基于切换输出机制的超短期风电功率预测

杨 茂,许传宇,王凯旋

(东北电力大学现代电力系统仿真控制与绿色电能新技术教育部重点实验室, 吉林 132012)

摘 要: 超短期风电功率预测可为机组控制和能源经济调度提供重要指导。为削弱风能波动性对于超短期风电功率预测精度的影响,提出了一种引入风速信息的切换输出机制,基于风速与功率的物理模型,分析了风速波动特征。对于波动特征超出门限值的时点,根据机组的惯性运行特性,构建不同风速变化情景下的风速-功率转化模型;对于平缓出力阶段,考虑到时序建模中单一模型的固有限制,提出一种不同运行状态下的超短期预测框架。将所提预测方法用于东北某风电场进行算例验证,结果表明:相比于单一模型的预测结果,所提方法可将均方根误差在 13.58%~16.39%的基础上降低 1.31%~4.12%。研究结果表明,所提方法可以有效提高超短期风功率的预测精度。

关键词:风电功率;超短期预测;人工智能;切换输出机制;时间序列;风速--功率曲线

Ultra-short-term Wind Power Forecasting Based on Switching Output Mechanism

YANG Mao, XU Chuanyu, WANG Kaixuan

(Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education, Northeast Electric Power University, Jilin 132012, China)

Abstract: Ultra-short-term wind power forecasting provides important guidance for unit control and energy economic dispatching. In order to weaken the influence of wind energy volatility on the prediction accuracy of ultra-short-term wind power, a switching output mechanism with wind speed information is proposed to analyze the characteristics of wind speed fluctuation based on the physical model of wind speed and power. For the time point when the fluctuation characteristic exceeds the threshold, according to the inertia operation characteristics of the unit, a wind speed-power conversion model under different wind speed variation scenarios is constructed. For the gentle output stage, considering the inherent limitation of a single model in time series modeling, an ultra-short-term prediction framework under different operating conditions is proposed. The proposed prediction method is applied to a wind farm in Northeast China for example verification. Compared with the prediction results of single model, the proposed method can be utilized to reduce the root mean square error by 1.31%~4.12% on the basis of 13.58%~16.39%. The results show that the proposed method can be utilized to effectively improve the accuracy of ultra-short-term wind power prediction.

Key words: wind power; ultra-short-term prediction; artificial intelligence; switching output mechanism; time series; wind speed-power curve

0 引言

风能是重要的清洁能源,据国际能源署 (International Energy Agency, IEA)^[1]预计,2019年— 2024 年期间,全球可再生能源总装机容量将增长 1 200 GW,增幅达到 50%,陆上风能则占据了增长 中的四分之一。受风能自身的随机性、波动性及间 歇性的影响,风功率呈现出高度不确定性^[2],使得 大规模风电并网给电力系统安全及电能质量带来了 严峻的挑战^[3-4]。因此,精确的功率预测是保证电力 系统稳定运行的基础之一^[5-6]。

超短期风电功率预测指对未来15 min~4 h 内的 风电功率进行预测^[7],主要用于风电机组控制、调 度计划制定及电力系统的经济运行等^[8-9],同时超短 期预测也是进行更长时间预测的基础^[10]。

超短期风电功率预测按照特征来源的不同,可 以分为物理特征建模、时间序列建模、混合特征建 模。物理特征建模是指所建模型的输入为风速、地 形、湍流等物理信息。文献[11]选择风速、温度、

基金资助项目:国家重点研发计划(促进可再生能源消纳的风电/光伏发电功率预测技术及应用)(2018YFB0904200)。

Project supported by National Key R&D Program of China (Technology and Application of Wind Power/Photovoltaic Power Prediction for Promoting Renewable Energy Consumption) (2018YFB0904200).

