

DOI: 10.7667/PSPC161827

# 基于 WRF 模式和 PSO-LSSVM 的风电场短期风速订正

叶小岭<sup>1,2</sup>, 顾荣<sup>1</sup>, 邓华<sup>1,2</sup>, 陈浩<sup>1</sup>, 杨星<sup>1</sup>

(1. 南京信息工程大学信息与控制学院, 江苏 南京 210044; 2. 南京信息工程大学气象灾害预报预警与评估协同创新中心, 江苏 南京 210044)

**摘要:** 风速预测是风电场风电功率预测的基础与前提, 以数值天气预报(WRF 模式)为基础进行风速预测, 为了提高 WRF 模式预测的准确性, 采用最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)对 WRF 模式输出的风速进行订正。同时, 为提高 LSSVM 算法的精确度和减小拟合过程的复杂度, 采用粒子群优化算法(Particle Swarm Optimization, PSO)对其参数进行优化。试验结果表明: 采用 LSSVM 订正可以进一步减小 WRF 模式预测风速的误差, 再经过 PSO 优化后, 相对均方根误差和相对平均绝对误差降低了 5%~10%, 均方根误差下降了 0.5 m/s。与未经优化的 LSSVM 以及极限学习机(ELM)算法对比分析后得出, 粒子群优化最小二乘支持向量机(PSO-LSSVM)对 WRF 模式预测的风速有较好的订正效果, 能进一步提高风速预测的准确性。

**关键词:** 风力发电; 风速订正; WRF 模式; PSO-LSSVM; 预测效果

## Modification technology research of short-term wind speed in wind farm based on WRF model and PSO-LSSVM method

YE Xiaoling<sup>1,2</sup>, GU Rong<sup>1</sup>, DENG Hua<sup>1,2</sup>, CHEN Hao<sup>1</sup>, YANG Xing<sup>1</sup>

(1. School of Information and Control, Nanjing University of Information Science & Technology, Nanjing 210044, China;  
2. Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters, Nanjing University of Information Science & Technology, Nanjing 210044, China)

**Abstract:** Wind speed forecasting is the base and precondition of wind power prediction of wind farm. The Numerical Weather Prediction (WRF) model is used to predict wind speed. In order to improve the accuracy of WRF model, the Least Square Support Vector Machine (LSSVM) is used to correct the wind speed of the output of the WRF model. At the same time, in order to improve the accuracy of the LSSVM model and reduce the complexity of the fitting process, Particle Swarm Algorithm (PSO) is used to optimize the parameters. Experimental results show that the LSSVM can further reduce the error of WRF model in predicting wind speed sequence, and the relative root mean square error and the relative to the average absolute error are reduced by 5%~10%, the RMS error decreased by 0.5 m/s. Compared with without optimized LSSVM and ELM, PSO-LSSVM has a better correction effect in wind speed predicting by WRF to improve the accuracy of wind speed forecasting.

This work is supported by National Natural Science Foundation of China (No. 41675156).

**Key words:** wind power; wind speed correction; WRF model; PSO-LSSVM; forecast effect

## 0 引言

随着人类对能源需求的不断增加, 传统的煤、

石油、天然气等化石能源被大量开采, 储量大幅度下降, 同时化石能源的过度使用也造成了温室效应、环境污染等问题, 所以清洁能源的开发和使用迫在眉睫<sup>[1]</sup>。而风能作为最有前途的绿色能源, 越来越受到了各国政府的重视<sup>[2]</sup>。由于风的不确定性和随机性, 进行准确的风电功率预测显得尤为重要<sup>[3]</sup>。而风速预测又是风电功率预测的基础, 若能提前准确地对风速进行预测, 就可以有效地解决大规模风

**基金项目:** 国家自然科学基金项目(41675156); 国家公益性行业(气象)科研专项(GYHY20110604); 江苏省六大人才高峰项目(WLW-021)资助; 江苏省研究生创新工程省立项目(SJZZ16-0155)

力运行和并网的问题<sup>[4]</sup>。按照建模方法的不同, 风速预测可以分为物理方法、统计方法和学习方法。单一的模型很难准确地进行风速预测, 所以越来越多的风速预测选择组合模型的方法<sup>[5-8]</sup>。

