

张颖超,肖寅,邓华. 2016. 基于 ELM 的风电场短期风速订正技术研究. 气象, 42(4):466-471.

基于 ELM 的风电场短期风速订正技术研究^{*}

张颖超^{1,2,3} 肖 寅¹ 邓 华²

1 南京信息工程大学信息与控制学院, 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, 南京 210044

3 江苏省大数据分析技术重点实验室, 南京 210044

提 要: 风速预测是风电场风功率预测的基础,其准确度严重影响着风电场的运行效率。为了提高短期风速预测的准确性,本研究采用了 WRF 中尺度数值模式,对我国东部沿海某风电场的风速进行预报。在此基础上,利用极限学习机算法(ELM)对 WRF 模式预报的风速进一步订正。实验结果表明,WRF 模式对风速、风向等气象要素有着较好的回报效果,利用 ELM 算法对 WRF 模式预报风速进行订正后,预报风速的误差进一步减小,相对均方根误差和相对平均绝对误差降低了 20%~30%。与其他的智能算法(BP 神经网络、SVM 算法)对比分析后得出,ELM 算法对 WRF 模式预报风速具有较好的订正效果,能够有效提高风速预报准确率。

关键词: WRF 模式, ELM 算法, 误差订正, 预报效果

中图分类号: P412

文献标志码: A

doi: 10.7519/j.issn.1000-0526.2016.04.010

Modification Technology Research of Short-Term Wind Speed in Wind Farm Based on ELM Method

ZHANG Yingchao^{1,2,3} XIAO Yin¹ DENG Hua²

1 School of Information and Control, Nanjing University of Information Science and Technology, Nanjing 210044

2 Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters,

Nanjing University of Information Science and Technology, Nanjing 210044

3 Jiangsu Key Laboratory of Big Data Analysis Technology, Nanjing 210044

Abstract: Wind speed forecasting is the basis of wind power forecasting, and its accuracy affects the efficiency of the wind farm seriously. In order to improve the accuracy of short-term wind speed forecasting, the WRF mesoscale numerical model was used to predict the wind speed of a wind farm in the eastern coasts of China. Besides, the Extreme Learning Machine (ELM) algorithm was used for further correction. The results show that, the WRF model has a better effect on the wind speed, wind direction and other meteorological elements. After correcting the wind speed forecasting of the WRF model, with the ELM algorithm, the error of wind speed forecasting becomes smaller, and the relative root mean square error and relative mean absolute error are reduced by 20%—30%. Thus, the ELM algorithm is qualified to have better correction capability for the wind speed of WRF model forecasting compared with other intelligent algorithms (BP neural network, SVM algorithm), and can improve the accuracy of wind speed forecasting effectively.

Key words: WRF model, Extreme Learning Machine (ELM) algorithm, bias correction, prediction effect

* 江苏省高校优势学科建设工程资助项目、江苏省六大人才高峰项目(WLW-021)、江苏省研究生创新工程省立项目(SJLX_0386)和公益性行业(气象)科研专项(GYHY201106040)共同资助

2015 年 6 月 24 日收稿; 2016 年 1 月 11 日收修定稿

第一作者:张颖超,主要从事复杂系统建模与评估、灾害评估与损失预测、气象服务效益研究、风电功率预测和气象数据质量控制等研究. Email:yc.nim@163.com

引言

近年来,因人们对能源需求的不断增加,煤、石油和天然气等不可再生资源被大量开采,其储量不断减少,同时这些能源的广泛使用也带来全球气候变暖的加快和环境污染的加剧,寻求清洁可再生能源的课题日益受到人们的关注。风电作为环保清洁的可再生资源,正逐渐受到各个国家的重视。由于风速具有随机性和间歇性,必然增加风能并入电网的难度,因此准确的风功率预测日益成为人们研究的热门和重点(雷亚洲等,2002)。风速的预测是风电功率预测的基础,若能提前准确的对风电场中的风速进行预报和评估,就可以有效地解决大规模风力运行和并网的难题(张保会等,2012)。

