 根

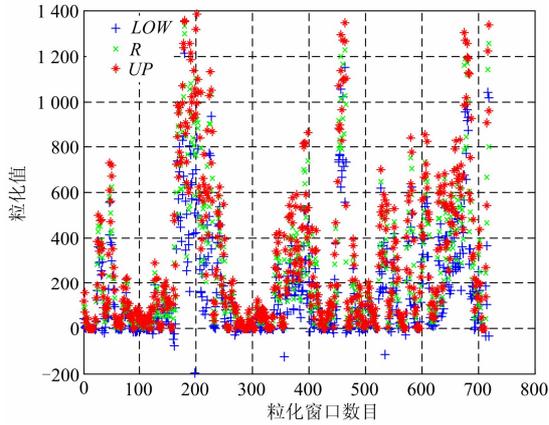


图3 模糊信息粒化可视化图

Fig. 3 Visualization of fuzzy information granulation

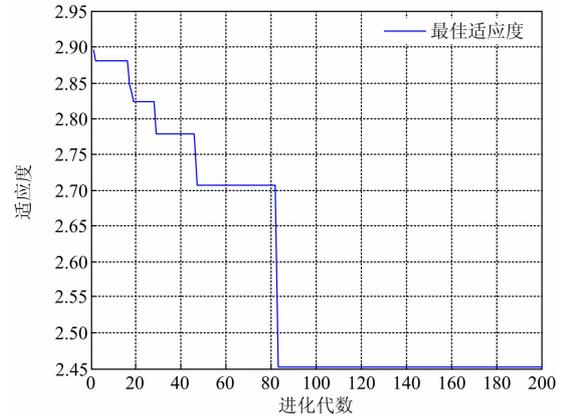


图5 适应度曲线

Fig. 5 Curve of fitness function

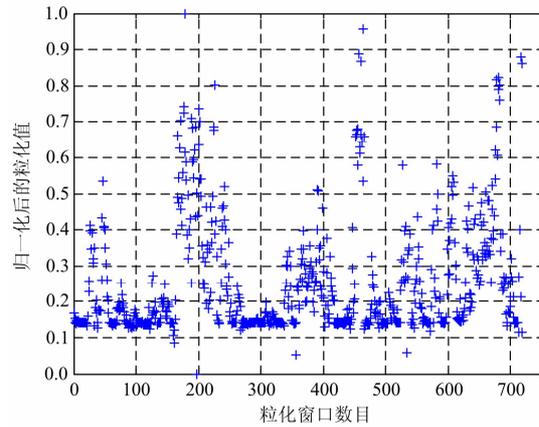


图4 LOW 值归一化

Fig. 4 LOW value normalization

据参数和训练样本得到优化后的模型。使用模型进行预测，得到的 *LOW* 值为 147.365 2。

使用同样方法建模，并优化最小二乘支持向量机模型预测得到的 *R*(平均值)和 *UP*(最大值)。以 1 个窗口(1 h)为单位，进行滚动联合预测 11 月 30 号零点到六点之间的风电功率情况，预测结果如表 1 所示。

为了更好地验证本文所提模型的有效性，使用同样的样本数据，在模糊信息粒化后，分别使用 Elman 神经网络和常规支持向量机进行相应的回归预测，同时对这两种模型也都选取合适的参数。其预测结果如表 2、表 3 所示。并对其进行相关误差分析，根据联合预测各分量的特点，对其采用不同的误差分析指标，对 *R* 采用均方根误差(RMSE)和平均相对误差(MRE)进行误差分析，对 *LOW* 和 *UP* 则同时采用平均绝对误差(MAE)和最大预测误差(MPE)进行误差分析。

表 1 LSSVM 风电功率联合预测结果

Table 1 Results of wind power combined prediction based on LSSVM

时间/ h	<i>LOW</i>		<i>R</i>		<i>UP</i>	
	预测值	实测值	预测值	实测值	预测值	实测值
1	147.365 2	152.17	194.665 0	188.30	231.154 8	219.32
2	42.163 9	51.26	80.210 4	95.08	137.645 1	133.49
3	88.794 6	95.64	124.971 6	127.11	159.310 6	138.06
4	54.350 9	68.91	136.440 2	127.08	221.658 9	212.60
5	230.443 7	248.43	294.631 5	318.39	354.409 7	352.94
6	245.651 3	248.06	370.332 9	358.04	451.126 3	440.44

表 2 Elman 风电功率联合预测结果

Table 2 Results of wind power combined prediction based on Elman

时间/ h	<i>LOW</i>		<i>R</i>		<i>UP</i>	
	预测值	实测值	预测值	实测值	预测值	实测值
1	141.782 1	152.17	176.302 2	188.30	245.983 5	219.32
2	44.369 5	51.26	101.681 8	95.08	145.392 6	133.49
3	91.256 4	95.64	142.776 9	127.11	149.060 2	138.06
4	47.265 1	68.91	134.511 2	127.08	253.265 7	212.60
5	221.265 7	248.43	281.029 3	318.39	367.998 5	352.94
6	234.006 9	248.06	364.301 8	358.04	446.231 7	440.44