本文使用 WRF 模式进行风速的初步预测, 再使用基于机器学习的方法对 WRF 模式预测的风速进行订正, 达到风速预测的效果。传统的订正模型大多采用线性方法, 但是由于风的变化具有很大的随机性, 因此两个观测系统获取的风速数据之间的相关性不大, 两者之间的关系应该非线性的, 所以使用非线性模型进行订正才更加科学与精确。文献[9]应用 BP 神经网络在 MM5 模式预报福建沿海对于非线性数据的建模, 预测效果得到很大的改善。文献[10]运用支持向量机(SVM)方法找出风速的人工观测序列和自动观测序列之间的潜在关系, 并把人工观测序列往自动观测序列上修正, 使得两个序列之间的差异减小。文献[11]提出将机器学习方法运用于气象预测, 这也是目前一个炙手可热的研究领域。对于非线性数学模型的处理, 目前使用较为广泛的是神经网络和 SVM 方法。其中神经网络对于非线性数据具有很强的拟合能力, 应用十分广泛。但是其仍然存在一些缺陷, 例如: 很依赖训练样本的质量; 易于陷入局部最优解; 无法控制收敛速度等等。而 SVM 作为另一种常用的方法, 很好地避免了神经网络存在的问题, 与神经网络相比, 具有基于结构风险最小化原则, 将问题转换为凸优化问题, 避免了局部最优解等优点<sup>[12-14]</sup>。但 SVM 中核参数  $\sigma$  和正则化参数  $C$  的取值对模型的精确度和复杂度都有很大的影响, 传统的 SVM 中参数的选取通过反复尝试来获得, 这样存在着一定的随机性。另一种方法则是通过交叉验证的方法, 虽然克服了人为的随机性, 但却降低了效率<sup>[15]</sup>。LSSVM 和 SVM 在整体上一致的, 但是对于数据量较大的试验, 通过将不等式的约束条件变成等式约束条件, 使计算速率得到很大提升。

在参数寻优的方法上, PSO 作为目前使用较为广泛的优化算法, 在全局搜索能力方面有着很好的效果, 使用 PSO 方法对 LSSVM 中的参数进行优化, 提高模型的精确度。本文采用基于物理方法的 WRF 模式和基于机器学习的方法 PSO-LSSVM 进行短期风速预测。

## 1 资料和方法

### 1.1 WRF 模式方案设计

WRF 模式作为新一代中尺度预报和同化系统<sup>[16]</sup>广泛地应用到风能评估和风速预测研究

中。本文实验对象是上海某海上风力发电厂, 预报的区域位于  $30^{\circ}41'10''\sim 32^{\circ}42'44''\text{N}$ ,  $120^{\circ}21'10''\sim 122^{\circ}52'33''\text{E}$ 。采用了四层嵌套方式, 网格数分别设置为  $79\times 79$ 、 $91\times 91$ 、 $112\times 112$ 、 $130\times 130$ , 水平网格的分辨率设置为  $27\text{ km}$ 、 $9\text{ km}$ 、 $3\text{ km}$ 、 $1\text{ km}$ 。通过大量的试验以及参考相关文献, 确定 WRF 模式物理方案配置为<sup>[17]</sup>: 微物理采用 Kessler 方案; 边界层参数化采用 MYJ 方案; 辐射采用 Dudhia 短波辐射和 RRTM 长波辐射方案; 近地面层参数化采用 MM5 相似方案; 陆面过程采用 Noah 陆面过程方案。WRF 模式预报区域如图 1 所示。

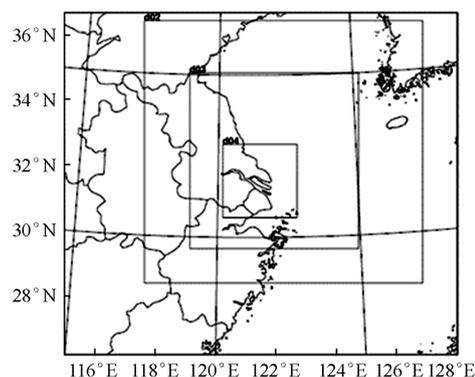


图 1 WRF 模式区域示意图

Fig. 1 WRF model area sketch

模式的输入资料采用美国国家环境预报中心的(NCEP)全球大气环流模式 NCEP/GFS 资料作为 WRF 的初始场和侧边界条件。GFS 资料能够预测未来 8 天的天气情况, 数据的分辨率为  $1^{\circ}\times 1^{\circ}$ 。并使用双线性插值的方法将 WRF 模式输出数据插值到  $70\text{ m}$  高度处的风机轮毂位置, 作为 WRF 模式预测的风速序列。