风向余弦值、风向正弦值、相对湿度和压强6个气 象特征作为输入构建超短期预测模型。物理特征建 模在超短期预测中较少:时间序列建模所建立的模 型输入仅包含带有时序信息的功率值;时序特征建 模在超短期预测模型中较为多见。同时,由于目前 的单一方法均无法适用于所有场景下的预测建模, 因此大量学者对组合模型方法展开了研究。文献 [12-13]对奇异谱分析后的功率时序子序列,分别构 建预测模型后,将子序列的预测结果重新组合作为 最终结果。文献[14-16]分别通过原子稀疏分解、集 成经验模态分解处理时间序列,分别进行建模。文 献[17]基于历史功率时序特征,构建了多个自回归 移动平均模型(autoregressive integrated moving average, ARIMA)模型的组合预测模型。文献[18]提出 了集群风电场的分层自回归组合预测方法。文献[19] 采用了基于误差加权的 ARIMA、人工神经网络、 灰色预测组合方法,并应用于超短期预测,取得了 良好的效果。上述组合方法基于功率子序列或模型 的特点进行了精细化的建模,而符合相应子序列特 点的模型或参数在上述研究中被证明可以有效地减 小误差。混合特征建模指利用风电场自身及周边的 多源特征建立预测模型,即使用物理信息和功率时 间序列直接参与预测。文献[20]通过随机森林提取 不同高度处(numerical weather prediction, NWP)信 息对风电场发电功率的累积贡献率,将根据累计贡 献率加权的 NWP 信息与历史功率数据作为预测模 型的输入变量。文献[21]对功率序列分别进行经验 模态分解与高频分量的变分模态分解,分别建立各 子序列的卷积神经网络和长短期记忆神经网络级联 模型,输入特征为历史功率、风速、风向。文献[22] 分析了空间平均风速和风向的重要性,并将空间平 均风速、风向与历史功率作为输入构建预测模型。

然而,物理特征建模使用的 NWP 信息精度及 更新频率难以满足超短期预测的要求^[23];时间序列 建模的最终目的是识别样本所对应的随机过程,而 不加入天气限制,历史样本可能对应的随机过程有 无数种,只使用功率信息建模的预测过程更多是基 于极短期时间内,气象信息不会发生突变的假设, 而风速的突变在某些时段仍是存在的。在风速的大 幅度波动或爬坡阶段往往会产生较大的预测误 差^[24-25]。混合特征建模目前的研究,更多是对建模 方法的研究,而大数据理论虽然从宏观概念层面可 以完成对输入特征全部有价值信息的提取,然而, 其内部的"黑箱性"难以克服,对于输入特征是否 得到了充分应用难以验证。另外,对于当前研究的 组合方法,大多数是基于"频谱分析—子序列建模 —再集成"的思路,但是根据笔者的测试,其计算 的时效性可能不满足超短期预测的要求;部分基于 历史时序特征的组合预测方法,往往限制于单一方 法的不同参数选择。

针对上述问题,本文提出基于超短期预测的切 换输出机制。基于风速与功率的传变特性,提取风 速波动特征值,并设立波动的门限值,以此为切换 机制的触发条件,在不同的波动情景下采取不同的 预测策略。与当前输入特征固定的混合特征建模不 同的是,所提出的切换输出机制是一种特征类型时 变的混合建模方式。对于波动特征超出门限值的时 点,建立风速-功率转换模型;根据机组的惯性运 行特性,建立不同风速变化场景下的风速-功率转 化模型;采用迭代递进的预测方式,将风速波动信 息纳入到后续建模;同时,对于迭代预测中的时序 建模过程,在现有组合预测方法的基础上,提出了 一种具有时效性的模式划分及动态组合方法。最后, 基于天气特征进行了误差的修正与最终集成。

1 超短期切换输出机制预测的基本思路

由于天气样本的稀疏性,目前尚无法验证天气 系统是否满足预测必须的连续性(连续性是指预测 对象的发展变化规律可以从过去延续到未来,掌握 历史数据的统计规律,就可以在一定程度上把握未 来的情况)^[26],而与之对应的功率时间序列的连续性 同样无法被证明。因此,仅通过对历史功率进行建 模的方法在某些场景下并不适用。但是,完全基于 天气信息建模在超短期预测中的精度又往往较低。

超短期预测在风电功率(或者风速)时序长度充 分大的前提下,可以通过平稳性检验,就认为其满 足弱平稳过程(弱平稳过程的内涵在于期望或方差 不随时间变化,相关函数仅与时间间隔有关)。但是 缩小其时间尺度,功率突变产生的离群点仍然存在, 这就导致仅根据功率时间序列的建模精度可以满足 一定要求,而对于由风速突变导致的功率突变点往 往无法感知。同时,在一个更广阔的时序长度下风 速突变的情况并不少见,其对应的功率突变会导致 预测结果产生较大的误差,并对电力系统造成冲击。

基于上述矛盾,提出了基于超短期风电功率预 测的切换输出机制,即将预测时段的未知风电功率 序列分为两种情景,即平缓出力和功率突变情景。 对于平缓出力,采用传统的时间序列建模;对于功 率突变情景,采用物理特征建模的方法。其输出机 制则根据对应时点的风速波动特征进行决策。

