

DOI: 10.19783/j.cnki.pspc.190128

风电预测方法与新趋势综述

韩自奋¹, 景乾明², 张彦凯², 拜润卿², 郭空明³, 章云³

(1. 国网甘肃省电力公司, 甘肃 兰州 730030; 2. 国网甘肃省电力公司电力科学研究院, 甘肃 兰州 730050;
3. 西安电子科技大学, 陕西 西安 710071)

摘要: 风力发电作为一种技术成熟、规模较大的新能源发电形式, 目前在世界各国得到了广泛应用和发展。风电具有不确定性的特点, 必须对其进行准确的预测才能保证并网后电力系统的正常运行。针对风电预测的传统方法和新的研究趋势开展了综述。首先对物理方法、时间序列方法、人工智能方法和组合方法进行了总结, 然后针对目前风电预测的几个重要的发展方向: 空间相关性预测、集群预测、不确定性预测和爬坡预测的研究进展进行了重点阐述。对现有的风电功率预测方法进行综述后, 进一步对这一领域的研究方向进行了展望。

关键词: 风电功率; 预测; 空间相关性预测; 不确定性预测; 爬坡预测

Review of wind power forecasting methods and new trends

HAN Zifen¹, JING Qianming², ZHANG Yankai², BAI Runqing², GUO Kongming³, ZHANG Yun³

(1. State Grid Gansu Electric Power Company, Lanzhou 730030, China; 2. State Grid Gansu Electric Power Research Institute, Lanzhou 730050, China; 3. Xidian University, Xi'an 710071, China)

Abstract: As a mature and large-scale form of new energy power generation, wind power has been widely used and developed in countries all over the world. Wind power has the characteristics of uncertainty, and it must be accurately predicted to ensure the normal operation of the power system after grid connection. This paper reviews the traditional methods and new research trends of wind power forecasting. Firstly, the physical methods, time series methods, artificial intelligence methods and combined methods are summarized. Then, the research progress of several important development directions of wind power forecasting: spatial correlation forecasting, cluster forecasting, uncertainty forecasting and ramp forecasting are highlighted. After reviewing the existing wind power forecasting methods, the research direction in this field is further prospected.

This work is supported by Science and Technology Project of State Grid Corporation of China (No. 52272217000Z).

Key words: wind power; forecasting; spatial correlation forecasting; uncertainty forecasting; ramp forecasting

0 引言

风电是一种重要的低碳能源, 它具有低成本、清洁、可再生等诸多优点, 具有可持续能源供应的潜力。大力发展风电, 对于减少温室气体排放以及应对能源危机都具有重要的意义。21世纪以来, 全球风电装机量持续增长, 其中中国、印度、美国等人口大国增长尤为迅速。

风电自身的随机性会影响并网后电网的调度运行和安全稳定, 尤其是风电渗透率较高时, 这些问题更加突出^[1-2], 需要电网具备大量调峰备用容量。

对于欧美一些国家, 其风电的具体形式是多个分布式的小容量风电场, 它们各自对电网引入的波动因素会在一定程度上互相抵消。而我国风电场的形式多为集中式和大容量, 风电的不稳定性对于电网的影响更为明显。正因如此, 我国目前存在大量的弃风行为, 这无疑造成了大量资源的闲置和浪费。而对风电功率的准确预测, 不仅是解决风电消纳这一问题的的重要手段, 也会增强风电在电力市场中的竞争力, 提高上网电价。对发电企业来说, 风电功率的精准预测有助于发电企业合理安排大型检修活动、减少弃风, 提高经济效益。

目前世界范围内已有一些成熟的风电预测系统, 如丹麦的 Zephyr 系统、德国的 WPMS、美国

的 eWind、我国电力科学研究院研发的 WPFS 等^[3]。但由于风电预测问题的复杂性, 目前围绕这一领域仍有大量的理论性研究, 目前已有一些研究人员对现有的风电预测方法进行了综述^[3-7]。

本文对风电预测的理论方法进行了梳理, 并对研究方向中一些重要的趋势进行了着重阐述。文章内容主要分为三部分: 首先介绍和回顾风电预测的传统方法, 之后对空间相关性预测、集群预测、不确定性预测和爬坡预测进行了重点介绍, 最后对这一领域的发展提出了若干设想和建议。

1 风电预测传统方法

根据标准的不同, 风电预测有多种分类方法。从时间尺度上, 可以分为超短期预测(以小时为单位), 短期预测(以天为单位), 中期预测(以月为单位)和长期预测(以年为单位)^[5]。其中超短期预测主要用于风电机组的控制, 短期预测主要用于电网的安排调度, 中期预测用于安排大型检修, 而长期预测主要的作用是风电场选址评估。从模型对象分类, 可以分为基于风速的预测和基于功率的预测。前者首先预测出风速, 之后根据功率曲线计算风电功率。而后者直接对风电功率进行预测。从模型原理角度分类, 通常可以分为物理方法、时间序列方法、人工智能方法三大类^[7]。另外还有将不同类型方法进行组合的组合预测方法, 在此一并介绍。

1.1 物理方法

风电预测的物理方法主要是指基于数字天气预报(NWP)的预测方法。它的原理是将气象数据和地表信息作为初始条件和边界条件, 采用大型计算机直接求解风速所满足的物理学方程组, 即流体力学和热力学偏微分方程组得到风电机组轮毂高度的风速大小和方向等信息, 然后根据风电场的功率曲线计算得到输出功率。由于是采用求解微分方程的方法, 物理方法不需要历史数据, 只需要知道当前的气象数据(初始条件)即可进行求解预测。

物理方法存在的缺点有: (1) 由于边界条件复杂, 流体力学和热力学偏微分方程组的计算量极大, 因此导致数字天气预报更新缓慢, 一般每日只更新几次, 所以不宜用于短期和超短期预测。(2) 为了减小计算量, 空间网格尺寸一般都取得比较大, 这导致预报的空间分辨率不高, 只能用于一片区域(约几十平方千米)的预测。(3) 众所周知, 气象系统是混沌系统, 对初始条件极为敏感, 而当前气象数据不可避免存在微小的误差, 因此物理方法预测的风速会有一定的误差。而风功率与风速的三次方成正比, 因此这个误差在转化为风功率后会进一步扩大。