风电场风速在时间尺度上分为超短期(未来 15 min 到 4 h 内)、短期(未来 72 h 内)、长期(数周或数月),短期风速预测的准确性有利于电力调度部门调整计划,减轻风能的并入对电网的不利影响。本文重点关注风电场短期风速的订正研究。目前,常采用 MM5、WRF 等中尺度数值模式来预报短期风速。WRF 模式使用数值天气预报资料降尺度来预报风速,预报时间更长、准确率更高(孙川永等,2009)。但由于现阶段 WRF 模式受物理参数化方案不完善、分辨率较低、地形不够精确等因素的影响,导致 WRF 模式的预报结果误差较大、预报结果具有不确定性(常俊等,2015;张宇等,2013;王益柏等,2014)。由于风能与风速的三次方成正比,较小的风速误差就可能带来较大的风电功率误差,因而有必要对 WRF 模式预报风速进行订正,进一步提高短期风速预报的准确度(方艳莹等,2012;许杨等,2013)。李茜等(2014)利用相似 Kalman 滤波法对 WRF 模式预报风速进行订正研究,结果表明对预报风速进行订正后,模式预报误差减小,预报准确率提高了。徐晶晶等(2013)利用相似误差法对 WRF 模式预报风速进行订正,减小了系统误差和随机误差,提高了短期预报的准确率;祝赢等(2013)利用线性滚动极值处理方法对 WRF 模式预报风速进行订正,结果表明采用滚动极值处理方法订正后的 WRF 模式预报风速的误差得到有效的降低,预报精度有了较大提高。这些研究表明经过了订正后的 WRF 模式预报风速精度明显提高,但在这些研究中,风速订正方法需要进行大量的实验研究,预报误差的大小取

决于各个模型建立的复杂与否。ELM 算法比传统的学习算法速度更快,数学模型简单,具有良好的泛化性能,在短期风速订正的研究中具有突出的优势。

本文利用 WRF 模式预报 70 m 高度处风速,分析预报风速与风电场风机轮毂高度 70 m 处的实际风速的误差,再利用 ELM 算法订正 WRF 模式预报风速。结果表明,该方法能够有效地减小 WRF 模式预报的误差,提高了短期风速预报的精度。

1 资料与方法

1.1 WRF 模式介绍

WRF 模式是由美国 NCAR、NOAA 联合一些大学和研究机构开发的区域中尺度数值预报模式(章国材,2004)。本文中 WRF 模式采用三重嵌套网格,网格数分别为 79×77 、 91×91 和 112×112 ,网格间距分别为 27、9 和 3 km。WRF 模式边界资料采用美国国家环境预报中心(NCEP)的全球大气环流模式 GFS 初始场资料,每 6 h 一次、分辨率为 $1^\circ \times 1^\circ$ 。模拟时段为 2014 年 1—12 月。模拟结果输出时间间隔为 15 min。模式输出要素为 70 m 处的气象数据,包括风速、风向、气温、气压及空气湿度等。

1.2 风电场及资料选取

本文以我国东部沿海某风电场为研究对象,所用资料为风电场风机轮毂高度 70 m 处的实测风速值,风速数据由 SCADA 系统采集,时间分辨率为 15 min。

以 2014 年全年的 WRF 预报风速作为实验资料,采用 ELM 订正算法逐月对 WRF 模式预报风速进行订正:从每月中随机抽取 1500 组预报风速数据,以前 1000 组数据作为训练样本建立订正模型,后 250 组数据作为检验样本检验模型,最后利用训练好的模型订正最后 250 组数据。

1.3 极限学习机(ELM)算法

极限学习机(ELM)是单隐藏层前馈神经网络(Single hidden Layer Feed forward Networks, SLFNs)中一种很有效的学习算法(Huang et al, 2006)。设 M 个不同的样本 $\{(x_i, t_i), i=1, \dots, N\}$, 其中 $x = (x_{i1}, x_{i2}, \dots, x_{im})^T \in R^n$, $t = (t_{i1}, t_{i2}, \dots,$