风速突变是导致功率突变的主要天气因素。仅 根据风速自身变化性质进行场景划分的方法可以提 取风速的变化特征,但是该方法对于与之对应的功 率序列波动的刻画可能存在偏差,因此需要引入风 速-功率间的传变特性,以进一步对切换机制的触 发策略展开研究。

若某时刻的风速为 v,则此时风机单位时间内 可捕获的理论功率为

$$P_{\rm M} = \begin{cases} 0, & v < v_{\rm in} \\ \frac{1}{2} C_{\rm p} \rho S v^3, & v_{\rm in} \le v < v_{\rm n} \\ P_{\rm n}, & v_{\rm n} \le v < v_{\rm out} \\ 0, & v \ge v_{\rm out} \end{cases}$$
(1)

式中: v_{in} 表示机组切入风速; C_{p} 表示风能利用系数; ρ 表示空气密度; S表示叶轮扫掠面积; v_{n} 表示机组额定风速; P_{n} 表示风电机组额定功率; v_{out} 表示机组切出风速。

根据风速与功率的物理模型关系,风机运行过 程中,S不发生变化。在 15 min 的时间间隔下, ρ 的变化极其微小,可以忽略。Cp与桨距角等因素有 关,在风速小于额定风速时,风机将持续保持最大 风能跟踪利用状态。因此,相较于传统的风速一阶 差分或风速的爬坡速率等,根据风速3次方提取出 的特征更能体现风速-功率间的传递关系[27]。因此, 在本文中提取风速立方的一阶差分值作为切换机制 触发的标准。设定波动门限值,若当前时点对应风 速与前一时点风速立方的一阶差分值在阈值范围 内,则认为当前时点为平缓出力情景,此时通过历 史风电功率外推对未来时段功率进行预测的基础: 若当前时点对应风速与前一时点风速立方的一阶差 分值超过波动阈值,则认为该时刻为功率突变情景, 此时需引入风速信息,对当前时点通过物理特征 建模。

对于功率突变场景的后续时点及平缓出力时 点,采用迭代递进的预测方法,其具体过程如图 1 所示。每一时点的输出机制根据对应时点的风速波 动值是否超过门限值进行判定。即,若 t+i 时点的 风速波动特征超过门限值,则判定 t+i 时点为功率 突变情景,对于此情景采用天气信息建模进行预测。





后续 t+i+1 时点风速波动特征若超过门限值,则同 样引入天气特征进行预测; 若未超过门限值, 则认 为该点相对前一时点为平缓出力,该时点采用 t 时 刻之前的部分时点,即实测功率,并与 t~t+i 的预测 功率组合为一段新的相同维数的时间序列进行预 测。在 t+i+1 时点的预测过程中,引入了 t+i 时点基 于天气信息得到的预测值,即认为是功率突变情景 下的功率。即使 t+i+1 时刻风速变为平缓,采用时 序外推的方式进行预测,在 t+i+1 时刻的输入也包 括了 t+i 时刻风速突变下的预测功率,即引入了风 速突变的信息。同时,由于时序最近点的相关性一 般为最大,因此在神经网络的训练过程中,会赋予 其较大的权重, 那么 t+i 的风速突变信息就可以被 合理引入到 t+i+1 时点的预测中; 而训练集中同样 包含了功率突变场景的时序外推过程,所以由此训 练得出的模型可以拟合相应情景下的功率。

2 切换输出机制的建模过程

切换输出机制的超短期风电功率预测需要对 功率突变情景和平缓出力情景,即风速-功率转换 过程与时序外推过程分别建模。对功率突变情景建 立不同波动场景的风速-功率曲线模型,对平缓出 力情景建立不同运行状态下的统计外推模型。建模 过程如下所述。

2.1 基于不同波动场景的风速--功率曲线建模

风速-功率曲线从传统意义上来讲是风机生产 厂家通过大量实验针对单台风力发电机组拟合出的 表征风速与发电功率之间关系的曲线。而对场级历 史数据拟合,建立整场风速-功率曲线模型,则可 以实现场级的风速-功率建模。