物理方法一般用于中期和长期预测, 特别是在风电场选址方面具有相当大的作用。为了改善初始条件的敏感性, 文献[8]将多组不同的天气预报结果作为初始条件分别进行计算, 再将结果进行组合, 结论证明对于 1~10 天的风电预测, 这种方法的预测结果好于使用单个初始条件的情况。而文献[9]考虑了基于三种不同气象模型分别进行计算后加权的方法。根据单个模型预测的偏差和误差的协方差矩阵, 可以得到最优权重。文献[10]提出了一种基于流场预计算的短期风速预测方法。该方法对一些离散化的边界条件进行预先计算, 然后基于流场特性数据库, 对所需预测状况下的风速和风向进行插值预测。为了改善低分辨率 NWP 的预测效果, 文献[11]在 NWP 的基础上, 利用流体力学原理解析地推导了地貌和尾流效应对流场的影响, 取得了较为理想的预测效果。

1.2 时间序列方法

自然界的绝大多数现象是满足确定性规律的, 但当规律过于复杂时, 往往会诉诸于统计学方法进行处理。传统的统计方法是指时间序列方法, 这种方法直接使用历史数据来推测未来时刻的数据, 不需要对系统建模, 因此是一种“黑匣子”方法^[6]。

最简单的时间序列方法是持续法, 该方法直接把当前的测量数据作为下一个时间点的预测值。由于风电功率时间序列存在相关性, 该方法虽然简单, 但在进行超短期预测, 而且数据随时间变化不剧烈时, 还是有较好的精度。因此持续法不但较为常用, 也经常作为一个基准, 用来评定其他方法的优劣。

最常用的时间序列模型为自回归滑动平均(ARMA)模型^[12], 所谓“自”回归, 是指模型采用数据本身来拟合未来的数据, 而不需要输入量。ARMA 模型一般适用于平稳时间序列, 对于非平稳时间序列, 常用的模型有差分自回归滑动平均(ARIMA)模型^[13]和自回归条件异方差(GARCH)模型^[14], 两者分别考虑了均值和方差随时间变化带来的非平稳性。

为改善普通 ARMA 模型的预测精度, 文献[15]基于 HOYW 定阶方法建立了加性噪声作用下的 ARMA 模型, 并验证了其相对于普通 ARMA 模型的优势。文献[16]基于大量历史数据, 采用 ARIMA 模型显著改善了预测效果。文献[17]将风电序列的波动性结构分解为永久性和暂时性两部分, 提出了 GARCH-M 模型。

总体而言, 时间序列方法只需要历史风功率数据, 避免了功率曲线对误差的放大, 使用和计算都相对简单一些。但低阶的时间序列模型拟合效果较

差,高阶模型需要确定的参数又太多,因此此类方法一般用于超短期和短期预测。当气候变化较为剧烈时,各类时间序列方法的效果都不太理想。

1.3 人工智能方法

随着人工智能的发展,诞生了许多基于智能学习的统计方法,其中机器学习的方法最为常用。这些方法通过一些学习的规则来建立输入输出之间的抽象模型,因此又称为“灰匣子”方法^[6]。

机器学习方法基于历史输入和输出数据,通过各种学习规则对系统的输入-输出关系建立模型,并进一步利用该模型预测未来的输出。近年来,大数据理论和各种智能学习方法迅猛发展,这一类方法已成为目前研究人员们关注的焦点之一。

早期常用的学习方法有人工神经网络(ANN)方法^[18]和支持向量机(SVM)方法^[19]。ANN是一类模拟人类大脑和神经网络工作原理的方法,它包括输入层、输出层和隐含层。ANN具有对系统的非线性特性建模的能力,因此更适合于描述风电功率与气象数据之间的复杂关系。另外,ANN特别适合编程以及并行计算。ANN方法的缺点有:需要大量样本进行长时间学习,计算量随维数增加迅速增长,容易陷入局部最优解,对训练数据的准确性有很高的要求等。SVM是机器学习方法的一种,它以结构风险最小化为准,计算实际风险,提高了算法的泛化能力。与ANN方法相比,SVM建立在严格的数学基础之上,且具有一些优点,如高维计算速度快、不易陷入局部最优解等。但是该方法的效果与核函数及参数的选取紧密相关,这一点依赖于使用者的经验。

人工智能学习的方法一般多用于超短期和短期预测。文献[20]结合神经网络算法和贝叶斯规则对酒泉风电基地进行了超短期预测。文献[21]在NWP的基础上,基于人工神经网络开发了具有良好人机界面的预测系统,并实现了与能量管理系统的无缝连接。文献[22]提出了一种由人工神经网络和遗传算法相结合的风力发电预测策略。文献[23]利用最小二乘支持向量机(LS-SVM)的方法对超短期风电负荷进行预测,通过算法的改进,计算效率和预测精度都得到了提高。文献[24]采用误差修正的最小二乘支持向量机模型对风电进行预测。考虑了模型的误差修正过程,与普通LS-SVM预测模型相比,平均绝对误差降低了52%。文献[25]提出了一种同时使用决策树和支持向量回归的异构集成学习方法。这种方法与单独使用支持向量回归相比,精度明显提高。而且通过调整预测数、样本数和使用的特征数等参数,可以很容易地在预测性能和计算时

间之间进行权衡。文献[26]发展了一种基于混合模式分解方法和在线序列异常鲁棒极值学习机的短期风速预测模型。结果表明混合模式分解能准确提取数据的特征以进行学习,而提出的在线学习方法明显优于离线预测。文献[27]分别采用多层前馈神经网络、支持向量回归、模糊推理系统、自适应神经模糊推理系统、数据处理群方法型神经网络等方法对巴西南部一座城市的风速进行了预测。结果表明,数据处理群方法型神经网络模型能成功地预测不同时间间隔下的风速,同时将自适应神经模糊推理系统与优化算法相结合,可以明显提高预测精度。文献[28]针对机器学习中的局部最优和过拟合问题,在数据预处理中,利用变重要性测度方法去除了一些冗余特征,并通过相关分析选择了密切样本。在学习方面提出了一种改进的监督随机森林方法,通过对每一个决策树的性能评估和对决策树的重构,构成新的随机森林。实例验证了该模型在精度、效率和鲁棒性方面都有显著的优势。

