

陈学君,李仲龙.超短期风速预报方法研究进展[J].沙漠与绿洲气象,2018,12(6):84-92.

doi:10.12057/j.issn.1002-0799.2018.06.011

超短期风速预报方法研究进展

陈学君¹,李仲龙²

(1.甘肃省气象服务中心,甘肃 兰州730020;2. 甘肃省气象信息与技术装备保障中心,甘肃 兰州730020)

摘要:综合分析国内外风速预报相关文献,从物理方法、统计与机器学习方法、组合方法3个方面对超短期风速预报方法的研究现状进行归纳总结,对比了主要预报方法的优缺点,给出了不确定分析和误差评价指标,探讨了在超短期风速预报研究中应重点解决的问题和发展方向。

关键词:超短期风速预报;物理方法;统计与机器学习方法;组合方法;不确定分析与误差评估

中图分类号:P456.1

文献标识码:A

文章编号:1002-0799(2018)06-0084-09

由于传统化石能源的短缺和造成环境污染,绿色能源成为各国政府的发展方向。风能是洁净的可再生能源,分布广泛。近年来在国家可再生能源法、节能减排的政策引导下,风力发电发展迅猛。按世界风能协会统计^[1],2016年全球风电新增装机容量达到54.6 GW,全球风电总装机容量为487 GW。截止2016年中国风电总装机容量为23.3 GW,约占全球风电市场份额的42.7%,是世界上风电装机容量最多、发展最迅速的国家。

风电在快速发展的同时也面临突出问题。由于风速受观测地的温度、气压、海拔、地形、纬度等诸多因素影响,具有随机性、间歇性、波动性特点,成为最难预测的气象要素之一,但它也是风功率预测中最关键的要素^[2,3]。风速预报从时间尺度上^[4]分为超短期、短期、中期、长期预报(表1)。超短期风速预报是指未来0~4 h风速预报,时间分辨率在1 h以内。在开放电力市场环境下,超短期风速预报是风电竞价交易的前提条件,其预报的准确性对实时电力系统调度、风电场的利用效率具有重要的现实意义。

准确预报风速需要科学的预测理论和模型,为此国内外学者进行了广泛的探索并提出多种预测方法^[5-7]。按照不同的建模机理,超短期风速预报可分

表1 基于时间尺度的风速预报分类

时间尺度	范围	应用
超短期	0~4 h,时间分辨率为10~15 min	风电的实时调度
短期	0~3 d,时间分辨率为15 min	机组组合和备用安排、日前电力市场调度安全
中期	超前3~7 d,时间分辨率为1 h	检修安排
长期	超前1周以上,时间分辨率为1~24 h	资源评测、调度管理等

注:预测尺度的间隔并非严格定义

为物理模型^[8]、统计与机器学习模型^[9]、组合模型^[10]等。

1 常用预报方法及其特点

1.1 物理方法

风速预报的物理方法包括一系列的微观气象学模型^[11],这些模型利用温度分层、等高线、粗糙度、地形模型^[12,13]模拟局地效应,将NWP(Numerical Weather Prediction)预测的风速、风向、温度、气压、湿度等气象数据转换成风电场的风速。

物理方法的关键为NWP。NWP根据大气流体特点,设定边界和初值,利用高性能计算机获得大气的热力学、流体力学方程组的数值解,预报未来时段的风速和其他气象要素。文献[14]中对常用的NWP模型进行说明。全球尺度的NWP相对于风电场来说太大了,一般采用中尺度模式。

收稿日期:2018-05-17;修回日期:2018-06-27

基金项目:甘肃省自然科学基金“超短期风速预测方法研究”(项目编号:1506RJZA187)甘肃省科技计划资助。

作者简介:陈学君(1973-),男,高级工程师,主要从事新能源气象与预测算法研究。E-mail: xuejunchen1971@163.com

由于混沌效应,NWP对初值非常敏感,一般利用2种NWP集合模型处理。一是使用多类NWP模型预报再使用加权平均得到预报结果,二是微调初始条件得到一组预报结果,再通过加权产生集合NWP预报。Zhao等^[15]采用3种不同空间分辨率、4种不同边界条件的WRF(Weather Research and Forecasting Mode)模式,认为相对单个NWP模型,集合模型精度提高35%左右。

物理模型主要采用类似计算流体力学CDF(Computational Fluid Dynamics)的微观气象学模型模拟大气,虽然存在许多CDF模式,但它们均采用相同的物理学原理,其主要区别为格点的结构、尺度和数值解法。冯双磊等^[16]利用地层、粗糙度、尾流模型将NWP数据转化为风机轮毂风速。马文通等^[17]采用中尺度数值预报模式输出结果驱动CDF模式运算动力降尺度的方法,得到精细化的复杂地形风电场风速预报和风电功率预报,业务试验表明基本满足电网预测误差和时效性要求。

物理方法利用大气动力、热力方程组可以精确描述风的规律,但忽略了历史数据中有用的信息,同时由于模式包含的不同参数化方案,使得其在风速预报中仍然存在一些困难。另外,针对特定风电场所建立的物理预报模型存在局限性,只能用于单个风电场或者理论研究,应用到其他风电场还需要重新进行建模。