### 1.2 风场数据的选取

本文以上海某海上风力发电厂作为研究对象。风场的实测资料为风机轮毂高度  $70\text{ m}$  的风速, 由 SCADA 系统采集。以上各种数据的时间分辨率均为  $15\text{ min}$ 。

由于风电场处于季风区, 每个季节的风速变化特性不同, 所以在订正时, 四个季节分开处理。即选择每个季节中的连续 15 天的数据进行试验。其中 14 天的风速资料即 1344 组数据作为训练样本, 最后 1 天的风速资料即 96 组数据作为测试样本。

### 1.3 LSSVM 算法

SVM 是一种很有效地用于非线性数据拟合回归预测的学习算法<sup>[18]</sup>。一组样本数据  $\{x_i, y_i\}$ ,  $i = 1, 2, \dots, s$ , 其中:  $s$  为样本的数目;  $x_i \in R^n$  为输入数据;  $y_i \in R$  为目标输出。通过引进不敏感的损失

函数  $\varepsilon$ , SVM 可以解决回归预测问题, 其主要思想如下所述。

1) 设决策函数  $f(x) = \omega \cdot \phi(x) + b$ , 其中  $\phi(\cdot)$  为非线性映射, 它的作用是将一组非线性数据映射到高维, 从而转换为高维的线性数据进行运算。

2) 通过引进惩罚参数  $C$  和不敏感损失参数  $\varepsilon$ , 这样回归问题就能转化为关于参数  $\omega$  和  $b$  的凸二次规划问题。如式(1)所示。

$$\begin{cases} \min L(\omega) = \frac{1}{2} \|\omega\|^2 + c \cdot \sum_{i=1}^n (\xi_i + \xi_i^*) \\ \text{s.t. } \omega \cdot x_i + b - y_i \leq \varepsilon + \xi_i & i=1, \dots, l \\ y_i - (\omega \cdot x_i + b) \leq \varepsilon + \xi_i & i=1, \dots, l \\ \xi_i^* \geq 0 & i=1, \dots, l \\ \xi_i \geq 0 & i=1, \dots, l \end{cases} \quad (1)$$

式中:  $\omega$  为法向量;  $b$  为偏差;  $C$  是惩罚因子;  $\xi_i$  和  $\xi_i^*$  是引进的松弛变量。

3) 通过拉格朗日(Lagrange)函数以及对偶原理, 选择径向基函数(RBF)作为核函数  $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ , 式(1)经过变换后, 可得其对偶问题其中,  $\alpha^* = (\alpha_1, \alpha_1^*, \dots, \alpha_l, \alpha_l^*)^T$  是拉格朗日乘子组成的向量。则决策函数为

$$y = g(x) = \sum_{i=1}^l (\hat{\alpha}_i^* - \hat{\alpha}_i) K(x_i, x_j) + \hat{b} \quad (2)$$

4) LSSVM 采用最小二乘法思想求解 SVM 的回归问题。将传统的支持向量机中的不敏感损失函数改为误差的二次平方项, 这样不等式的约束条件就转换成了等式的约束条件。式(1)转换为式(3)。

$$\begin{cases} \min J = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \\ \text{s.t. } \omega^T \phi(x_i) + b + e_i = y_i, i=1, 2, \dots, N \end{cases} \quad (3)$$

式中:  $e_i$  为训练误差;  $\gamma$  确定训练误差平方的惩罚程度, 称为正则化参数。通过 Lagrange 函数以及对偶原理, LSSVM 用于非线性预测模型的公式为

$$f(x) = \sum_{i=1}^N \lambda_i K(x, x_i) + b \quad (4)$$

其中,  $\lambda$  和  $b$  可以求出。所以在 LSSVM 中, 核参数  $\sigma$  和正则化参数  $C$  的取值对模型的精确度和复杂度影响很大, 本文选用 PSO 算法对这两个参数进行寻优。