总之,人工智能学习方法与时间序列方法相比,能更好地考虑非线性因素,且具有自适应、自学习的能力,但需要大量数据并且需要对数据进行预处理,而且训练时间较长,对于学习过程中未遇到的罕见天气状况下的风电功率没有预测能力。另外,在学习中采用不同的相似度度量准则,也会对结果产生很大影响,这一点仍依赖于相关人员的经验。

1.4 组合预测方法

各类传统方法均有一定的优点和缺点,而且方法是否适用,依赖于预测时间长短和特定风电场的地理因素以及预测的直接目的,所以对方法的优劣进行评判是没有意义的,若采用多种方法进行组合预测,则可望取得更好的预测效果^[29]。

为了综合考虑各类预测方法的结果,研究人员考虑将不同方法分别独立预测出的结果加权后组合得到最终预测值^[30],这种方法又称为基于权重系数的组合预测方法,或者横向组合预测方法。

与采用单一的方法相比,加权组合的方法可以有效地减小误差的上限,提升预测结果的稳健性。毫无疑问,对于这种方法而言,最重要的是确定各方法的权重系数。目前常用的方法有等权重法、最小二乘法、最小方差法、贝叶斯方法、熵值法等。文献[31]提出了基于最大熵原理的模型组合方法,通过将三个以NWP输入的ANN模型进行组合,发现这种组合模型比单一模型以及其他权重系数组合模型的效果都要好。文献[32]发展了一种两步预测方法,在方法的第一步中,根据不同的评估标准,为每种类型的神经网络选择最佳预测值。在第二步中,

通过贝叶斯算法根据期望最大化(EM)算法估计的后验模型概率对单个预测值进行加权。结果表明,该方法能对不同的情况进行合理的预测。文献[33]提出了一种时变权重的组合方法,该方法根据模型在前一天的性能,对单个预测站点的模型权重不断进行更新。文献[34]将 BP 神经网络、RBF 神经网络和 SVM 三种方法,分别用等权重平均法、协方差优选组合法和时变权系数组合法进行了组合,结果证明时变权系数能更有效地提高预测精度。文献[35]将 ARMA 模型和 BP 神经网络进行加权组合,基于线性规划的思想求出了误差绝对值最小时的最优组合预测权系数。

加权组合的方法由于需要使用多种方法分别进行计算,因此需要耗费较多的计算量,不过优点是各方法可以并行处理,从而节省计算时间。

另一种组合预测方法是在不同的环节使用不同的方法,以发挥不同类型方法各自的优点,可以称为基于融合的组合预测方法,或纵向组合预测方法。早期的研究主要着重于物理预测和统计预测的组合,一般将物理预测的结果作为智能统计方法的输入变量。而近期此类方法常常融入一些信号处理方法、优化方法、残差评估的方法等。根据所融入方法的不同,纵向组合预测方法可以分为三类:

(1) 包含数据前处理环节的方法。这类方法首先采用小波变换(WT),经验模式分解(EMD)等方法将时间序列分解为多个分量,对每个分量进行预测后,重新组合作为最终的预测结果。文献[36]考虑风电场附近多个位置的 NWP,利用聚类分析法提取与预测日 NWP 最相近的样本,然后用主成分分析法对信息进行预处理,提高了预报的精度。文献[37]针对非平稳风速时间序列,将其进行小波分解后分别利用 ARMA 模型进行预测,最后叠加得到最终预测值。文献[38]利用 EMD 将风电场功率分解为本征模函数(IMF)分量和残余分量。利用灰色预测模型对残余分量进行预测。对于 IMF 分量,识别其特征,如果是混沌时间序列,则采用最大的李雅普诺夫指数预测方法进行预测。否则,使用灰色预测模型进行预测。将剩余分量和所有 IMF 分量的预测结果进行汇总,得出风电场功率的最终预测结果。

(2) 包含参数选择和优化环节的方法。这类方法采用遗传算法等优化算法对模型参数进行优化后,再进行预测。文献[39]采用遗传算法对分段支持向量机模型参数进行自动搜索。由此得到的模型可以很好地预测未来 1~6 h 的风力发电量。文献[40]利用一种新的基于交叉算子和选择机制的差分进化算法来训练 Ridgelet 神经网络,进而对风力发电量进行

预测。文献[41]研究了一种新的用于风速时间序列预测的神经网络结构训练算法。该训练算法基于扩展卡尔曼滤波器,利用粒子群优化算法对设计参数进行改进。

(3) 包含误差处理环节的方法。此类方法首先进行一次预测,然后根据结果对残余误差进行估算,最后根据估算的误差对预测结果进行修正。文献[42]首先建立了风速的灰色预测模型。然后利用马尔可夫模型将风速的残差分为几个不同的状态,通过计算各状态的概率分布,进一步预测了残差并对预测值进行修正。文献[43]采用 ARIMA 模型预测风速时间序列,同时用 GARCH 模型模拟得到的残余误差,研究表明这种组合方法的输出更接近测量值。

2 风电预测新趋势

2.1 考虑空间相关性的预测方法

风速场作为一种时空物理场,虽然有一定的随机性,但在较短的时间间隔上和空间距离上都具有一定的相关性。功率预测的时间序列方法就是利用了同一空间点数据在临近时刻的相关性,而早期大多数方法并未考虑风电场临近地理位置气象数据所携带的有用信息,因此,考虑空间相关性的预测方法近年来逐渐开始受到关注。文献[44]对这一领域进行了很好的综述,给出了基于空间相关性的风电功率预测的定义、概念和特点,对方法进行了分类阐述,总结了该领域尚存在的问题与不足。

考虑空间相关性的预测方法也可以分为物理方法和统计方法两大类。所谓的物理方法就是从风场满足的物理规律出发来推导各点之间的风速关系,进而利用该关系来进行预测^[45]。例如,文献[46]对于规律性排布的风电机组阵列,根据计算流体力学(CFD)的方法推导出各机组之间的相关矩阵,从而由少量机组的信息推导出整个机组的功率信息。另外,风电机组之间的尾流效应,大气涡流的空间尺度等都是相关性的影响因素。空间相关性的潜在物理机制较为复杂,需要深入进行探讨,因此目前大多数文献还停留在对规律的总结层面,具体的应用不多。如文献[47]利用一种新发展的大涡模拟方法,对风电场内部和上方的湍流进行了计算和研究。