1.2 统计与机器学习方法

统计与机器学习模型主要利用风电场和周围风电场历史数据、NWP数据学习风速特征、构建预报模型对未来风速进行预测,主要方法有持续法、时间序列预报法、人工神经网络、支持向量机和卡尔曼滤波等。

1.2.1 持续法

持续法将当前时刻的风速作为下一时刻的最优预报值。它假定当前时刻的值为下一时刻的最好预报值,在预报间隔不超过15 min的情况下,其预报精度可能超出原理复杂的机器学习方法,但对于时间超过半小时的预报效果非常差,仅作为一种基准方法验证其他方法的预报性能。

1.2.2 时间序列预报法

时间序列法利用历史风速序列建模,经过模型识别、参数估计、模型检验确定数学模型,主要有自回归、滑动平均、自回归滑动平均等模型^[18]。

时间序列建模的核心在于模型阶数和系数确定。常用的模型选择准则有赤池信息法AIC

(Akaike information criterion)和施瓦兹贝叶斯法SBC(Schwartz Bayesian criterion)。在选择模型时,AIC与SBC越小越好。

Nfaoui等^[19]利用历史小时风速进行时间序列建模,通过模型阶数比较认为模型表现高度依赖于模型参数。在经典时间序列预测的基础上,Liu等、Qin等^[20,21]利用小波分解的ARIMA(Autoregressive Integrated Moving Average Model)模型预测后重新聚合获得结果,与经典时间序列、人工神经网络模型相比预测效果更佳。Peng等^[22]将ARIMA和残差的自回归条件异方差模型ARCH(Autoregressive Conditional Heteroscedastic)结合使用小波分解的风速子时间序列展开预报,结果显示该方法减小误差5%左右。为了应对风速的非正态,Zhang等^[23]先将风速数据变换为标准化的高斯分布,其次用AR模型预报,模型应用到香港某风电场证明有效。Erdem等^[24]采用四种方法将ARMA模型用于风速和风向预报。第一种方法将风速分解为纬向、经向,分别用ARMA模型预报,结果合成为风速、风向;第二种方法用两个非独立ARMA模型预报,其中传统ARMA模型预报风速,链接ARMA模型预报风向;第三种方法用向量自回归模型VAR(Vector Autoregression)预报风速、风向;第四种方法用门限向量自回归模型预报风速、风向,对比结果显示在风向预报中第一种方法优于第二种方法,而风速预报则正好相反;向量自回归模型的风向预报好于单变量模型,而风速预报则不明显;向量自回归模型与门限向量自回归模型预报效果差别不大。Kavasseri等^[25]利用分数差分自回归求和移动平均模型对风速建模,在48 h预报尺度上的准确率与持续法相比有显著提高。

1.2.3 人工神经网络

人工神经网络ANN(Artificial Neural network)具有很强识别非线性特征^[26]的能力,很早用于风速预报。人工神经网络分为静态、动态神经网络两类。静态神经网络是指没有反馈、延迟的网络,输出由输入通过隐藏层处理后产生,反向传播BP^[27,28](Backpropagation Algorithm)、径向基RBF^[29](Radial Basis Function)、极限学习机ELM(Extreme Learning Machine)等网络均属此类。而动态神经网络的输出不仅依靠当前输入,而且依赖以前的输入、输出或者网络的状态,时间序列神经网络则是此类的典型。目前在风电预报领域的ANN将遗传算法、粒子群算法、模糊逻辑、小波分析与人工神经网络结合而形成的混合智能系统HIS(hybrid intelligent systems)^[30],

由于其优良的预报效果而大受欢迎。Ata^[31]比较不同结构 ANN 模型在风速预报中的应用,认为没有一种 ANN 模型能够适用各种情况下的风速预报,应当针对具体特征选择合适的模型。Li 等^[32]采用自适应线性神经网络、前馈反向传播网络、径向基函数神经网络 3 种 ANN 对美国两个风电场建模,发现同一数据用于不同类型的神经网络对预报结果的影响非常大,差距最大可达 20%。Peri 等^[33]用小波技术、相似日方法、情感神经网络集合预报短期风速与功率。Senkal 等^[34]对风速预报中比较 BP 神经网络、小波神经网络性能显示小波神经网络误差小。Jyothi 等^[35]采用自适应小波神经网络、自适应神经模糊推理系统、时间序列神经网络 3 类不同 ANN 对风速进行预报对比显示混合自适应小波神经网络性能最优。在风速预报模型中除了考虑风要素外,Filik 等^[36]认为还应将气压、温度等相关气象要素纳入模型。