#### 1.4 粒子群优化算法

PSO 是最早由 Kennedy 等于 1995 年提出的一种全局随机优化技术<sup>[19]</sup>, 具有不易于陷入局部极小值, 需要调整的参数少且易于实现等优点, 所以在非线性和多模态问题中使用较广。假设  $n$  维的搜索

空间中有  $m$  个粒子组成的种群  $x = [x_1, x_2, \dots, x_m]^T$  代表有  $m$  个潜在解, 第  $i$  个粒子的位置为  $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T$ , 其对应的速度为  $v_i = [v_{i1}, v_{i2}, \dots, v_{im}]^T$ 。粒子之间通过个体最优位置  $p_i = [p_{i1}, p_{i2}, \dots, p_{im}]^T$  和种群最优位置  $g_i = [g_1, g_2, \dots, g_n]^T$  这两个极值实现信息的交换, 每个粒子根据式(5)来更新自身的速度和位置。

$$\begin{cases} v_{id}^{k+1} = \omega v_{id}^k + c_1 \text{rand}() (p_{id}^k - x_{id}^k) + c_2 \text{rand}() (g_d^k - x_{id}^k) \\ x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \end{cases} \quad (5)$$

式中:  $\omega$  为惯性因子, 控制搜索能力;  $c_1$  和  $c_2$  是学习因子, 决定了学习的能力;  $v_{id}^k$  和  $x_{id}^k$  分别是粒子  $i$  在第  $k$  次迭代中第  $d$  维的速度和位置;  $p_{id}^k$  和  $g_d^k$  是粒子  $i$  的最优位置以及种群的最优位置。每次迭代中, 每个粒子都需要根据目标函数计算其适应值, 从而确定  $p_{id}^k$  和  $g_{id}^k$ 。将 LSSVM 中的核参数  $\sigma$  和正则化参数  $C$  分别表示为  $p_{id}^k$  和  $g_{id}^k$ , 以均方根误差作为目标函数, 通过寻优得到参数  $\sigma$  和  $C$  的最优值。

#### 1.5 评价指标

根据气象局发布的最新文件, 风速预测的准确度指标主要包含均方根误差(RMSE), 相对均方根误差(rRMSE)以及相对平均绝对误差(rMAE), 通过这些指标对风速预测的准确率进行评价。

## 2 试验验证

### 2.1 WRF 模式风速预测

以 2014 年全年的风向为例, 图 2 为 2014 年测风塔实测风向与 WRF 模式预测风向的比较, 其中图 2(a)~图 2(d)分别表示春、夏、秋、冬四个季节的风向玫瑰图。虚线表示 WRF 模式的预测风向, 实线表示风场的实测风向。从图中可以看出, 除了春季 WRF 模式的预测风向有所偏差之外, 其余三个季节 WRF 模式的预测风向与实测风向具有较好的一致性, 概率分布相似。

再以 2014 年春季的风速为例, 抽取 14 天的风速资料即 1344 组数据, 结合风场的实测风速以及 WRF 模式的预测风速。通过对比可以发现, WRF 模式预测风速和 SCADA 系统采集的实测风速在整体上是一致的, 如图 3 所示。

将图 3 中 WRF 模式预测风速与实测风速作差, 就是预测的误差值, 其中在  $[-2, 2]$ (m/s)范围的样本数占整个试验序列的 50%, 如图 4 所示。

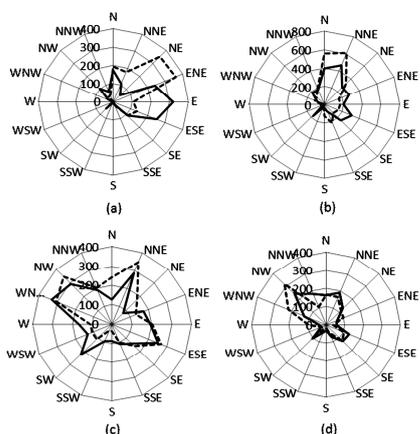


图 2 WRF 模式预测风向与实测风向对比  
Fig. 2 Comparison of wind direction between WRF and observed