与物理方法不同的是,统计方法只利用各个点的时间序列来进行研究,基本不考虑内在的物理规律。统计方法的关键是如何确定数据相关性随空间距离和时间间隔的变化规律,进而找出与待测点相关性最高的参考点以及最优时间延迟^[48]。传统的手段是计算样本互相关函数(SCCF)的极值点。与物理方法相比,统计方法不需要考虑、推导和计算复杂

的流体力学规律,但缺点是需要对海量数据进行处理。为了提高数据处理效率,此类方法往往采取离线处理和在线处理分离进行的方式。文献[49]中提出了定向点累积半变异函数的概念,它提供了有关局部空间风速和/或海拔变化的信息。根据此概念,可以沿着所需方向获得每个站周围的风速影响半径,进而找出与待测点相关度最高的位置。该方法有较高的计算效率。文献[50]提出一种“离线分类优化模型,在线确认空间相关性并匹配预测模型”的方法,提高了在线预测环节的效率。

2.2 风电集群预测方法

传统风电预测主要着眼于对单一风电场进行预测,而当并网的风电场较多时,显然调度人员更关心所有风电场总功率的波动带来的影响。对我国而言,由于风电场多集中在西北地区形成集群分布,因此从整体上预测风电集群出力无疑具有重要的意义^[51]。

风电集群预测的传统方法主要分为叠加法和统计升尺度法^[52]两类。叠加法顾名思义就是对所有风电场出力进行预测后相加得到总的出力。该方法思路简单,但当风电场数量较多时,预测计算量会显著提高,而且单个风电场的预测误差会叠加,导致集群预测精度较低。另外,叠加法没有利用到各风电场之间的相关性。因此,叠加法适合于分布稀疏,数量较少的集群。统计升尺度法则利用了各风电场之间功率以及总功率之间的关联性。该方法认为单一风电场功率与集群总功率之间存在一定的映射关系,因此可以通过各种方法如机器学习方法建立某个基准风电场功率和总功率之间的模型,然后通过单一风电场的功率预测便可得到集群功率的预测值。统计升尺度法与叠加法相比,后期的预测计算量明显减小,但前期要通过大量工作建立基准风电场和集群之间的复杂模型。而且,在基准风电场的选取方面,选取的基准风电场功率需要和集群功率之间有较强的关联性,而且基准风电场的功率预测误差要尽可能小。该方法在欧洲一些面积较小的国家如丹麦有广泛的应用。

除了广泛应用的叠加法和统计升尺度法外,近年来研究人员对新的方法不断进行探索。文献[53]提出的空间资源匹配法是近年来较为热门的方法。该方法通过当前时空风速数据和历史风速数据的相似性,加权得到集群功率的预测值。显然空间资源匹配法需要较多的历史数据积累。文献[54]对空间资源匹配法进行了改进,在参数中加入了预测时间前一个时间点的测量功率,并对一些系数进行了优化。文章指出还应考虑将湿度、温度、气压等条件

加入参数中以提高预测精度。文献[55]针对空间资源匹配法中的冗余信息提出了两种方法,一是基于最小冗余极大相关准则选择子集,二是基于主成分分析方法选择子集。文章同时提出了一种局部加权学习方法,利用处理后的特征集生成电力预测结果。

总之风电集群预测由于规模较大,且各风电场地理环境不同,因此主要采用统计和学习的方法,物理方法很少使用。目前已有的方法并未考虑到随机性的影响,事实上各风电场之间的波动性既可能相互叠加造成更大的误差,也可能相互抵消减小误差。因此不确定性的预测方法可能会是该领域的一个新思路。

2.3 不确定性预测方法

对于风电功率预测,一方面,由于气象观测数据存在误差,模型具有近似性等因素,预测结果必然存在一定程度的偏离,因此更合理的预测手段不但要给出估计值,还要对误差进行量化;另一方面,风电时间序列本身就是一个随机过程。因此,考虑结果的随机性,采用不确定性理论进行预测,不但更符合风电功率本身的特点,同时相较传统的点估计提供了更多的信息,更有利于做出最优决策。目前不确定性预测可以分为三大类^[56]:

(1) 概率预测。该方法取得的结果为一些概率统计量,最理想的是获得风电功率的概率密度函数(PDF)。当PDF难以求得时,分位数、区间、统计矩等信息也有重要的指导作用。概率预测方法可分为参数法和非参数法。参数法对概率分布进行假定,之后根据最大似然等方法求出这些参数。显然当实际数据并不服从假定分布时,会产生较大误差。高斯分布是最简单和常见的一种随机分布,但风电序列的随机性往往并不满足高斯分布。文献[57]针对风电序列提出了一种广义Logist正态分布。文献[58]基于扭曲高斯过程,通过将风电序列自动转换为潜在序列,来处理风电序列中的非高斯随机性。

非参数法不对分布做出事先假定,可有效避免建模误差,但使用起来较为复杂。常用的非参数方法有自适应重采样、核密度估计方法以及一些人工智能方法。文献[59]为了避免对预测误差分布形状的假设,提出了一种基于经验和非参数的自适应重采样方法。文献[60]提出了一种风速概率分布的非参数核密度估计方法。将该方法与多种常用风速参数分布模型进行了比较,证明这种估计方法具有更好的适应性。文献[61]发展了一种基于极值学习机和粒子群优化的风力发电区间预测的新方法,在预先不知道预测误差的情况下,通过覆盖概率和锐度的直接优化直接生成预测区间。

(2) 风险指数预测。概率预测虽然提供了较多的信息, 但是也对决策人员的能力提出了更高的要求, 不能像点估计一样直接进行判断。而风险指数预测则是给出了确定性预测结果误差的预期水平。风险指数通过简单的几个离散指标(如颜色红-绿-黄或者数字 1—5)来描述结果的可信度, 当风险指数较高时, 需要采取一些保护措施来预防预测误差带来的潜在风险。此类方法的优点是有助于做出决策, 难点是如何确定合适的指标水平。文献[62]采用了规范化预测风险指数来描述系综成员的分布。该方法用欧几里德范数和加权标准差分别测量两个系综成员之间的距离。