1.2.4 支持向量机

在统计学习的 VC 维 (Vapnik -Chervonenkis Dimension)理论、结构风险最小原则的基础上发展起来的 SVM(Support Vector Machine)由 Vapnik^[37]提出,具有良好的非线性建模能力。此方法避免了传统统计模型容易陷入局部最优,具有全局优化、训练时间短和泛化能力强等优点,在风速预报^[38]中得到广泛应用。Mohandes 等^[39]比较 SVM、多层感知器神经网络两类模型用于沙特阿拉伯麦地那风速预报,显示 SVM 明显优于多层感知器。Hu 等^[40]建议用贝叶斯理论对传统 SVM 损失函数进行修改提高 SVM 预测性能。Kong 等^[41]先用主成分分析进行变量选择,其次用粒子群算法对简化支持向量机参数优化,实验表明方法有效。

1.2.5 卡尔曼滤波

卡尔曼滤波 (Kalman Filter) 算法利用状态方程、量测方程组成线性随机系统的状态空间模型来描述滤波器,对状态变量作出最佳估计。该算法可以将两种预测机理相差较大的方法融合,有效补偿同类预报方法所引起的类似误差累积从而改善预报性能。目前,卡尔曼滤波方法在风速预报研究中倾向于与其他方法相结合。潘迪夫等^[42]将经典时间序列和卡尔曼滤波结合用于风速预报,实例表明算法有效提高了预测精度。Shukur 等^[43]以马来西亚和伊朗风速数据为例用时间序列模型确定卡尔曼滤波-人工神经网络模型输入结构,案例显示与单独的卡尔曼滤波、人工神经网络相比误差降低 10%以上。修春波等^[44]建立了迟滞神经网络,将卡尔曼滤波与

ARMA 模型融合实现风速的混合预报,仿真结果说明迟滞神经网络的预报性能优于传统神经网络,而组合预报性能优于单一预测。Chen 等^[45]将无迹卡尔曼滤波、支持向量机结合用于风速预报,实验表明该方法优于单独人工神经网络、支持向量机、时间序列 AR 模型、卡尔曼滤波 AR 模型。

1.3 组合方法

为了进一步提高预报准确率,利用单一预报模型各自优点,组合模型^[5]被提出。由于相对于单个模型,组合预报模型精度明显提高因而大受欢迎。一般说来,组合方法需要许多基础预报模型经过组合后得到预报结果。Ye 等^[6]将组合预报分为协作型组合、竞争型组合两类。(图 1)。




图1 风速预报组合方法框架

1.3.1 协作型组合

协作型组合将一个预报问题分解成多个子问题,对于每个子问题分别预报,综合所有子问题的预报结果获得最终预报,各子问题间的关系为协作,具体通过预处理、后处理两种方式实现。

基于预处理的协作型组合将输入数据分解成一系列子数据集分别建模、预报,子预报模型输出代数和为最终预报。在风速预报中,一般用小波分解 WA (Wavelet Decomposition)^[46]、经验模态分解 EMD (Empirical Mode Decomposition)^[47] 等算法实现信息去噪与数据集分解。步骤如下:

假设输入数据集,分解算法分解为 $x_{d1}, x_{d2}, \dots, x_{dN}$, 分别为 N 个分量建立预报模型,标记为:

$$\hat{F}_{d_i}(t+h) = \sum_{i=1}^n f(x_{d_i}(t)), i=1, 2, \dots, N \quad (1)$$

这里 $\hat{F}_{d_i}$ 为输入数据预报结果, t 为预报当前时刻, h 为预报步长, f 为预报模型。组合预报为 $\hat{F}$, 即:

$$\hat{F}(t+h) = \sum_{i=1}^n \hat{F}_{d_i}(t+h) = \sum_{i=1}^n f(x_{d_i}(t)), i=1, 2, \dots, N \quad (2)$$

Chen 等^[48]用 EEMD (Ensemble Empirical Mode Decomposition) 对数据去噪,使用非线性自回归神经网络进行风速预报,实验显示模型误差降低约

10%。作为数据预处理的另外一种方式,Chen 等^[49]利用小波、汉明滤波对风速剔除异常值和去噪,用布谷鸟优化算法对 SVC 参数优化,案例验证模型有效。而 Kitajima 等^[50]提出将风速信息当做复数处理,利用复值神经网络预报,用日本气象部门风速资料进行验证,认为复值神经网络模型优于实值神经网络。另外,为了增加数据源,Jiang 等^[51]用灰色关联分析将相邻测风塔数据作为训练数据进行风速预报。

基于后处理的协作型组合将预报数据分解为线性、非线性两部分,其中线性部分常使用 ARMA 模型,非线性部分则采用 GARCH、ANN、SVM 等。假设输入数据集 x ,建立线性模型 $f(\cdot)$,预报值标记为

$$\hat{l}(t)=f(x(t)). \quad (3)$$

则 $e(t)=x(t)-\hat{l}(t)$ 是线性预报的非线性残差,对其建立非线性模型

$$\hat{n}(t)=g(e(t)). \quad (4)$$

其中 $g(\cdot)$ 是非线性模型,则组合预报表示为:

$$\hat{f}(t)=\hat{l}(t)+\hat{n}(t), \quad (5)$$

即线性、非线性部分代数和。

Shi 等^[52]提出 ARIMA-ANN、ARIMA-SVM 两种组合模型,其中风速线性部分用 ARIMA 预报,非线性部分分别用 ANN、SVM 预报,最终预报结果为两部分相加。与单个 ARIMA、ANN、SVM 模型相比,组合模型的均方根误差和平均绝对误差减小 5.5% 以上。而 Lojowska 等^[53]先将风速序列差分、威布尔拟合转换为平稳、正态序列,接着构建 ARIMA-GARCH 组合模型进行预报。Ji 等^[54]采用两类支持向量机组合预报模型实现风速预报,其中回归支持向量机预报风速,分类支持向量机分类训练预报误差,预报结果用估计的误差实现修正,案例验证相对于常规支持向量机可获得更小的均方根误差。