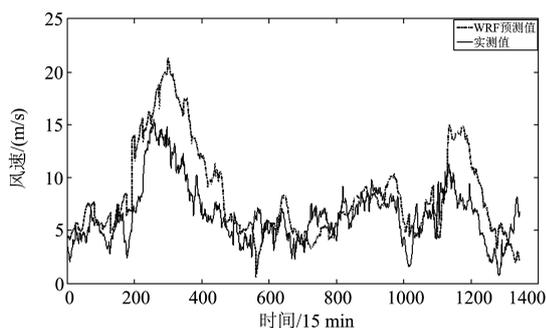


图 3 WRF 模式预测风速与实测风速对比  
Fig. 3 Comparison of wind speed between WRF and observed

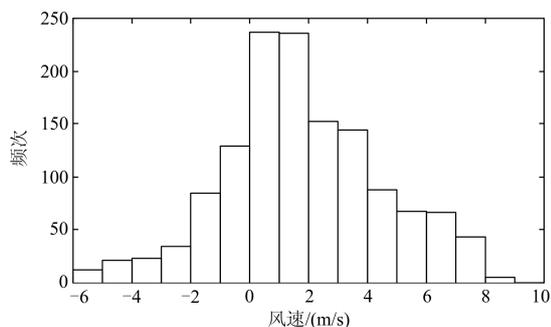


图 4 WRF 模式预测风速与实测风速误差分布  
Fig. 4 Distribution of wind speed error of WRF and observed

通过图 2—图 4 可以发现, WRF 模式能够较好地反映风速和风向特征, 说明利用该方法进行风场的短期风速预测是可行的。

但是当时间轴的单位缩小后, WRF 模式的预测风速和实测风速之间存在误差, 从表 1 可以看出, WRF 模式预测风速与实测风速的 RMSE 在 2 m/s 左右, rMAE 在 25%左右, rRMSE 在 30%左右。因为风场处于季风区, 夏、冬两季由于季风的影响,

风速变化大, 所以 WRF 模式预测风速的误差比较大。春、秋两季风速较为平稳, 所以预测风速误差也较小。这也说明 WRF 模式进行风速预测时存在误差, 需要进一步订正才能准确地预测风速。

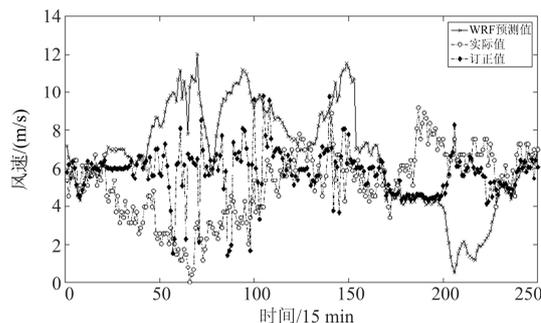
表 1 WRF 模式下四个季节风速误差分析

Table 1 Wind speed error analysis of the four seasons in WRF model

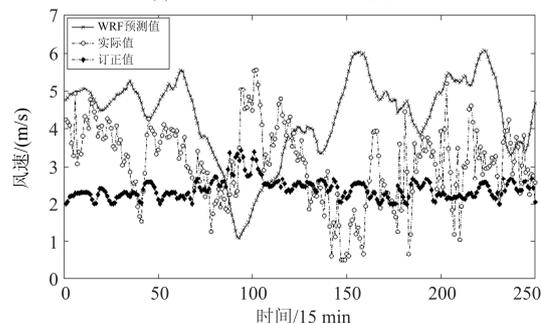
季节	rMAE/%	rRMSE/%	RMSE/(m/s)
春	21.55	26.93	1.37
夏	43.63	49.29	3.5
秋	19.68	22.15	1.65
冬	25.83	32.73	1.56

## 2.2 PSO-LSSVM 算法订正

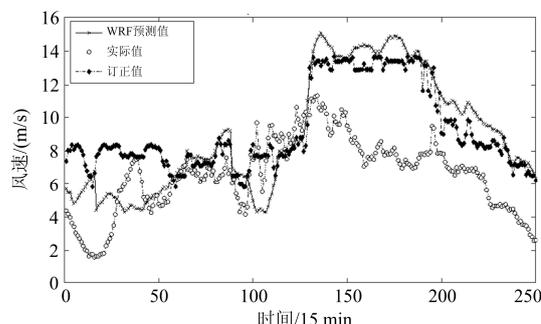
为了解决 WRF 模式预测风速存在误差的问题, 本文采用 LSSVM 算法对 WRF 模式预测的风速进行订正, 并采用 PSO 算法对 LSSVM 中的参数进行优化。以 2014 年春、夏、秋、冬四个季节中的样本数据为例, 订正后的风速序列如图 5 所示。