(3) 时空情景预测。传统的随机预测只是把特定点和特定时刻的预测结果作为一个随机变量来研究, 而正如上一部分所述, 风速场是一个时空随机场, 考虑其在时间和空间尺度上的总体特性更为合理。另一方面, 在电力系统运行中, 存在着动态经济调度、风电场与储能系统协调等多阶段、多时间的决策问题。利用随机场的联合概率密度函数, 可以模拟不同时间不同地点风力发电量的时间相关性。然而, 这种方法的计算量非常大, 因此需要在精确性和经济性之间做出权衡。另外直接使用联合概率密度函数进行决策也是几乎不可能的, 还需要一些随机优化算法。文献[63]引入了多变量 ARMA 模型, 并采用方差-协方差矩阵来表征风速分布的时空相关性。为了减少数据量, 文献[64]采用聚类方法将多个情景分组为不同的聚类, 而文献[65]则采用了 Kantorovich 距离以减少情景的数量。

对于不确定性预测, 一个普遍存在的问题是难以对预测结果进行评定, 因为实际测量到的数据只是一个样本, 无法与预测结果进行比较。文献[66]指出, 可靠性是概率预测评价的首要要求, 在满足可靠性要求的基础上, 通过预测模型的锐度对预测模型的性能进行排序。文献[67]同样指出可靠性评价起着基础性评价的作用, 应首先进行。

2.4 爬坡预测

对于短期和超短期风电预测而言, 工作人员最关心的实际上是风电功率在短时间内的突然变化, 此类现象称为风电爬坡^[68]。当数据变化较为平缓时, 采用最简单的持续法就可以有很好的预测精度, 而一旦爬坡现象出现, 由于数据变化太快, 预测的难度明显增加。

根据变化的方向, 爬坡现象可以分为上爬坡和下爬坡, 分别对应于风电功率的突然增长和减小。无论哪一种爬坡都会对电网的正常运行带来严重的影响。在给定时间间隔内, 功率的变化若超过一个

阈值, 就认为发生了爬坡现象。显然该阈值的选取影响着事件的预报, 阈值太小容易造成假阳性错误, 太大则又可能出现漏报。从物理机制上寻求爬坡现象的普遍解释存在一定的难度, 这是因为对于每一个特定的风电机组, 即使空间上距离很近, 其爬坡事件的内在机制也可能会大相径庭。

爬坡事件的预测方法可以分为直接方法和间接方法两大类^[69]。其中间接法是在对风功率进行预测的基础上, 从中提取爬坡信息。而直接方法是直接对爬坡事件的发生与否进行预测, 通过对大量的历史数据采用统计学习的方法来完成。由于爬坡事件属于小概率事件, 因此直接法需要长时间的样本积累以及较为复杂的学习算法。

由于间接法是基于传统风电预测方法, 这里不再叙述, 而只是对直接法的研究进行概述。文献[70]采用了五种不同的数据挖掘算法对爬坡预测进行了测试, 发现支持向量机回归算法效果最好。文中还采用了提升树算法选择参数以提高爬坡事件的预测精度。文献[71]基于突变理论, 利用相关性分析、主成分分析和线性加权累加方法对气象数据进行处理, 提取爬坡的特征变量, 建立突变预测模型并训练模型参数, 以实现爬坡事件的预测。文献[72]采用经验模式分解、核函数岭回归和随机向量泛函神经网络相结合的综合方法, 对风电爬坡和爬坡速率进行预测。文献[73]先建立一个能够捕捉风电变化趋势的主模型, 之后采用马尔可夫切换自回归模型对主模型的预测残差进行修正, 最后应用改进的推拉门算法提取直线段, 并利用斜坡定义检测爬坡事件。文献[74]将斜坡事件的可能性转化为一个数据驱动的鲁棒概率不等式, 给出了最坏斜坡事件的概率上界, 显著降低了决策的保守程度。

由于风电爬坡实际上对应于小概率事件的预测问题, 采用概率方法处理爬坡预测问题的思路显得更为合理。另外, 统计学习的方法实际上没有直接考虑风电场的实际物理特性, 因此有必要研究针对具体风电场的、结合物理方法的爬坡预测手段。

3 结论与展望

随着我国风力发电装机容量的不断增加, 准确预测风力发电量是保证电网安全运行的必要条件。本文对风电预测的物理方法和统计方法进行了介绍, 重点对组合预测、空间相关性预测、不确定性预测进行了综述。在此基础上, 对今后风电预测的发展和改进提出一些设想和建议。

风电功率信号可以分解为确定性部分和纯随机部分, 因此根据风电机组的特定地理因素, 建立一

种缩减的模型, 计算出数据的确定性部分, 再通过统计方法得到随机部分, 两者叠加作为最终预测结果, 是一种值得考虑的思路。

目前大数据概念方兴未艾, 研究人员不但应充分利用各类有关的信息, 同时建议在风电场周边大的范围内多设立测量点, 一方面可以充分利用数据的空间规律进行预测, 另一方面分析不同测量点之间的数据, 也会有助于归纳和揭示潜在的物理规律, 从而反过来对数据的选取、测量点的优化布置起到指导作用。

由于风电场地理位置、气候条件、内部布局等因素都不尽相同, 无法找出一种模型能够适用于所有风电场的功率预测, 而且风电预测最终要服务于特定风电场和电网的运行和控制, 因此, 风电预测应该做到因地制宜, 具体问题具体分析。