1.3.2 竞争型组合

与协作型组合相反,竞争型组合通过数据多样性、参数多样性、模型多样性建立多个基础预报模型体现竞争,趋向于选取性能好的成员。也称该方法为多模型组合预报。

参数多样性组合利用不同的参数向量生成多个类似基础模型,其中每个模型有相同输入。如在天气、气候预测中利用扰动理论的集合预报^[55,56]。设输入数据为 x ,对于同类模型建立不同的参数向量 $\theta_1, \theta_2, \dots, \theta_N$,组成模型组,最终预报值 $\hat{f}$ 为:

$$\hat{f}(t+h)=\frac{1}{N} \sum_{i=1}^n f_i(x(t), \theta_i), i=1, 2, \dots, N \quad (6)$$

式中 t 为当前时刻, h 为预报步长, f 为预报模型。

模型多样性组合对相同的输入数据集 x , 选择不同的预报模型 $f_1(\cdot), f_2(\cdot), f_N(\cdot)$ 。最终预报值 $\hat{f}$ 表示为

$$\hat{f}(t+h)=\sum_{i=1}^n \omega_i f_i(x(t)), i=1, 2, \dots, N \quad (7)$$

式中 t 为当前时刻, h 为预报步长, ω 为权值。 ω 范围为 $[-2, 2]$ 之间,权值和等于 1^[57]。即

$$\sum_{i=1}^n \omega_i=1 \quad \omega_i \geq 1, i=1, 2, \dots, N \quad (8)$$

其中基本模型 $f_1(\cdot), f_2(\cdot), \dots, f_N(\cdot)$ 类型众多,一般有时间序列、ANN、SVM 等^[58]。

数据多样性组合有多个输入数据集 $x_1, x_2, \dots, x_N$ 。最终预报值 $\hat{f}$ 为

$$\hat{f}(t+h)=\sum_{i=1}^n \omega_i f_i(x_i(t)), i=1, 2, \dots, N \quad (9)$$

或

$$\hat{f}(t+h)=f(x_1(t), x_2(t), \dots, x_N(t)), i=1, 2, \dots, N \quad (10)$$

式中 t 为当前时刻, h 为预报步长, ω 为权值。两个公式分别表示两类多输入集合预报方法, $f_1(\cdot), f_2(\cdot), \dots, f_N(\cdot)$ 分别表示不同类型的模型, $f(\cdot)$ 表示同一模型。

统计学中的 Bagging 和 Boosting^[59,60]均实现了数据的多样性。Wu 等^[59]将 Adaboost 提升算法引入前馈神经网络(BP)完成风速预测。

1.4 三类方法优缺点

在风速预报研究中无论是物理方法、统计与机器学习方法还是不同的组合预报方法都存在一定的局限性,其优缺点如表 2 所示。Treiber 等^[61]采用集合 NWP 方法、统计方法对德国气象站数据进行风速预测,认为大多数情况下的统计与机器学习方法能在超短期、长期预测中提供一个较好的结果,而在短期、中期的预测水平中,大气动力学的影响变得非常重要,在这些情况下,使用物理方法是必不可少的。

近年来一些风速预报模型已经被研发出来,并在特定的站点表现出不错的精度。然而,由于风速预报的不确定性很难得出哪个模型是最好的,因为每个模型在使用中都具有优缺点和显著的站点依赖性。因此,预报模型在一个站点的表现并不能保证该模型将在另一个站点也能很好的应用。