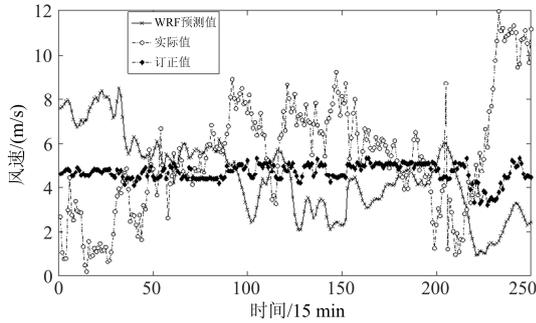
(a) 春—PSO—LSSVM 风速修正模型



(b) 夏—PSO—LSSVM 风速修正模型



(c) 秋—PSO—LSSVM 风速修正模型



(d) 冬—PSO—LSSVM风速修正模型

图5 四季风速订正对比

Fig. 5 Comparison of the revised wind speed and the observed wind speed

从图5可以看出, 经过 PSO-LSSVM 算法订正后, WRF 模式的预测风速更加接近于实测风速。误差较大的夏、冬两季, 改善效果也最明显, 春、秋两季的误差也有小幅度的下降。订正后的预测风速和实测风速之间的误差分析如表2所示。

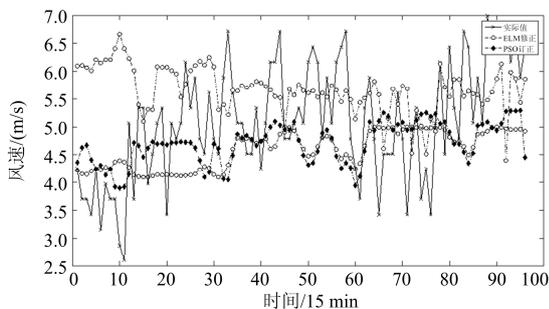
表2 订正后四个季节风速误差分析

Table 2 Wind speed error analysis of the four seasons after revised

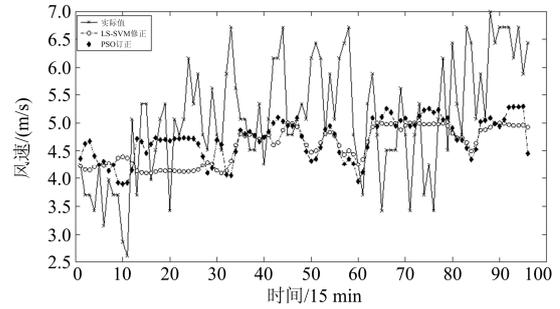
季节	rMAE/%	rRMSE/%	RMSE/(m/s)
春	17.34	21.62	1.10
夏	29.68	24.31	2.1
秋	15.98	19.46	1.45
冬	19.78	24.45	1.17

通过表1和表2的对比可以发现, 订正后的误差进一步减小。其中夏季的误差减小最多, rRMSE和rMAE均减小20%, RMSE减小1.4 m/s。春、秋、冬的订正误差也有小幅度的减小。从图5可以直观地看出, 经过 PSO-LSSVM 算法订正后, WRF 模式订正风速与实际风速更为接近, 说明了算法的有效性。

另外, 本文也采用了极限学习机(ELM)以及未经 PSO 优化的 LSSVM 对 WRF 模式的风速进行了订正。以春季为例, 订正后的风速序列如图6所示。



(a) PSO-LSSVM与ELM订正对比



(b) PSO-LSSVM与LSSVM订正对比

图6 不同算法订正比较

Fig. 6 Comparison of the different revised algorithms

通过图6可以看出, ELM 和 LSSVM 都能对 WRF 模式预测的风速进行订正。经过比较, PSO 优化后的 LSSVM 订正效果更好。三种算法的误差分析如表3所示。

表3 不同订正算法误差分析

Table 3 Error analysis of different revised algorithms

订正算法	WRF	ELM	LSSVM	PSO-LSSVM
rMAE/%	21.55	19.41	18.07	17.34
rRMSE/%	26.93	23.65	21.98	21.62
RMSE/(m/s)	1.37	1.20	1.12	1.10