基于历史数据散点拟合出的整场风速-功率曲 线,在进行风速-功率转换时可能会引起较大误差。 以东北某风力发电场为例,首先对异常场景进行剔 除,统计风速、功率散点如图 2(a)所示。由于风力 发电场内部流场等因素的影响,每个风速值对应的 功率并非唯一确定的,以风速值 10 m/s 为例,其功 率最大值为 92.79 MW,最小值为 66.87 MW。因此, 直接采用风速对整场功率进行回归可能会产生较大 的误差。

在风力发电的过程中,风带动叶片的惯性十分 巨大,当风速发生变化时,叶片转速发生相应的变 化仍需要一定的惯性时间,据此定义风速升高为风 速上升场景,风速降低为风速下降场景。东北某风 力发电场场景划分后的风速-功率散点如图 2(b)所 示,可知在同一风速而处于不同的风速波动场景下 时,风场出力往往存在较大差异。因此,本文分别 在风速上升及风速下降场景中建立风速-功率曲线 模型进行拟合。

2.2 不同运行状态下的统计外推模型

2.2.1 不同运行状态下的超短期预测框架

超短期风电功率预测往往是基于历史功率信 息采用统计外推的方式进行预测的,其方法的内在 依据是假设在极短期的时段内功率不会发生突变。 本文基于这种超短期预测时序外推方法的前置假 设,考虑到时序建模中单一模型的固有限制,建立 一种不同运行状态下的超短期预测时序外推框架, 根据每次预测的最近时间点出力特征进行在线模式 划分,在备选模型库中选择对应的最优模型进行预测。

当前时刻风电功率出力的大小不同,其后续发 电功率经常表现出不同的特征。风电功率将风电功 率序列按照已知时点的大小划分为高出力、中出力 及低出力模式。即:若*P>Yg*,则设定其后续16维 序列为高出力模式;若*Ya*<*Pi*<*Yg*,则设定其后续16 维序列为中出力模式;若*Pi*<*Ya*,则设定其后续16 维序列为低出力模式。其中,*Pi*为*t*时点的风电功 率值,*Yg*、*Ya*分别为划分高、低出力的阈值。本文 对未来4h进行预测,同时设定输入特征同样为16 维。对于高、低出力阈值拟分别设置为容量的30%、 50%。按照以上参数将数据分为不同出力模式,每 种出力模式按照时间序列分组,每组数据内包含16 维,分别统计不同出力模式下的特征值,采用极差



*R、*方差 *D、*平均值*C*及相邻时点最大绝对波动值*B**来表征不同的出力模式,各特征计算式如下:

$$R = \frac{1}{n} \sum_{i=1}^{n} \left(\max(P_i) - \min(P_i) \right)$$
(2)

$$D = \frac{1}{n} \sum_{i=1}^{n} \frac{\sum_{k=1}^{n} (P_{i,k} - \overline{P}_i)^2}{k}$$
(3)

$$\overline{C} = \frac{1}{n} \sum_{i=1}^{n} \left(\frac{1}{k} \sum_{k=1}^{u} P_{i,k} \right)$$
(4)

$$B^* = \frac{1}{n} \sum_{i=1}^{n} \max \left| P_{i,k+1} - P_{i,k} \right|$$
(5)

式中: *n* 为数据组数,即共统计 *n* 组功率数据; *P_{i,k}* 为第 *i* 组、第 *k* 维功率; *u* 为每组功率总维数,在本 文中 *u* 为 16。并定义相邻时点最大波动值 *B*,考虑 了 *B**忽略的波动方向,其表达式为

$$B = \frac{1}{n} \sum_{i=1}^{n} \max\left(P_{i,k+1} - P_{i,k}\right)$$
(6)

对东北某风电场前 8 个月的数据特征进行统 计,其结果如表1所示,可以发现在不同出力模式 下,预测时段功率特征往往呈现不同的特点。值得 说明的是,即使某一段 16 维的时间序列属于某种出 力模式,也并不证明该序列内的每一时点都为该出 力,只能证明该模式下序列的部分特征整体偏向于 某一特性。以本文统计的部分统计特性为例:高出 力下的波动极为剧烈,且相邻时点波动值很大,波 动发生时主要为下降波动;中出力下的波动较为剧 烈,波动方向从数值上为负数,但其大小趋近于0; 此外,中出力下的方差偏大,其相邻时点最大波动 绝对值与最大波动值间差距也较大,说明其仍存在 大量上升方向波动点,波动方向并不确定;低出力 情况下,整体情况较为平缓,且大波动发生时主要 为上升方向波动。从整体上看,风电功率出力模式 更倾向于低出力状态。