表2 不同风速预报方法优缺点

类别	优点	缺点	方法个例	个例优点	个例缺点
统计与机器学习方法	适用范围广,建模过程费时少	需要大量历史数据,缺乏对特殊天气过程的识别,主要依赖历史数据	时间序列方法 (ARIMA, ARCH)	模型假设和结构简单,自适应程度高	外推效果差,预测范围小
			神经网络方法 (BP, RBF)	拟合效果好,具有非线性性质	稳定性差,数据依赖程度高
			人工智能优化算法 (遗传算法, 粒子群算法)	仿真方法较容易理解,易与其他方法结合	容易陷入局部极值
			模糊及支持向量机方法	容错能力强,不需要精确数学模型,人机交互简单	精确程度低,缺乏系统性,核函数选择、参数优化难度大
			卡尔曼滤波	递推结构,线性方法,不依赖历史数据,可以将两种不同预测机理的方法融合	需要系统的历史状态
物理方法	对天气过程预报技巧高,中长期预报效果好	初始场信息敏感,随着分辨率提高,空分率要大量消耗资源,不同地区需要分别建模	频域方法	不会损失原始信号精度	动态特性较差
			中尺度数值模式 (MM5, WRF)	模拟准确,有大量可选择的参数化方案	适合天气预测,未对风能预报做专门优化
			计算流体力学方法 (CFD)	并行效率高,提供二次开发接口	需要大量观测数据,模拟范围有限
			物理模式 (Prediktor)	能够预报空间特性	依赖数值天气预报,计算成本高
组合方法	鲁棒性好,模型风险小,应用范围广	建模过程复杂,难度大,需要掌握相关知识	风能预报系统 (Ewind, ANEMOS)	技术成熟,适合极端天气	不易与其他方法结合
			混合算法 (WRF-BP)	适应性较好,结合不同模型优点	建模过程复杂,难度大

2 不确定分析与预测误差

2.1 不确定分析

不确定分析使用多种可能情况反映风险和预测错误,通常可以用损失函数来描述。一般采用概率方式、风险指数和情景产生^[62]三种方法实现模型的不确定分析^[63]。

在概率方式中用分位数、区间预测、概率密度函数、概率累计分布函数等概率估计表征未来的不确定。而参数化、非参数化的概率区间预报可以实现上述目标。利用预先定义的误差分布(如高斯分布^[64]),参数化方法可以轻易获得区间预报。此种方法特点为:计算量小,但实际应用中设定的误差分布可能不合理。与参数化方法相比,非参数化方法不需要点预

报的先验信息和误差分布假定,能够真实反应预报的不确定性。主要有中位数回归 QR (Quartile Regression)^[65]、核密度估计 KDE (Kernel Density Estimation)^[66]等方法实现区间预报。沈培等^[67]用 RBF 构建预报区间,按照残差估计预报区间的上下界,用覆盖概率、区间宽度综合准则为目标函数更新权值。

风险指数与预报方法无关,通常用气象风险指数 MRI (Meteo-Risk Index)、归一化的预测风险指数 NPRI (Normalized Prediction Risk Index) 提供期望误差的先验信息。对于风电场而言,风险指数提供最简单和最直观的不确定信息,它用一个实数确定预测风险。气象风险指数定义为反应大气系统的稳定程度、描述 MRI 与预测误差的线性关系。指数代表多个 NWP 结果的偏离程度,大的偏离意味着不稳定的天气状况条件。同时, MRI 也可以作为在线的天气风险预警工具。

情景模拟方法意味着每个时刻产生一系列电网调度的情况,称之为不同的情景。实际上,确定性预报假定产生最可能的情景,情景产生意味着产生一系列预测情景刻画风险和预测误差,它能有效地描述随着时间的流逝预报不确定性的发展,能够帮助风能调度者持续和不间断的决策。大量的情景代表实际的情况可能性更大,然而很自然的产生模型的冗余进而影响计算和决策的效率,因此如何选择最具有代表性的情景、减少情景维度是未来研究的方向。

2.2 常用预测误差指标及其特点

为了度量预报模型的优劣,预报误差被提出,其定义为预报值和实际值间的差异。目前行业标准在模型的评价中主要有平均绝对误差 MAE (Mean Absolute Error)、均方根误差 RMSE (Root Mean Square Error)、平均偏差、平均方差、误差频率分布直方图、相关系数、平均绝对百分比误差、判决系数、标准误差偏差、归一化的平均绝对误差、归一化的均方根误差等指标,上述误差指标均不依赖测试集大小。在同一测试集的情况下,由于技巧评分可以对于模型间的误差指标(如 RMSE、MAE 等)进行量化比较,故而是多组模型整体比较的常用指标。

风速误差分为纵向、横向误差。纵向误差是指某一时段预测结果在垂直方向与实测结果的差别程度,用偏大或偏小概括;而横向误差描述预测结果在水平时间轴上与实际观测的差别,即预测序列峰值的超前或滞后,其单位为时间,但在实际应用中 RMSE、MRE 等横向误差常算至纵向误差中。

2.3 综合评估指标

由于上述误差指标存在各自优缺点,在一定程度上刻画了风速误差的不同特征。但当各指标的结论不一致时会增加应用的困难,可以考虑构建综合评估指标。

(1)风速预报指数,综合考虑预报和实测的误差和趋势,主要包括平均准确率 ACI 和相关系数 R 。

$$WPI = k_1 \cdot ACI + k_2 \cdot R \quad (12)$$

式中 k_1, k_2 为权重系数, $k_1 + k_2 = 1$ 。

(2)区域风速预报指数,综合评价特定区域风速的预报精度。

$$PWPI = \sum_{j=1}^n k_j \cdot WPI_j, \\ k_j = \frac{C_j}{C_1 + C_2 + \dots + C_n} \quad (13)$$