参考文献

- [1] 张宇童, 汪樟垚, 雷怡菲, 等. 考虑自组织临界条件的区域电网风电极限渗透率评估方法[J]. 电力系统保护与控制, 2019, 47(2): 15-21.
ZHANG Yutong, WANG Zhangyao, LEI Yifei, et al. An evaluation method for the maximum penetration of wind power of district power grid based on the self-organization criticality[J]. Power System Protection and Control, 2019, 47(2): 15-21.
- [2] 李军徽, 冯喜超, 严干贵, 等. 高风电渗透率下的电力系统调频研究综述[J]. 电力系统保护与控制, 2018, 46(2): 163-170.
LI Junhui, FENG Xichao, YAN Gangui, et al. Survey on frequency regulation technology in high wind penetration power system[J]. Power System Protection and Control, 2018, 46(2): 163-170.
- [3] 牛东晓, 范磊磊. 风电功率预测方法综述及发展研究[J]. 现代电力, 2013, 30(4): 24-28.
NIU Dongxiao, FAN Leilei. Review and development study on wind power prediction methods[J]. Modern Electric Power, 2013, 30(4): 24-28.
- [4] 黎静华, 桑川川, 甘一夫, 等. 风电功率预测技术研究综述[J]. 现代电力, 2017, 34(3): 1-11.
LI Jinghua, SANG Chuanchuan, GAN Yifu, et al. A review of researches on wind power forecasting technology[J]. Modern Electric Power, 2017, 34(3): 1-11.
- [5] 王健, 严干贵, 宋薇, 等. 风电功率预测技术综述[J]. 东北电力大学学报, 2011, 31(3): 20-24.
WANG Jian, YAN Gangui, SONG Wei, et al. Review of wind power prediction[J]. Journal of Northeast Dianli University, 2011, 31(3): 20-24.
- [6] 杨茂, 马秀达, 温道扬, 等. 风电功率预测研究综述[J]. 电测与仪表, 2013, 50(7): 7-10.
YANG Mao, MA Xiuda, WEN Daoyang, et al. Review of wind power prediction[J]. Electrical Measurement & Instrumentation, 2013, 50(7): 7-10.
- [7] 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.
- [8] TAYLOR J W, BUIZZA R. Using weather ensemble predictions in electricity demand forecasting[J]. International Journal of Forecasting, 2003, 19(1): 57-70.
- [9] NIELSEN H A, NIELSEN T S, MADSEN H, et al. Optimal combination of wind power forecasts[J]. Wind Energy, 2007, 10(5): 471-482.
- [10] 李莉, 刘永前, 杨勇平, 等. 基于 CFD 流场预计算的短期风速预测方法[J]. 中国电机工程学报, 2013, 33(7): 27-32.
LI Li, LIU Yongqian, YANG Yongping, et al. Short-term wind speed forecasting based on CFD pre-calculated flow fields[J]. Proceedings of the CSEE, 2013, 33(7): 27-32.
- [11] 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.
- [12] 刘仁山, 孟祥宏. 含自适应阈值的 ARMA 网络流量异常检测算法[J]. 信阳师范学院学报(自然科学版), 2013, 26(2): 296-300.
LIU Renshan, MENG Xianghong. Network traffic abnormality detection algorithm based on ARMA with self-adaptive threshold[J]. Journal of Xinyang Normal University (Natural Science Edition), 2013, 26(2): 296-300.
- [13] SFETSOS A. A novel approach for the forecasting of mean hourly wind speed time series[J]. Renewable Energy, 2002, 27(2): 163-174.
- [14] HUI Z, FANG J, MEI H. Numerical analysis of application GARCH to short-term wind power forecasting[C] // 2010 International Conference on Power System Technology, October 24-28, 2010, Hangzhou, China: 1-6.
- [15] 高阳, 朴在林, 张旭鹏, 等. 基于噪声场合下 ARMA 模型的风力发电量预测[J]. 电力系统保护与控制, 2010, 38(20): 164-167.
GAO Yang, PIAO Zailin, ZHANG Xupeng, et al. Prediction of wind power generation based on ARMA with additive noise model[J]. Power system protection and control, 2010, 38(20): 164-167.
- [16] ELDALI F A, HANSEN T M, SURYANARAYANAN S,

- et al. Employing ARIMA models to improve wind power forecasts: a case study in ERCOT[C] // 2016 North American Power Symposium (NAPS), September 18-20, 2016, Denver, CO, USA: 1-6.
- [17] CHEN H, LI F, WANG Y. Component GARCH-M type models for wind power forecasting[C] // 2015 IEEE Power & Energy Society General Meeting, July 26-30, 2015, Denver, CO, USA.
- [18] KARINIOTAKIS G N, STAVRAKAKIS G S, NOGARET E F. Wind power forecasting using advanced neural networks models[J]. IEEE Transactions on Energy Conversion, 1996, 11(4): 762-767.
- [19] 杨阳, 杨璐, 郎劲, 等. 基于 LS-SVM 算法的多场景风电功率预测研究[J]. 智慧电力, 2017, 45(7): 58-63.
YANG Yang, YANG Lu, LANG Jin, et al. Study on multi-scenario wind power prediction based on LS-SVM algorithm[J]. Smart Power, 2017, 45(7): 58-63.
- [20] 马彦宏, 汪宁渤, 马明, 等. 基于神经网络的酒泉风电基地超短期风电功率预测方法[J]. 电力建设, 2013, 34(9): 1-5.
MA Yanhong, WANG Ningbo, MA Ming, et al. Ultra-short-term wind power prediction method based on neural network for Jiuquan wind power base[J]. Electric Power Construction, 2013, 34(9): 1-5.
- [21] 范高锋, 王伟胜, 刘纯. 基于人工神经网络的风电功率短期预测系统[J]. 电网技术, 2008, 32(22): 72-76.
FAN Gaofeng, WANG Weisheng, LIU Chun. Artificial neural network based wind power short term prediction system[J]. Power System Technology, 2008, 32(22): 72-76.
- [22] ARSHAD J, ZAMEER A, KHAN A. Wind power prediction using genetic programming based ensemble of artificial neural networks (GPeANN)[C] // 2014 12th International Conference on Frontiers of Information Technology, December 17-19, 2014, Islamabad, Pakistan.
- [23] 崔杨, 李莉, 陈德荣. 基于最小二乘支持向量机的超短期风电负荷预测[J]. 电气自动化, 2014(5): 35-37.
CUI Yang, LI Li, CHEN Derong. Ultra-short-term wind power load forecast based on least squares SVM[J]. Electrical Automation, 2014(5): 35-37.
- [24] ZHANG Y, WANG P, NI T, et al. Wind power prediction based on LS-SVM model with error correction[J]. Advances in Electrical & Computer Engineering, 2017, 17(1): 3-8.
- [25] HEINERMANN J, KRAMER O. Machine learning ensembles for wind power prediction[J]. Renewable Energy, 2016, 89: 671-679.
- [26] ZHANG D, PENG X, PAN K, et al. A novel wind speed forecasting based on hybrid decomposition and online sequential outlier robust extreme learning machine[J]. Energy Conversion and Management, 2019, 180: 338-357.
- [27] KHOSRAVIA, MACHADO L, NUNES R O. Time-series prediction of wind speed using machine learning algorithms: a case study Osorio wind farm, Brazil[J]. Applied Energy, 2018, 224: 550-566.
- [28] SHI K, QIAO Y, ZHAO W, et al. An improved random forest model of short-term wind-power forecasting to enhance accuracy, efficiency, and robustness[J]. Wind Energy, 2018, 21(12): 1383-1394.
- [29] TASICARAOGLU A, UZUNOGLU M. A review of combined approaches for prediction of short-term wind speed and power[J]. Renewable and Sustainable Energy Reviews, 2014, 34: 243-254.
- [30] BATES J M, GRANGER C. The combination of forecast[J]. Operation Research Quarterly, 1969, 20: 451-468.
- [31] HAN S, LIU Y. The study of wind power combination prediction[C] // 2010 Asia-Pacific Power and Energy Engineering Conference, March 28-31, 2010, Chengdu, China.
- [32] LI G, SHI J, ZHOU J. Bayesian adaptive combination of short-term wind speed forecasts from neural network models[J]. Renewable Energy, 2011, 36(1): 352-359.
- [33] MAHONEY W P, PARKS K, WIENER J. A wind power forecasting system to optimize grid integration[J]. IEEE Transactions on Sustainable Energy, 2012, 3(4): 670-682.
- [34] 刘纯, 范高锋, 王伟胜, 等. 风电场输出功率的组合预测模型[J]. 电网技术, 2009, 33(13): 74-79.
LIU Chun, FAN Gaofeng, WANG Weisheng, et al. A combination forecasting model for wind farm output power[J]. Power System Technology, 2009, 33(13): 74-79.
- [35] 曾鸣, 李树雷, 王良, 等. 基于 ARMA 模型和 BP 神经网络组合优化算法的风电预测模型[J]. 华东电力, 2013, 41(2): 347-352.
ZENG Ming, LI Shulei, WANG Liang, et al. Wind power prediction model based on the combined optimization algorithm of ARMA model and BP neural networks[J]. East China Electric Power, 2013, 41(2): 347-352.
- [36] 王丽婕, 冬雷, 高爽. 基于多位置 NWP 与主成分分析的风电功率短期预测[J]. 电工技术学报, 2015, 30(5): 79-84.
WANG Lijie, DONG Lei, GAO Shuang. Wind power short-term prediction based on principal component analysis of NWP of multiple locations[J]. Transactions of China Electrotechnical Society, 2015, 30(5): 79-84.
- [37] 李东福, 董雷, 礼晓飞, 等. 基于多尺度小波分解和时间序列法的风电场风速预测[J]. 华北电力大学学报,