$t_{im}^T \in R^m$, 含有 N 个隐层神经元及激活函数为 $g(x)$ 的标准 SLFNs 数学建模可表示为:

$$\sum_{i=1}^N \beta_i g(x_j) = \sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) \quad (1)$$

$$j = 1, \dots, M$$

式中, $w_i = [w_{i1}, w_{i2}, \dots, w_{im}]^T$ 是连接第 i 层输入结点与隐层结点的权值向量; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 是连接第 i 个隐层结点与输出结点的权值向量; b_i 是第 i 层隐层结点的阈值; $(w_i \cdot x_j)$ 表示 w_i 和 x_j 的内积, 输出结点为线性结点。若含有 N 个隐层神经元及激活函数为 $g(x)$ 的标准 SLFNs 可以零误差的逼近这 M 个样本, 即网络实际输出等于期望输出, 则式(1)可以表示为:

$$\sum_{i=1}^N \beta_i g(x_j) = \sum_{i=1}^N \beta_i g(w_i \cdot x_j + b_i) = t_j \quad (2)$$

$$j = 1, \dots, M$$

以上 N 个等式可以写成:

$$H\beta = T \quad (3)$$

式中,

$$H(w_1, \dots, w_N, b_1, \dots, b_N, x_1, \dots, x_M) = \begin{bmatrix} g(w_1 x_1 + b_1) & \dots & g(w_N x_1 + b_N) \\ \vdots & \vdots & \vdots \\ g(w_1 x_M + b_1) & \dots & g(w_N x_M + b_N) \end{bmatrix}_{M \times N}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}_{N \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

H 是隐层输出矩阵, H 第 i 行代表第 i 个训练样本关于所有隐层结点的输出; H 的第 j 列代表所有训练样本关于第 j 个隐层结点的输出。ELM 学习算法过程如下:

(1) 首先确定隐含层神经元个数, 输入层与隐含层间的连接权值 w 以及隐含层神经元的偏置 b 随机赋值。

(2) 选择隐含层神经元的激活函数, 该函数必须无限可微, 进而求出 H 。

(3) 计算输出层权值 $\hat{\beta}$: $\hat{\beta} = H^+ T'$ 。

1.4 误差评价指标

本文采用了相对均方根误差 ($rRMSE$) 和相对平均绝对误差 ($rMAE$) 衡量模型的订正效果。均方根误差 ($RMSE$) 如式(4)所示, $rRMSE$ 是在原来均方根误差 ($RMSE$) 的基础上除以观测的平均值, 表示均方根误差占实际观测的百分率, 这种衡量指标

更加客观评价了一个序列变化产生误差的相对大小, 如式(5)所示。 $rMAE$ 是平均绝对误差除以平均观测值, 如式(6)所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [\hat{x}_k(i) - x_k(i)]^2} \quad (4)$$

$$rRMSE = \left\{ \sqrt{\frac{1}{N} \sum_{i=1}^N [\hat{x}_k(i) - x_k(i)]^2} \left/ \left[\frac{1}{N} \sum_{i=1}^N x_k(i) \right] \right\} \times 100\% \quad (5)$$

$$rMAE =$$

$$\left\{ \frac{1}{N} \sum_{i=1}^N |\hat{x}_k(i) - x_k(i)| \left/ \left[\frac{1}{N} \sum_{i=1}^N x_k(i) \right] \right\} \times 100\% \quad (6)$$