表 3 SVM 风电功率联合预测结果

Table 3 Results of wind power combined prediction based on SVM

时间/ h	<i>LOW</i>		<i>R</i>		<i>UP</i>	
	预测值	实测值	预测值	实测值	预测值	实测值
1	136.998 1	152.17	181.965 2	188.30	226.389 5	219.32
2	48.396 5	51.26	105.623 1	95.08	141.996 4	133.49
3	86.711 5	95.64	135.332 9	127.11	146.102 8	138.06
4	56.394 7	68.91	121.986 0	127.08	234.951 7	212.60
5	228.396 4	248.43	373.251 6	318.39	369.668 5	352.94
6	241.764 5	248.06	362.001 3	358.04	454.963 9	440.44

从表 4 中可以看出, 三种模型都可以进行风电功率的联合预测研究。然而本文使用的自适应粒子群优化 LSSVM 的联合预测模型性能更好, 预测精度更高。

表 4 几种模型的误差指标

Table 4 Error indicators of the three models

预测 模型	LOW		R		UP	
	MAE	MPE	RMSE	MRE	MAE	MPE
Elman	14.087 4	27.164 3	17.903 6	0.075 0	18.513 7	40.665 7
SVM	12.301 4	28.033 6	23.346 4	0.072 1	10.370 5	22.351 7
LSSVM	9.283 4	17.986 3	13.350 3	0.064 9	9.742 6	21.250 6

## 5 结论

本文基于实测数据, 探讨应用信息粒化技术和最小二乘支持向量机相结合的方法建立风电功率波动范围和风电功率平均值的联合预测模型。从实验研究过程和结果来看, 可以得到以下结论:

1) 信息粒化技术具有对大规模数据进行挖掘并有效提取有用信息的能力, 最小二乘支持向量机具有对任何非线性函数的逼近能力。两种方法相结合建立的联合预测模型可以有效地进行风电功率的联合预测。

2) 与其他两种模型的对比研究验证了本文模型的先进性和有效性, 充分说明了本文模型在工程应用上具有可行性。

3) 本文所提出的联合预测模型具有较好的自适应性的特点, 广西金紫山风电场某风机风电功率平均值和风电功率波动范围的联合预测的结果说明该模型能很好地应用于风电功率预测领域中。

## 参考文献

[1] 林卫星, 文劲宇, 艾小猛, 等. 风电功率波动特性的概率分布研究[J]. 中国电机工程学报, 2012, 32(1): 38-46.  
LIN Weixing, WEN Jinyu, AI Xiaomeng, et al. Probability density function of wind power variations[J]. Proceedings of the CSEE, 2012, 32(1): 38-46.

[2] 崔杨, 穆钢, 刘玉, 等. 风电功率波动的时空分布特性[J]. 电网技术, 2011, 35(2): 110-114.  
CUI Yang, MU Gang, LIU Yu, et al. Spatiotemporal distribution characteristic of wind power fluctuation[J]. Power System Technology, 2011, 35(2): 110-114.

[3] SORENSEN P, CUTULULIS N A, VIGUERAS-RODRIGUEZ A, et al. Power fluctuations from large wind farms[J]. IEEE Transactions on Power Systems, 2007, 22(3): 958-965.

[4] MARY B, GORAN S. Value of bulk energy storage for managing wind power fluctuations[J]. IEEE Transactions

on Energy Conversion, 2007, 22(1): 197-205.

[5] ERNST B, OAKLEAF B, AHLSTROM M L, et al. Predicting the wind[J]. IEEE Power & Energy Magazine, 2007(11): 79-89.

[6] 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 Shuanglei, WANG Weisheng, LIU Chun, et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE, 2010, 30(2): 1-6.

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

[8] 范高锋, 王伟胜, 刘纯, 等. 基于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.

[9] 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 Tiejia, 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.

[10] 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.

[11] 王丽婕, 廖晓钟, 高阳, 等. 风电场发电功率的建模和预测研究综述[J]. 电力系统保护与控制, 2009, 37(13): 17-20.  
WANG Lijie, LIAO Xiaozhong, GAO Yang, et al. Summarization of modeling and prediction of wind power generation[J]. Power System Protection and Control, 2009, 37(13): 17-20.

[12] 杨锡运, 孙宝君, 张新房, 等. 基于相似数据的支持向量机短期风速预测仿真研究[J]. 中国电机工程学报, 2012, 32(4): 35-41.  
YANG Xiyun, SUN Baojun, ZHANG Xinfang, et al. Short-term wind speed forecasting based on support vector machine with similar data[J]. Proceedings of the CSEE, 2012, 32(4): 35-41.