- 2012, 39(2): 43-48.
- LI Dongfu, DONG Lei, LI Xiaofei, et al. A wind speed forecasting method for wind farms based on different scales wavelet decomposition and time series analysis[J]. Journal of North China Electric Power University, 2012, 39(2): 43-48.
- [38] AN X, JIANG D, ZHAO M, et al. Short-term prediction of wind power using EMD and chaotic theory[J]. Communications in Nonlinear Science and Numerical Simulation, 2012, 17(2): 1036-1042.
- [39] SHI J, YANG Y, WANG P, et al. Genetic algorithm-piecewise support vector machine model for short term wind power prediction[C] // 2010 8th World Congress on Intelligent Control and Automation, July 7-9, 2010, Jinan, China.
- [40] AMJADY N, KEYNIA F, ZAREIPOUR H. Short-term wind power forecasting using ridgelet neural network[J]. Electric Power Systems Research, 2011, 81(12): 2099-2107.
- [41] ALANIS A Y, SIMETTI C, RICALDE L J, et al. A wind speed neural model with particle swarm optimization Kalman learning[C] // World Automation Congress 2012, June 24-28, 2012, Puerto Vallarta, Mexico.
- [42] CHEN S, YE L, ZHANG G, et al. Short-term wind power prediction based on combined grey-Markov model[C] // 2011 International Conference on Advanced Power System Automation and Protection, October 16-20, 2011, Beijing, China.
- [43] WANG M D, QIU Q R, CUI B W. Short-term wind speed forecasting combined time series method and arch model[C] // 2012 International Conference on Machine Learning and Cybernetics, July 15-17, 2012, Xi'an, China.
- [44] 叶林, 赵永宁. 基于空间相关性的风电功率预测研究综述[J]. 电力系统自动化, 2014, 38(14): 126-135.
- YE Lin, ZHAO Yongning. A review on wind power prediction based on spatial correlation approach[J]. Automation of Electric Power Systems, 2014, 38(14): 126-135.
- [45] 叶燕飞, 王琦, 陈宁, 等. 考虑时空分布特性的风速预测模型[J]. 电力系统保护与控制, 2017, 45(4): 114-120.
- YE Yanfei, WANG Qi, CHEN Ning, et al. Wind forecast model considering the characteristics of temporal and spatial distribution[J]. Power System Protection and Control, 2017, 45(4): 114-120.
- [46] 曾程, 叶林, 赵永宁. 考虑尾流效应的风电场短期功率空间预测模型[J]. 电力系统保护与控制, 2012, 40(24): 59-64.
- ZENG Cheng, YE Lin, ZHAO Yongning. Spatial model for short term wind power prediction considering wake effects[J]. Power System Protection and Control, 2012, 40(24): 59-64.
- [47] WU Y T, PORTÉ-AGEL F. Simulation of turbulent flow inside and above wind farms: model validation and layout effects[J]. Boundary-Layer Meteorology, 2013, 146(2): 181-205.
- [48] 杨正瓴, 杨钊, 张玺, 等. 基于季风提高空间相关性预测的优化延迟时间[J]. 电力系统保护与控制, 2016, 44(15): 33-38.
- YANG Zhengling, YANG Zhao, ZHANG Xi, et al. Improving optimal lag time of spatial correlation prediction by characteristics of monsoon[J]. Power System Protection and Control, 2016, 44(15): 33-38.
- [49] SAHIN A D, SEN Z. Wind energy directional spatial correlation functions and application for prediction[J]. Wind Engineering, 2009, 24(3): 223-231.
- [50] 陈宁, 薛禹胜, 丁杰, 等. 利用空间相关性的超短期风速预测[J]. 电力系统自动化, 2017, 41(12): 124-130.
- CHEN Ning, XUE Yusheng, DING Jie, et al. Ultra-short term wind speed prediction using spatial correlation[J]. Automation of Electric Power Systems, 2017, 41(12): 124-130.
- [51] 彭小圣, 熊磊, 文劲宇, 等. 风电集群短期及超短期功率预测精度改进方法综述[J]. 中国电机工程学报, 2016, 36(23): 6315-6326.
- PENG Xiaosheng, XIONG Lei, WEN Jinyu, et al. A summary of the state of the art for short-term and ultra-short-term wind power prediction of regions[J]. Proceedings of the CSEE, 2016, 36(23): 6315-6326.
- [52] 陈颖, 孙荣富, 吴志坚, 等. 基于统计升尺度方法的区域风电场群功率预测[J]. 电力系统自动化, 2013, 37(7): 1-5.
- CHEN Ying, SUN Rongfu, WU Zhijian, et al. A regional wind power forecasting method based on statistical upscaling approach[J]. Automation of Electric Power Systems, 2013, 37(7): 1-5.
- [53] LOBO M G, SANCHEZ I. Regional wind power forecasting based on smoothing techniques, with application to the Spanish peninsular system[J]. IEEE Transactions on Power Systems, 2012, 27(4): 1990-1997.
- [54] 彭小圣, 樊闻翰, 王勃, 等. 基于改进空间资源匹配法的风电集群功率预测技术[J]. 电力建设, 2017, 38(7): 10-17.
- PENG Xiaosheng, FAN Wenhan, WANG Bo, et al. A lifting spatial resources matching approach based wind power prediction of regions[J]. Electric Power Construction, 2017, 38(7): 10-17.