其中 C_j 为第 j 个风电场装机容量, n 为评价区域内风电场个数。

(3)由于不同风速段输出功率不同,将观测风速分为“小风速段”(小于切入风速)、“变化风速段”(切入风速至额定风速)、“额定风速段”(额定风速至切出风速)、“风险风速段”(大于等于切出风速)4段,分别计算误差指标,最终优化整体误差获得预报模型的评估。

3 未来的发展方向

综合分析各种文献,在未来研究中应当注意:

(1)单一的预报模型难以满足对精度要求,组合预报模型可以有效提高预报精度,组合的方式可以是并联、串联或切换。

(2)数值预报描述气象演变过程,可以有效降低误差。从不同 NWP 模型构建的集合 NWP 、增加 NWP 的时间和空间分辨率、考虑风向、大气压强、空气密度、大气湿度等因素,都有助于提高预报精度。

(3)为预测结果建立物理意义明确的评价指标,寻找预报误差蕴含的有用信息,将有助于预报系统的改进;同时,由于风速具有很强的局地性,研究模型自适应的参数估计非常有必要。

(4)区域风速预报对于风电场非常有用,参考站点和不同地点的组合选择在区域预报中应当考虑;另外,目前预报主要集中在风速点值(均值)预报,在实际应用中风速区间预报、极端事件爬坡预报、极值预测对于保护电网和电力调度部门而言非常重要。

参考文献:

[1] Gwec. Global wind power statistics 2015 [R]. Brussels,

Belgium: Global Wind Energy Council, 2016.