式中, N 表示样本序列的长度, $\hat{x}_k(i)$ 是第 i 个样本的预测值, $x_k(i)$ 是第 i 个样本的观测值。

2 基于 WRF 模式的风速预报和订正

2.1 风速频率分布和风向玫瑰图

该风电场 2014 年全年测风塔 70 m 处风速数据和风速频率分布如图 1 所示。从图 1 可知, 风速主要集中在 $3 \sim 10 \text{ m} \cdot \text{s}^{-1}$, 风能分布较为集中。风电场四个季度的风向玫瑰图如图 2 所示。图 2a 表示春季的风向, 主风向为 E; 图 2b 表示夏季, 主风向为 NNE; 图 2c 代表秋季, 方向多分布在 WNW 和 ESE; 图 2d 代表冬季, 主风向为 NW。相比春、夏季, 秋和冬季的风向变化幅度较大, 各个方位的风向所占比例都较大, 但总体上, 四个季节的风向都相对较集中在主风向上。由图 1、图 2 可知该风电场风向较为稳定, 风能分布集中, 适合风力发电。

图 3 为 2014 年测风塔与 WRF 模式预报风向

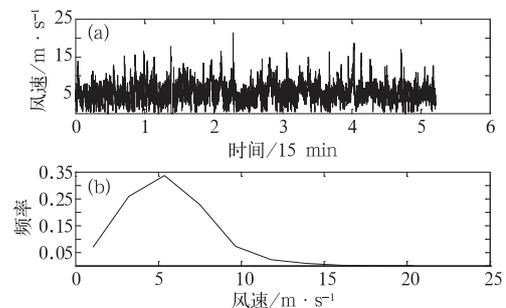


图 1 全年风速数据(a)和风速频率(b)分布
Fig. 1 Annual wind speed data (a) and frequency distribution of wind speed (b)

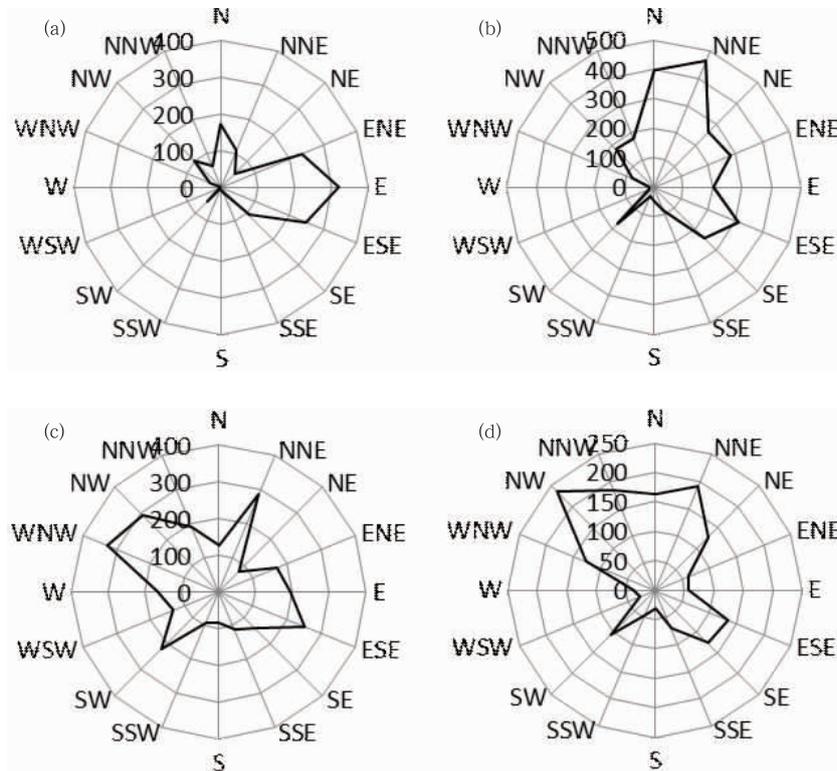


图 2 春(a)、夏(b)、秋(c)和冬(d)四个季度的风向分布
Fig. 2 Wind statistics of the four seasons of spring (a), summer (b), autumn (c), winter (d)