由图6及表3可以看出, 订正后的风速更加接近实测风速。RMSE、rRMSE、rMAE 三种指标都有了一定程度的下降。其中, 相比于未经优化的 LSSVM 和 ELM 算法, 本文提供的 PSO-LSSVM 订正效果更好, 从而验证了该算法在风速订正上的有效性。

由于实验的风场处于季风区, 所以春、冬两季中风速的日变化量比较大, 所以使用 WRF 模式进行风速预测时, 误差较大。通过引进的智能算法进行订正后, 能减小预测的误差。如果在订正的过程中, 考虑气温和气压等其他气象要素, 订正效果可能会更好, 这也是下一步研究的内容。

### 3 总结

本文以上海某风场 2014 年全年的实测风速和同时刻 WRF 模式的预测风速作为试验资料。利用 PSO-LSSVM 对 WRF 模式预报的风速进行订正。选取春、夏、秋、冬四个季节中的 15 天数据, 以前 14 天的数据作为训练数据, 最后 1 天的数据作为测试数据, 验证了该算法在风速订正上的有效性。主要结论如下:

1) 使用 WRF 模式预测的风速与风场的实测风速较为一致, 所以用该方法进行短期风速预测是可行的。但是 WRF 模式预测的风速与实际风速之间

仍然存在着差异, 进行风电功率预测时, 需要对 WRF 模式预测的风速进行订正, 才能满足实际的需要。

2) 使用 PSO-LSSVM 算法进行订正后, WRF 模式预测的风速与实测风速更加接近, 误差指标 RMSE、rRMSE、rMAE 都有了下降。对于春、秋、冬三个季节, RMSE 下降 0.3~0.5 m/s, rRMSE 和 rMAE 下降 5%~8%。对于夏季, 由于台风天气较多, 风速变化较频繁, 所以经过订正后, 效果更为明显, 其中 RMSE 下降 1.4 m/s, rRMSE 和 rMAE 下降 20%, 订正后的风速更加接近实测风速。