- [2] 肉孜·阿基, 阿依谢姆古丽·孜比布拉, 艾克代·沙拉木. 2014年冬季阿图什2次灾害性大风对比分析[J]. 沙漠与绿洲气象. 2017(3): 72-78.
- [3] 金莉莉, 李振杰, 缪启龙, 等. 乌鲁木齐市近地层风切变指数特征[J]. 沙漠与绿洲气象. 2016(4): 81-86.
- [4] De Giorgi M G, Ficarella A, Tarantino M. Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods [J]. Energy. 2011, 36(7): 3968-3978.
- [5] Ye R, Suganthan P N, Srikanth N. Ensemble methods for wind and solar power forecasting—A state-of-the-art review [J]. Renewable and Sustainable Energy Reviews. 2015, 50: 82-91.
- [6] Foley A M, Leahy P G, Marvuglia A, et al. Current methods and advances in forecasting of wind power generation[J]. Renewable Energy. 2012, 37(1): 1-8.
- [7] 段学伟, 王瑞琪, 王昭鑫, 等. 风速及风电功率预测研究综述[J]. 山东电力技术. 2015(07): 26-32.
- [8] Salcedo-Sanz S, Ángel M P, Ortiz-García E G, et al. Hybridizing the fifth generation mesoscale model with artificial neural networks for short-term wind speed prediction [J]. Renewable Energy. 2009, 34(6): 1451-1457.
- [9] Kavasseri R G, Seetharaman K. Day-ahead wind speed forecasting using f-ARIMA models [J]. Renewable Energy. 2009, 34(5): 1388-1393.
- [10] Jiang P, Ma X. A hybrid forecasting approach applied in the electrical power system based on data preprocessing, optimization and artificial intelligence algorithms [J]. Applied Mathematical Modelling. 2016, 40(23-24): 10631-10649.
- [11] De Giorgi M G, Ficarella A, Tarantino M. Error analysis of short term wind power prediction models [J]. Applied Energy. 2011, 88(4): 1298-1311.
- [12] 胡义成, 伊里哈木, 王秋香, 等. 乌鲁木齐大气边界层风温垂直结构特征[J]. 沙漠与绿洲气象. 2015(3): 44-49.
- [13] 辛渝, 陈洪武, 赵逸舟, 等. MM5模式在新疆风能资源详查中的应用试验——以5月为例 [J]. 沙漠与绿洲气象. 2011(2): 12-18.
- [14] Foley A M, Leahy P G, Marvuglia A, et al. Current methods and advances in forecasting of wind power generation[J]. Renewable Energy. 2012, 37(1): 1-8.
- [15] Zhao J, Guo Z, Su Z, et al. An improved multi-step forecasting model based on WRF ensembles and creative fuzzy systems for wind speed[J]. Applied Energy. 2016, 162: 808-826.
- [16] 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(02): 1-6.
- [17] 马文通,朱蓉,李泽椿,等. 基于CFD动力降尺度的复杂地形风电场风电功率短期预测方法研究[J]. 气象学报. 2016(01): 89-102.
- [18] Box G E, Jenkins G M. Time series analysis: forecasting and control rev. ed.[J]. Journal of Time, 1976, 31(4): 238-242.
- [19] Nfaoui H, Buret J, Sayigh A A M. Stochastic simulation of hourly average wind speed sequences in Tangiers (Morocco)[J]. Solar Energy. 1996, 56(3): 301-314.
- [20] Liu H, Tian H, Chen C, et al. A hybrid statistical method to predict wind speed and wind power [J]. Renewable Energy. 2010, 35(8): 1857-1861.
- [21] Qin T, Peng H. Short-term wind speed forecasting based on non-stationary time series analysis [C]. 2011 2nd International Conference on Control, Instrumentation and Automation. 2011.
- [22] Peng L, Lili Y. Short-term wind speed forecasting based on non-stationary time series analysis and ARCH model [C]. 2011.
- [23] Zhang X, Zhang J, Li Y, et al. Short-term forecasting of wind speed based on recursive least squares [C]// International Conference on Electrical and Control Engineering. IEEE, 2011:367-370.
- [24] Erdem E, Shi J. ARMA based approaches for forecasting the tuple of wind speed and direction[J]. Applied Energy. 2011, 88(4): 1405-1414.
- [25] Kavasseri R G, Seetharaman K. Day-ahead wind speed forecasting using f-ARIMA models [J]. Renewable Energy. 2009, 34(5): 1388-1393.
- [26] Raol J R, Mankame S S. Artificial neural networks[J]. Resonance. 1996, 1(2): 47-54.
- [27] 孙川永,陶树旺,彭友兵,等. 基于神经网络方法的风电场风电功率预报研究[J]. 电网与清洁能源. 2011(12): 90-94.
- [28] Fadare D A. The application of artificial neural networks to mapping of wind speed profile for energy application in Nigeria[J]. Applied Energy. 2010, 87(3): 934-942.
- [29] 武小梅,白银明,文福拴. 基于RBF神经网络的风电功率短期预测[J]. 电力系统保护与控制. 2011(15): 80-83.
- [30] Mellit A, Kalogirou S A, Hontoria L, et al. Artificial intelligence techniques for sizing photovoltaic systems: A review [J]. Renewable and Sustainable Energy Reviews. 2009, 13(2): 406-419.
- [31] Ata R. Artificial neural networks applications in wind energy systems: a review [J]. Renewable and Sustainable Energy Reviews. 2015, 49: 534-562.
- [32] Li G, Shi J. On comparing three artificial neural networks for wind speed forecasting [J]. Applied Energy. 2010, 87(7): 2313-2320.
- [33] Peri R M, Mandal P, Hague A U, et al. Very Short-Term Prediction of Wind Farm Power: An Advanced Hybrid Intelligent Approach [M]. IEEE Industry Applications Society Annual Meeting, 2015.
- [34] Senkal S, Ozgonenel O. Performance analysis of artificial and wavelet neural networks for short term wind speed prediction[C]// International Conference on Electrical and Electronics Engineering. IEEE, 2014:196-198.
- [35] Jyothi M N, Rao P V R. Very-Short Term Wind Power Forecasting through Adaptive Wavelet Neural Network[C]. 2016 Biennial International Conference on Power and Energy Systems: Towards Sustainable Energy (PESTSE). 2016.
- [36] Filik U B, Filik T. Wind Speed Prediction Using Artificial Neural Networks Based on Multiple Local Measurements in Eskisehir [C]//Caetano N D, Felgueiras M C, Forment M A. Energy Procedia, 2017: 107, 264-269.
- [37] Vapnik V N. The Nature of Statistical Learning Theory[C]// Conference on Artificial Intelligence. Springer-Verlag, 1995:988-999.
- [38] 汪廷华,陈峻婷. 核函数的度量研究进展[J]. 计算机应用研究. 2011(1): 25-28.
- [39] Mohandes M A, Halawani T O, Rehman S, et al. Support vector machines for wind speed prediction [J]. Renewable Energy. 2004, 29(6): 939-947.
- [40] Hu Q, Zhang S, Xie Z, et al. Noise model based v-support vector regression with its application to short-term wind speed forecasting [J]. Neural Networks. 2014, 57: 1-11.
- [41] Kong X, Liu X, Shi R, et al. Wind speed prediction using reduced support vector machines with feature selection[J]. Neurocomputing. 2015, 169(SI): 449-456.
- [42] 潘迪夫,刘辉,李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术. 2008(7): 82-86.
- [43] Shukur O B, Lee M H. Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA [J]. Renewable Energy. 2015, 76: 637-647.
- [44] 修春波,任晓,李艳晴,等. 基于卡尔曼滤波的风速序列短期预测方法[J]. 电工技术学报. 2014(02): 253-259.
- [45] Chen K, Yu J. Short-term wind speed prediction using an unscented Kalman filter based state-space support vector regression approach[J]. Applied Energy. 2014, 113 (SI): 690-705.