- [55] WANG Z, WANG W, WANG B. Regional wind power forecasting model with NWP grid data optimized[J]. *Frontiers in Energy*, 2017, 11(2): 175-183.
- [56] ZHANG Y, WANG J, WANG X. Review on probabilistic forecasting of wind power generation[J]. *Renewable and Sustainable Energy Reviews*, 2014(32): 255-270.
- [57] KOU P, GAO F, GUAN X. Sparse online warped Gaussian process for wind power probabilistic forecasting[J]. *Applied Energy*, 2013, 108: 410-428.
- [58] PINSON P. Very-short-term probabilistic forecasting of wind power with generalized logit-normal distributions[J]. *Applied Statistics*, 2012, 61(4): 555-576.
- [59] KARINIOTAKIS G. Conditional prediction intervals of wind power generation[J]. *IEEE Transactions on Power Systems*, 2010, 25(4): 1845-1856.
- [60] QIN Z, LI W, XIONG X. Estimating wind speed probability distribution using kernel density method[J]. *Electric Power Systems Research*, 2011, 81(12): 2139-2146.
- [61] WAN C, XU Z, PINSON P. Direct interval forecasting of wind power[J]. *IEEE Transactions on Power Systems*, 2013, 28(4): 4877-4878.
- [62] PINSON P, NIELSEN H A, MADSEN H, et al. Skill forecasting from ensemble predictions of wind power[J]. *Applied Energy*, 2013, 86(7): 1326-1334.
- [63] MPRALES J M, MÍNGUEZ R, CONEJO A J. A methodology to generate statistically dependent wind speed scenarios[J]. *Applied Energy*, 2010, 87(3): 843-855.
- [64] SUMAILI J, KEKO H, MIRANDA V, et al. Finding representative wind power scenarios and their probabilities for stochastic models[C] // 2011 16th International Conference on Intelligent System Applications to Power Systems, September 25-28, 2011, Hersonissos, Greece.
- [65] SHARMA K C, JAIN P, BHAKAR R. Wind power scenario generation and reduction in stochastic programming framework[J]. *Electric Power Components and Systems*, 2013, 41(3): 271-285.
- [66] PINSON P, NIELSEN H A, MØLLER J K, et al. Non-parametric probabilistic forecasts of wind power: required properties and evaluation[J]. *Wind Energy*, 2007, 10(6): 497-516.
- [67] GNEITING T, BALABDAOUI F, RAFTERY A. Probabilistic forecasts, calibration and sharpness[J]. *Journal of the Royal Statistical Society*, 2010, 69(2): 243-268.
- [68] 杨茂, 马剑, 李大勇, 等. 超短期风电功率爬坡事件检测和统计分析[J]. *电力系统保护与控制*, 2018, 46(6): 62-68.
- YANG Mao, MA Jian, LI Dayong, et al. Ultra-short-term wind power climbing event detection and statistical analysis[J]. *Power System Protection and Control*, 2018, 46(6): 243-268.
- [69] 张东英, 代悦, 张旭, 等. 风电爬坡事件研究综述及展望[J]. *电网技术*, 2018, 42(6): 1783-1792.
- ZHANG Dongying, DAI Yue, ZHANG Xu, et al. Review and prospect of research on wind power ramp events[J]. *Power System Technology*, 2018, 42(6): 1783-1792.
- [70] KUSIAK A. Prediction of wind farm power ramp rates: a data-mining approach[J]. *Journal of Solar Energy Engineering*, 2009, 131(3): 376-385.
- [71] 甘迪, 柯德平, 孙元章, 等. 基于突变理论的风电爬坡多步预测[J]. *现代电力*, 2016, 33(3): 14-21.
- GAN Di, KE Deping, SUN Yuanzhang, et al. Multi-step wind power ramp forecasting based on catastrophe theory[J]. *Modern Electric Power*, 2016, 33(3): 14-21.
- [72] QIU X, REN Y, SUGANTHAN P N, et al. Short-term wind power ramp forecasting with empirical mode decomposition based ensemble learning techniques[C] // 2017 IEEE Symposium Series on Computational Intelligence (SSCI), November 27 – December 1, 2017, Honolulu, HI, USA.
- [73] OUYANG T, ZHA X, QIN L, et al. Prediction of wind power ramp events based on residual correction[J]. *Renewable Energy*, 2019, 136: 781-792.
- [74] CAO Y, WEI W, WANG C, et al. Probabilistic estimation of wind power ramp events: a data-driven optimization approach[J]. *IEEE Access*, 2019, 7: 23261-23269.

收稿日期: 2019-01-28; 修回日期: 2019-06-11

作者简介:

韩自奋(1976—), 男, 博士, 高级工程师, 研究方向为新能源发电与控制技术研究; E-mail: zifenhanepc@126.com

景乾明(1956—), 男, 硕士, 高级工程师, 研究方向为电力系统智能运行及新能源消纳技术。E-mail: qmjinggepc@163.com

(编辑 周金梅)