3) 与 ELM 和未经 PSO 优化的 LSSVM 进行对比, 选取春季数据作为试验样本, 本文提供的 PSO-LSSVM 方法的订正效果更好。

### 参考文献

- [1] 张颖超, 郭晓杰, 叶小岭, 等. 一种短期风电功率集成预测方法[J]. 电力系统保护与控制, 2016, 44(7): 90-95.  
ZHANG Yingchao, GUO Xiaojie, YE Xiaoling, et al. An integrated forecasting method of short-term wind power[J]. Power System Protection and Control, 2016, 44(7): 90-95.
- [2] 王恺, 关少卿, 汪令祥, 等. 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[J]. 电力系统保护与控制, 2015, 43(2): 26-32.  
WANG Kai, GUAN Shaoqing, WANG Lingxiang, et al. A combined forecasting model for wind power prediction based on fuzzy information granulation and least squares support vector machine[J]. Power System Protection and Control, 2015, 43(2): 26-32.
- [3] 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.
- [4] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1: 8pp.  
DOI 10.1186/s41601-016-0016-y
- [5] YU J, ZHE S, KUSIAK A. Very short-term wind speed forecasting with Bayesian structural break model[J]. Renewable Energy, 2013, 50(3): 637-647.
- [6] 彭怀午, 杨晓峰, 刘方锐. 基于 SVM 方法的风电场短期风速预测[J]. 电网与清洁能源, 2009, 25(7): 48-52.  
PENG Huaiwu, YANG Xiaofeng, LIU Fangrui. Short-term wind speed forecasting of wind farm based on SVM method[J]. Power System and Clean Energy, 2009, 25(7): 48-52.
- [7] ZJAVKA L. Wind speed forecast correction models using polynomial neural networks[J]. Renewable Energy, 2015, 83: 998-1006.
- [8] 黄凤新, 刘寿东, 祝赢, 等. 基于滚动极值处理的 BP 神经网络方法的 WRF 模式预报风速订正[J]. 科学技术与工程, 2013, 13(7): 1768-1772.  
HUANG Fengxin, LIU Shoudong, ZHU Ying, et al. Application of BP neural network based on rolling extremal management in revising wind speed forecasting of WRF model[J]. Science Technology and Engineering, 2013, 13(7): 1768-1772.
- [9] 陈德花, 刘铭, 苏卫东, 等. BP 神经网络在 MM5 预报福建沿海大风中的释用[J]. 暴雨灾害, 2010, 29(3): 263-267.  
CHEN Dehua, LIU Ming, SU Weidong, et al. Interpretation and application of BP artificial neural network in MM5 model forecasting gale for coastal regions of Fujian Province[J]. Torrential Rain and Disasters, 2010, 29(3): 263-267.
- [10] 孔令彬, 赵艳茹, 王聚杰, 等. 基于支持向量机风速订正方法的研究[J]. 西南大学学报(自然科学版), 2014, 36(5): 194-200.  
KONG Lingbin, ZHAO Yanru, WANG Jujie, et al. Modification of wind speed based on SVM[J]. Journal of Southwest University (Natural Science Edition), 2014, 36(5): 194-200.
- [11] 朱玉祥, 黄嘉佑, 丁一汇. 统计方法在数值模式中应用的若干新进展[J]. 气象, 2016, 42(4): 456-465.  
ZHU Yuxiang, HUANG Jiayou, DING Yihui. Some new advances in application of statistical methods to numerical models[J]. Meteorological Monthly, 2016, 42(4): 456-465.
- [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] 武雪玲, 沈少青, 牛瑞卿. GIS 支持下应用 PSO-SVM 模型预测滑坡易发性[J]. 武汉大学学报(信息科学版), 2016, 41(5): 665-671.  
WU Xueling, SHEN Shaoqing, NIU Ruiqing. Landslide susceptibility prediction using GIS and PSO-SVM[J]. Geomatics and Information Science of Wuhan University, 2016, 41(5): 665-671.
- [14] DEPPE A J, GALLUS W A, TAKLE E S. A WRF ensemble for improved wind speed forecasts at turbine height[J]. Wea Forecasting, 2013, 28(1): 212-228.
- [15] 杨光焰, 吴息, 周海. WRF 模式对福建沿海风电场风速预测的效果分析[J]. 气象科学, 2014, 34(5): 530-535.  
YANG Guangyan, WU Xi, ZHOU Hai. Effect analysis of WRF on wind speed prediction at the coast wind power station of Fujian province[J]. Journal of the Meteorological Sciences, 2014, 34(5): 530-535.
- [16] 程兴宏, 陶树旺, 魏磊, 等. 基于 WRF 模式和自适应偏最小二乘回归法的风能预报试验研究[J]. 高原气象, 2012, 31(5): 1461-1469.  
CHENG Xinghong, TAO Shuwang, WEI Lei, et al. Short-term wind power forecasting experiment based on WRF model and adapting partial least square regression method[J]. Plateau Meteorology, 2012, 31(5): 1461-1469.
- [17] 刘兴杰, 岑添云, 郑文书, 等. 基于模糊粗糙集与改进聚类的神经网络风速预测[J]. 中国电机工程学报, 2014, 34(19): 3162-3169.  
LIU Xingjie, CEN Tianyun, ZHENG Wenshu, et al. Neural network wind speed prediction based on fuzzy rough set and improved clustering[J]. Proceedings of the CSEE, 2014, 34(19): 3162-3169.
- [18] VAN GESTEL T, DE BRABANTER J, DE MOOR B, et al. Least squares support vector machines[M]. Singapore: World Scientific, 2002.
- [19] 牛海清, 叶开发, 许佳, 等. 基于粒子群优化支持向量机的电缆温度计算[J]. 华南理工大学学报(自然科学版), 2016, 44(4): 77-83.  
NIU Haiqing, YE Kaifa, XU Jia, et al. Calculation of cable temperature based on support vector machine optimized by particle swarm algorithm[J]. Journal of South China University of Technology (Natural Science Edition), 2016, 44(4): 77-83.

收稿日期: 2016-11-03; 修回日期: 2017-01-24

作者简介:

叶小岭(1964—), 女, 教授, 硕士生导师, 研究方向为系统建模与最优化控制; E-mail: xyz.nim@163.com

顾荣(1993—), 男, 通信作者, 硕士研究生, 研究方向为短期风电功率预测; E-mail: 595341601@qq.com

邓华(1977—), 男, 工程师, 博士研究生, 研究方向为风电功率预测。E-mail: denghua@nuist.edu.cn

(编辑 姜新丽)