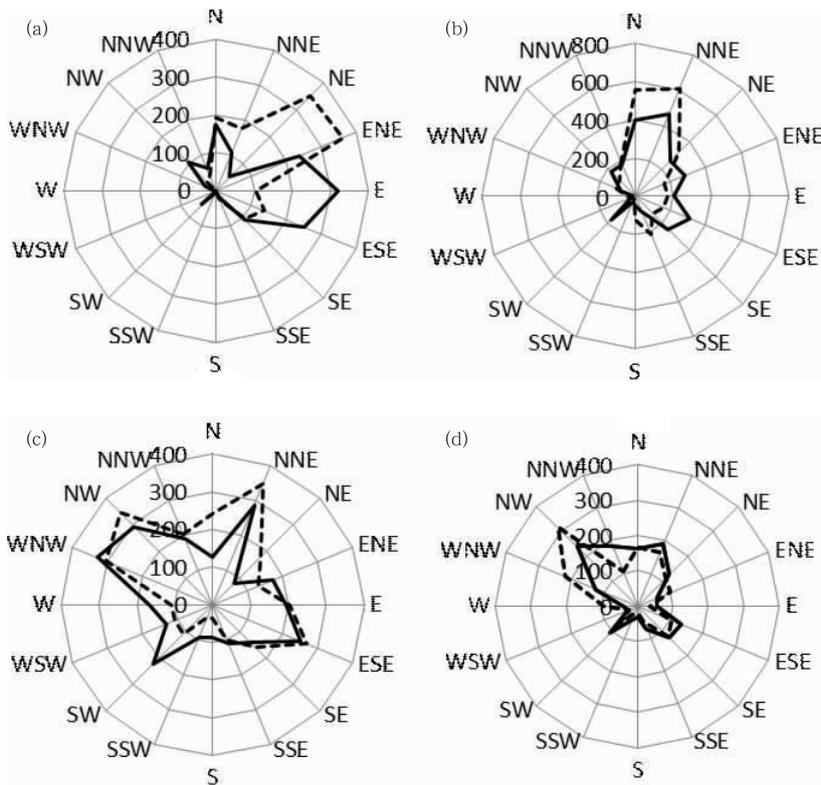


图 3 春(a)、夏(b)、秋(c)和冬(d)四个季度的预测(虚线)与实测(实线)风向玫瑰图比较
Fig. 3 Comparison of wind rose diagram between prediction (dotted line) and observed (solid line) of the four seasons of spring (a), summer (b), autumn (c), winter (d)

玫瑰图的比较,图 3a~3d 分别代表春、夏、秋、冬四个季节。从图 3 中可知,除了春季 WRF 模式预报主风向略有偏差;夏、秋、冬三季的 WRF 模式预报风向与测风塔实测的风向有较好的一致性,风向概率分布相似,盛行风向一致,风频大小接近,说明 WRF 模式预报数据能较好地反映风速、风向等特征,利用 WRF 模式预报风电场短期风速是可行的。

2.2 WRF 模式预报风速误差分析

表 1 为 2014 年 12 个月的 WRF 模式预报风速与测风塔风速(70 m 处)的误差分析。从表 1 中可以看出,WRF 模式预报风速的 $rRMSE$ 在 30%~50%,误差最小的为 7 月,值为 34.06%,误差最大的为 9 月,值为 48.60%,各个月的相对均方根误差都较高。也导致了全年的平均 $RMSE$ 为 $3.55 \text{ m} \cdot \text{s}^{-1}$, $rRMSE$ 为 42.84%, $rMAE$ 为 33.20%。由此可知,WRF 模式预报风速相比测风塔实测风速的误差较大。因此,仅仅依靠 WRF 模式预报出的风速来预测风能是不够的,有必要采用一些智能算法对 WRF 模式预报风速订正,可以进一步提高 WRF 模式预报风速的准确率。

表 1 12 个月风速的误差分析

Table 1 Wind speed error analysis of the twelve months

月份	$RMSE$ / $\text{m} \cdot \text{s}^{-1}$	$rRMSE$ /%	$rMAE$ /%
1 月	2.52	41.91	32.83
2 月	2.48	45.82	33.58
3 月	2.20	48.43	39.46
4 月	3.73	43.93	35.75
5 月	4.19	42.28	34.43
6 月	4.10	40.92	30.75
7 月	4.90	34.06	20.91
8 月	5.29	40.20	36.15
9 月	3.98	48.60	31.91
10 月	3.30	43.70	33.13
11 月	2.96	40.32	35.60
12 月	2.97	43.91	33.89
全年	3.55	42.84	33.20