[13] 陈宁, 沙倩, 汤奕, 等. 基于交叉熵理论的风电功率组

- 合预测方法[J]. 中国电机工程学报, 2012, 32(4): 29-34.  
CHEN Ning, SHA Qian, TANG Yi, et al. A combination method for wind power prediction based on cross entropy theory[J]. Proceedings of the CSEE, 2012, 32(4): 29-34.
- [14] 吴兴华, 周晖, 黄梅. 基于模式识别的风电场风速和发电功率预测[J]. 继电器, 2008, 36(1): 27-32.  
WU Xinghua, ZHOU Hui, HUANG Mei. Wind speed and generated power forecasting based on pattern recognition in wind farm[J]. Relay, 2008, 36(1): 27-32.
- [15] 李卫星, 李志民, 邬建华, 等. 基于信息融合理论的电力系统预测方法研究[J]. 继电器, 2001, 29(10): 16-18.  
LI Weixing, LI Zhimin, WU Jianhua, et al. Research on power system forecasting method based on the theory of information fusion[J]. Relay, 2001, 29(10): 16-18.
- [16] 李俊芳, 张步涵, 谢光龙, 等. 基于灰色模型的风速-风电功率预测研究[J]. 电力系统保护与控制, 2010, 38(19): 151-159.  
LI Junfang, ZHANG Buhuan, XIE Guanglong, et al. Grey predictor models for wind speed-wind power prediction[J]. Power System Protection and Control, 2010, 38(19): 151-159.
- [17] ZADEL L A. Towards a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic[J]. Fuzzy Sets and System, 1997, 90(2): 111-127.
- [18] PAWLAK Z. Granularity of knowledge, indiscernibility and rough sets[C] // Proceedings of IEEE World Congress on Computational Intelligence, Piscataway, NJ, USA: 1998.
- [19] 张铃, 张钊. 模糊商空间理论(模糊粒度计算方法)[J]. 软件学报, 2003, 14(4): 770-776.  
ZHANG Ling, ZHANG Bo. Theory of fuzzy quotient space (methods of fuzzy granular computing)[J]. Journal of Software, 2003, 14(4): 770-776.
- [20] BARGIELA A, PEDRYCZ W. Granular computing: an introduction[M]. Dordrecht: Kluwer Academic Publishers, 2003.
- [21] 王林, 叶林, 陈盛, 等. 支持向量机向量维数对短期风电功率预测精度的影响[J]. 电力系统保护与控制, 2012, 40(15): 63-69.  
WANG Lin, YE Lin, CHEN Sheng, et al. Influence of the vector-dimension of SVM on short-term wind power prediction accuracy[J]. Power System Protection and Control, 2012, 40(15): 63-69.
- [22] 张宁宇, 高山, 赵欣. 一种考虑风电随机性的机组组合模型及其算法[J]. 电工技术学报, 2013, 28(5): 22-29.  
ZHANG Ningyu, GAO Shan, ZHAO Xin. An unit commitment model and algorithm with randomness of wind power[J]. Transactions of China Electrotechnical Society, 2013, 28(5): 22-29.
- [23] 黄大为, 张伟, 韩学山. 一种考虑系统有功调节能力的风电功率场景选取方法[J]. 电力系统保护与控制, 2013, 41(1): 33-39.  
HUANG Dawei, ZHANG Wei, HAN Xueshan. A wind power scenarios' selection method considering the active power dispatching ability[J]. Power System Protection and Control, 2013, 41(1): 33-39.
- [24] 曾鸣, 吕春泉, 田廓, 等. 基于细菌群落趋药性优化的最小二乘支持向量机短期负荷预测方法[J]. 中国电机工程学报, 2011, 31(34): 93-99.  
ZENG Ming, LÜ Chunquan, TIAN Kuo, et al. Least squares-support vector machine load forecasting approach optimized by bacterial colony chemotaxis method[J]. Proceedings of the CSEE, 2011, 31(34): 93-99.
- [25] 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, 29(4): 65-69.  
SHANG Wanfeng, ZHAO Shengdun, SHEN Yajing. Application of LSSVM optimized by genetic algorithm to modeling of switched reluctance motor[J]. Proceedings of the CSEE, 2009, 29(4): 65-69.
- [26] 张春晓, 张涛. 基于最小二乘支持向量机和粒子群算法的两相流含油率软测量方法[J]. 中国电机工程学报, 2010, 30(2): 86-91.  
ZHANG Chunxiao, ZHANG Tao. Soft measurement method for oil holdup of two phase flow based on least squares support vector machine and particle swarm optimization[J]. Proceedings of the CSEE, 2010, 30(2): 86-91.
- [27] 田东平, 赵天绪. 基于 Sigmoid 惯性权值的自适应粒子群优化算法[J]. 计算机应用, 2008, 28(12): 3058-3061.  
TIAN Dongping, ZHAO Tianxu. Adaptive particle swarm optimization algorithm based on Sigmoid inertia weight[J]. Computer Applications, 2008, 28(12): 3058-3061.

收稿日期: 2014-04-10; 修回日期: 2014-10-09

作者简介:

王 恺(1989-), 男, 助理工程师, 从事电网和企业数据分析等相关工作; E-mail: wkwkwk2818@163.com

关少卿(1979-), 男, 工程师, 从事电缆生产管理工作;

汪令祥(1976-), 男, 博士, 助理研究员, 从事风电设备开发工作。