- [46] Liu H, Tian H, Chen C, et al. A hybrid statistical method to predict wind speed and wind power [J]. *Renewable Energy*. 2010, 35(8): 1857-1861.
- [47] Yu C, Li Y, Zhang M. Comparative study on three new hybrid models using Elman Neural Network and Empirical Mode Decomposition based technologies improved by Singular Spectrum Analysis for hour-ahead wind speed forecasting [J]. *Energy Conversion and Management*. 2017, 147: 75-85.
- [48] Chen X, Zhao J, Hu W, et al. Short-term wind speed forecasting using decomposition-based neural networks combining abnormal detection method [J]. *Abstract and Applied Analysis*. 2014(984268).
- [49] Chen X, Jin S, Qin S, et al. Short-Term Wind Speed Forecasting Study and Its Application Using a Hybrid Model Optimized by Cuckoo Search [J]. *Mathematical Problems in Engineering*. 2015(608597).
- [50] Kitajima T, Yasuno T. Output prediction of wind power generation system using complex-valued neural network [C]// *Sice Conference 2010, Proceedings of. IEEE*, 2010:3610-3613.
- [51] Jiang P, Wang Y, Wang J. Short-term wind speed forecasting using a hybrid model [J]. *Energy*. 2017, 119: 561-577.
- [52] Shi J, Guo J, Zheng S. Evaluation of hybrid forecasting approaches for wind speed and power generation time series [J]. *Renewable and Sustainable Energy Reviews*. 2012, 16(5): 3471-3480.
- [53] Lojowska A, Kurowicka D, Papaefthymiou G, et al. Advantages of ARMA-GARCH wind speed time series modeling [C]// *IEEE, International Conference on Probabilistic Methods Applied To Power Systems. IEEE*, 2010:83-88.
- [54] Ji G R, Han P, Zhai Y J. Wind Speed Forecasting Based on Support Vector Machine with Forecasting Error Estimation [C]// *International Conference on Machine Learning and Cybernetics. IEEE*, 2007:2735-2739.
- [55] Magnusson L, Leutbecher M, Kallen E. Comparison between Singular Vectors and Breeding Vectors as Initial Perturbations for the ECMWF Ensemble Prediction System [J]. *Monthly Weather Review*. 2008, 136(11): 4092-4104.
- [56] Pinson P, Hagedorn R. Verification of the ECMWF ensemble forecasts of wind speed against analyses and observations [J]. *Meteorological Applications*. 2012, 19(4): 484-500.
- [57] Xiao L, Wang J, Dong Y, et al. Combined forecasting models for wind energy forecasting: A case study in China [J]. *Renewable and Sustainable Energy Reviews*. 2015, 44: 271-288.
- [58] Wang J, Song Y, Liu F, et al. Analysis and application of forecasting models in wind power integration: A review of multi-step-ahead wind speed forecasting models [J]. *Renewable and Sustainable Energy Reviews*. 2016, 60: 960-981.
- [59] Junli W U, Zhang B, Wang K. Application of Adaboost-Based BP Neural Network for Short-Term Wind Speed Forecast [J]. *Power System Technology*. 2012.
- [60] Shao H, Wei H, Deng X, et al. Short-term wind speed forecasting using wavelet transformation and AdaBoosting neural networks in Yunnan wind farm [J]. *IET Renewable Power Generation*. 2017, 11(4SI): 374-381.
- [61] Treiber N A, Sp th S, Heinnermann J, et al. Comparison of Numerical Models and Statistical Learning for Wind Speed Prediction [C]// *Esann*. 2015.
- [62] Pinson P, Girard R. Evaluating the quality of scenarios of short-term wind power generation [J]. *Applied Energy*. 2012, 96: 12-20.
- [63] Yan J, Liu Y, Han S, et al. Reviews on uncertainty analysis of wind power forecasting [J]. *Renew Able and Sustainable Energy Reviews*. 2015, 52: 1322-1330.
- [64] Wan C, Xu Z, Pinson P, et al. Probabilistic Forecasting of Wind Power Generation Using Extreme Learning Machine [J]. *IEEE Transactions on Powper Systems*. 2014, 29(3): 1033-1044.
- [65] Ul Haque A, Nehrir M H, Mandal P. A Hybrid Intelligent Model for Deterministic and Quantile Regression Approach for Probabilistic Wind Power Forecasting [J]. *IEEE Transactions on Power Systems*. 2014, 29(4): 1663-1672.
- [66] Bessa R J, Miranda V, Botterud A, et al. Time-adaptive quantile-copula for wind power probabilistic forecasting [J]. *Renewable Energy*. 2012, 40(1): 29-39.
- [67] 沈培, 魏海坤. 基于 RBF 神经网络的风电场风速区间预测 [J]. *工业控制计算机*. 2016(05): 55-57.

Research Advance on Ultra-short-term Wind Speed Forecasting Methods

CHEN Xuejun¹, LI Zhonglong²

(1.Gansu Meteorological Service Centre, Lanzhou 730020, China; 2.Gansu Meteorological Information & Technique Support & Equipment Centre, Lanzhou 730020, China)

Abstract The related domestic and international wind speed forecasting researches are comprehensively analyzed. The research status and progress of ultra-short-term wind speed forecasting methods are summarized from three aspects: physical methods, statistical and machine learning methods, and combination methods. The advantages and disadvantages of the main forecasting methods are compared. The uncertainty analysis and the error evaluation metrics are provided. The issues and directions which should be addressed in the research of ultra-short-term wind speed forecasting are discussed.

Key words ultra-short-term wind speed forecasting; physical methods; statistical and machine learning methods; combination methods; uncertainty analysis and error evaluation metrics