2.3 ELM 算法订正

为了解决 WRF 模式预报风速误差较大的问题,本文利用极限学习机(ELM)算法对 WRF 模式预报风速进行订正。表 2 为经过 ELM 算法订正后各个月份 WRF 模式预报风速与测风塔实测风速的误差比较, $RMSE$ 在 $1.8 \sim 3.3 \text{ m} \cdot \text{s}^{-1}$,全年平均 $RMSE$ 为 $2.42 \text{ m} \cdot \text{s}^{-1}$; $rRMSE$ 在 14%~24%,全

年平均 $rRMSE$ 为 18.74%; $rMAE$ 在 10%~20%,全年平均 $rMAE$ 为 14.61%。与表 1 相比,经过 ELM 算法订正后的 12 个月的 $rRMSE$ 和 $rMAE$ 均明显减小,均降低了 20%~30%,全年平均 $RMSE$ 减小了 $1.13 \text{ m} \cdot \text{s}^{-1}$ 。但各个月的订正结果也有着差异。春和秋季中,有两个月的 $rRMSE$ 大于 20%,其余月的 $rRMSE$ 均小于 20%。总体上来说,ELM 算法对 WRF 模式预报风速进行订正提高了风速的预报能力,减小了模式的系统误差和随机误差,提高了预测风速的精度。

表 2 订正风速与实际风速的误差比较

Table 2 The error comparison of the revised wind speed and the observed wind speed

误差	$RMSE$ / $\text{m} \cdot \text{s}^{-1}$	$rRMSE$ /%	$rMAE$ /%
1 月	1.83	18.20	14.34
2 月	1.96	16.51	12.39
3 月	2.00	21.38	19.61
4 月	2.46	19.13	14.18
5 月	2.55	18.46	13.70
6 月	2.72	14.63	10.16
7 月	3.24	18.90	14.53
8 月	3.30	17.88	14.49
9 月	2.31	18.56	14.87
10 月	2.61	20.00	16.18
11 月	2.11	23.80	17.12
12 月	1.96	17.43	13.78
全年	2.42	18.74	14.61

另外,本文也采用 BP 神经网络方法和 SVM 算法对 WRF 模式预报风速进行了订正,将 ELM 算法与 SVM 算法、BP 神经网络算法的订正结果进行了比较,结果如图 4 所示。从图 4 中可以看出,通过 SVM、BP、ELM 算法对 WRF 模式预报风速订正,订正后的各月平均风速更接近于测风塔实测同期风

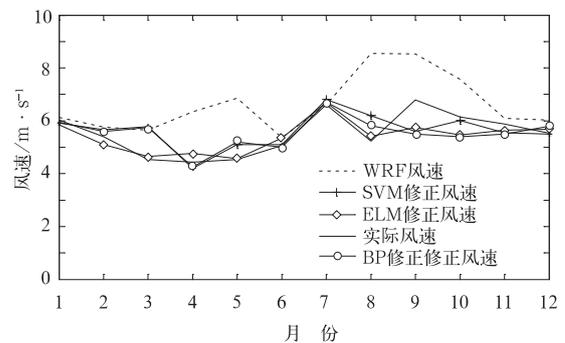


图 4 不同模型的订正风速分布

Fig. 4 The distribution of revised wind speeds of different models

速。因此,用 WRF 模式进行短期风速预测时,必须要进一步订正,才能得到更准确的风速,从而提高短期预测的精度。同时,与 SVM、BP 相比,ELM 订正后的风速更接近实测风速。