在不同模式下,风电功率时间序列呈现出不同 的特性,而单一的模型无法完整描述所有模式的出 力特点,针对这种情况,本文构建了一种针对不同 模式下的超短期风电功率预测框架,如图3所示。 设立备选模型库,通过验证集检验选择各模式下的 最优模型,用于测试集数据。其具体流程如下:

 1)设置不同出力模式下的阈值,划分训练集、 验证集、测试集,选定多种备选方法。

 2)将训练集数据按照当前时刻出力进行模式 划分。

3)各出力模式下训练集数据分别采用各备选 方法进行训练,并将训练好的模型放入备选模型库。

4)将备选模型库中的模型放入验证集进行检验,得出各出力模式下的最优模型。

5) 将各模式下的最优模型用于测试集。

2.2.2 BAS 搜索算法

由于人工智能方法在统计方法领域的优越表现,在多模式预测框架中,其主要用来选择各类神 经网络模型放入备选模型库。然而,神经网络随机 初始参数的选取会对预测精度造成影响,在验证集 中将影响模型的选择,进而影响最终的预测效果。 天牛须搜索(beetle antennae search, BAS)算法^[28]具 有灵活性、简易性及能够规避局部最优解等特点, 为了保证整体预测架构的稳定性,本文选取 BAS 算法对平缓出力情景所建立模型的初始参数选取过 程进行优化。

BAS 算法是结合了天牛在捕食过程中的检测 和搜索行为而提出的一种新的启发式算法。当天牛 寻找食物时,它会通过身体一侧的触角来接收气味。 利用两个触角在附近区域进行探测,当一侧的触角 检测到的气味具有较高浓度时会转向该侧,否则会

表1 不同出力模式下的功率特征

Table 1	Power characteristics in different output modes					
出力模式	R	D	\overline{C}	В	B^{*}	
高出力	46.053	271.300	45.794	-16.299	25.848	
中出力	30.858	124.185	31.600	-4.453	17.059	
低出力	14.674	47.448	10.423	2.396	8.158	



图 3 不同运行状态下的时序外推预测框架

Fig.3 Time series extrapolation prediction framework under different operating conditions

转向另一侧。

首先,对搜索行为进行建模,用式(7)来描述甲 虫搜索的随机方向。

$$\boldsymbol{b} = \frac{\operatorname{rand}(k,1)}{\left\|\operatorname{rand}(k,1)\right\|'} \tag{7}$$

式中: **b** 表示天牛在解空间中的随机方向; rand(·) 表示随机函数; *k* 表示位置的维数。

假设天牛个体 *t*(*t*=1, 2, …)时刻在多维解空间 中的位置为矢量 *x*^{*t*},则其两侧触角的搜索行为如(8) 式所示。

$$\begin{cases} \boldsymbol{x}_{r} = \boldsymbol{x}^{t} + d^{t}\boldsymbol{b} \\ \boldsymbol{x}_{l} = \boldsymbol{x}^{t} - d^{t}\boldsymbol{b} \end{cases}$$
(8)

式中: xr 表示位于右侧搜索区域中的位置; xi 表示 左侧搜索区域中的位置; d' 是 t 时刻与搜索能力相 对应的触须感应长度,其大小应覆盖足够的搜索区 域,使搜索过程在开始时从局部最小点跳出来,然 后随着时间的推移而逐渐缩小范围。

随后,为了描述气味检测行为,考虑搜索行为

与气味检测相关联,进一步生成式(9)所示的迭代模型。

 $\boldsymbol{x}^{t} = \boldsymbol{x}^{t-1} + \delta^{t} \boldsymbol{b} \operatorname{sign} \left(f\left(\boldsymbol{x}_{r}\right) - f\left(\boldsymbol{x}_{1}\right) \right)$ (9)

式中: δ 是搜索的步长,代表在 t 时刻为递减函数时的收敛速度, δ 初始值等于搜索区域。f(x)为适应度函数; sign()表示符号函数,若 x_r 附近适应度大于 x_1 适应度,则该符号函数取 1,天牛个体将在向前时刻的 b 方向上前进 δ 步长;反之,则向 b的负方向移动 δ 步长。

根据触须感应长度 d 和步长 δ 等搜索参数特定,参数更新规则如下:

$$\begin{cases} d^{t} = 0.95d^{t-1} + 0.01\\ \delta^{t} = 0.95\delta^{t-1} \end{cases}$$
(10)