表 3 列出了不同订正算法对 WRF 模式预报风速订正结果的年均误差比较。从表 3 中可以看出,ELM 算法订正后的年均 $RMSE$ 、 $rRMSE$ 和 $rMAE$ 相比 BP 神经网络、SVM 订正结果小,ELM 算法在短期风速订正中的精度比其他算法高,说明该算法的订正效果优于其他智能算法,同时对全年 WRF 模式预报风速进行训练时,ELM 算法较其他算法训练速度快,具有良好的泛化性能,从而验证了 ELM 算法的高效性。

表 3 三种订正算法的年均误差比较
Table 3 Comparison of the three revised algorithms annual error

订正算法	ELM 算法	BP 神经网络算法	SVM 算法
$RMSE$ $/m \cdot s^{-1}$	2.42	2.73	2.78
$rRMSE/\%$	18.74	25.44	23.51
$rMAE/\%$	14.61	20.17	19.76

3 结 论

本文以我国东部沿海某风电场风机轮毂高度 70 m 处的 2014 年全年实测风速与同时刻 WRF 模式预报风速数据(70 m 处)为实验资料,利用极限学习机(ELM)方法对 WRF 模式预报风速进行订正研究。主要结论如下:

(1) WRF 模式对风速、风向等气象要素有着较好的预报效果,用于预报风电场短期风速是可行的。

(2) 用 WRF 模式进行短期风速预测时,必须要进一步订正,才能得到更准确的风速,从而提高短期风功率预测的精度。

(3) 使用 ELM 算法对 WRF 模式预报风速进

行订正,订正后的 WRF 预报风速相对均方根误差和相对平均绝对误差降低了 20%~30%,经过订正后的预报风速更趋近于实测风速,预报精度明显提高,说明利用 ELM 算法对预报风速进行订正可有效减小模式的系统误差和随机误差,能够提高风速预测的准确率。

(4) 相比其他的智能算法(BP 神经网络、SVM 算法),ELM 算法在风速修正中的精度比其他的算法高,训练速度快,具有良好的泛化性能。ELM 算法在风速订正研究中具有突出的优势。

参考文献

- 常俊,彭新东,范广洲,等. 2015. 结合历史资料的数值天气预报误差订正. 气象学报,73(2):341-354.
- 方艳莹,徐海明,朱蓉,等. 2012. 基于 WRF 和 CFD 软件结合的风能资源数值模拟试验研究. 气象,38(11):1378-1389.
- 雷亚洲,王伟胜,戴慧珠. 2002. 风电对电力系统运行的价值分析. 电网技术,26(5):10-14.
- 李茜,孙娴,程路. 2014. 基于 WRF 模式与相似 Kalman 滤波法订正后的风速预报效果分析. 水电能源科学,32(6):197-201.
- 孙川永,陶树旺,罗勇,等. 2009. 高分辨率中尺度数值模式在风电场风速预报中的应用. 太阳能学报,30(8):1097-1099.
- 王益柏,梅娜,范磊,等. 2014. WRF 模式对 2013 年 1 月华北一次大雾的数值对比试验. 气象,40(12):1522-1529.
- 徐晶晶,胡非,肖子牛,等. 2013. 风能模式预报的相似误差订正. 应用气象学报,24(6):731-740.
- 许杨,陈正洪,杨宏青,等. 2013. 风电场风电功率短期预报方法比较. 应用气象学报,24(5):625-630.
- 张保会,李光辉,王进. 2012. 风电接入电力系统故障电流的影响因素分析及对继电保护的影响. 电力自动化设备,32(2):1-8.
- 章国材. 2004. 美国 WRF 模式的进展和应用前景. 气象,30(12):27-31.
- 张宇,郭振海,林一骅,等. 2013. 中尺度模式风电场风速短期预报能力研究. 大气科学,37(4):955-962.
- 祝赢,柳艳香,程兴宏,等. 2013. 线性滚动极值处理方法对数值模拟风速的订正研究. 热带气象学报,29(4):681-686.
- Huang G B, Zhu Q Y, Siew C K. 2006. Extreme learning machine: Theory and applications. Neural Computation,70:489-501.