让*d*和δ都以0.95的斜率随迭代次数做自适应 线性变化。

基于上述搜索过程,对验证集模型选取及模型 确定后的离线训练过程模型参数分别寻优。

3 整体预测模型的建立

本文以东北某容量为 99 MW 的风电场 2012 年 1月1日—2012 年 9月6日的数据为研究对象,时 间间隔为 15 min,其中前 200 d 为训练集;采用随 后 42 d 的数据对多模式下的最优方法进行验证,设 置为验证集;通过剩余数据对提出方法的有效性进 行测试,设置为测试集。所选择的测试集发生弃风 限电情况较少,可以削弱数据处理对于方法验证的 影响。训练集风速为风电场机组平均风速,验证集 及测试集风速来源为 NWP 100 m 风速,基于文献 [29]的方法进行修正。以 1 m/s 的区间建立映射模 型。输入为 t 及 t+1 时刻的 NWP 风速,采用极限学 习机(extreme learning machine, ELM)模型进行修正。

对于各模式下最优模型的备选方法包括: ELM、ELMAN 神经网络、反向传播(back propagation, BP)神经网络、长短期记忆(long-short term memory, LSTM)神经网络、广义回归神经网络 (generalized regression neural network, GRNN)、径 向基(radial basis function, RBF)神经网络。为避免 随机初始参数对方法选择的干扰,各模型均采用 BAS 算法进行优化,并重复 10 次实验,取结果的 算术平均值。对验证集数据在不同运行状态下各模 型的误差进行测试,统计结果如表 2 所示。将均方 根误差(root mean square error, RMSE)*R*rmse 作为方 法选择的依据,其表达式为

表 2 不同运行状态下不同方法的 RMSE 对比	Ľ
--------------------------	---

 Table 2
 RMSE comparison of different methods under

different	running	condi	tions

## 开门	RMSE				
快至	高出力	中出力	低出力		
ELM	0.245 3	0.180 4	0.106 8		
ELMAN	0.276 3	0.233 1	0.115 7		
BP	0.288 5	0.199 8	0.119 3		
LSTM	0.233 4	0.363 9	0.104 2		
GRNN	0.205 5	0.183 3	0.108 1		
RBF	0.338 7	0.218 4	0.114 4		

$$R_{\rm rmse} = \sqrt{\frac{\sum_{i=1}^{m} (y_i - \hat{y}_i)^2}{mC_{\rm ap}^2}}$$
(11)

式中: y_i 为 i 时刻的实际功率; \hat{y}_i 为 i 时刻的预测功率序列; m 为待评价时点的个数; C_{ap} 为风电场装机容量。

根据验证集精度对比结果,在高、中、低出力 模式时,GRNN、ELM、LSTM 模型的精度分别达 到最高。在各运行状态下,分别调用对应模型进行 预测。

同时,由于超短期预测固有的时滞偏差,根据 天气情况建立误差修正模型,建立 ELMAN 修正模 型,输入为基于灰色关联分析得到的 NWP 特征, 具体分析过程见附录 A,模型输出为预测误差。

对于算例数据集,可建立整体预测框架如图 4 所示。对于切换输出机制的触发条件,即波动的门 限值大小,基于试错法得出,结果如图 5 所示。分 别设定上、下两个方向的门限值,上限为最大正波 动的 20%,下限为最大负波动的 10%,超过门限值 则触发切换机制。

4 算例分析

4.1 评价标准

根据《风电功率预测功能规范 Q/GDW 10588—2015》^[7],除均方根误差外,本文选择极大误差率 r₁,合格率 r₂、平均绝对误差 M_{mape}、相关系数 *I* 作为评价标准,根据文件要求,对第 4 h 的数据进行考核,计算式如下:

$$r_{1} = \max\left(\frac{|y_{i} - \hat{y}_{i}|}{C_{ap}}\right)$$
(12)

$$r_2 = \frac{1}{m} \sum_{i=1}^{m} B_i \times 100\%$$
(13)



图 4 整体预测框架









(

1

$$M_{\rm mape} = \frac{1}{m} \sum_{i=1}^{m} \frac{|y_i - \hat{y}_i|}{C_{\rm ap}} \times 100\%$$
(14)

$$I = \frac{\operatorname{cov}(y, \hat{y})}{\sqrt{D(y)D(\hat{y})}}$$
(15)

$$\begin{cases} \left(1 - \frac{|y_i - y_i|}{C_{ap}}\right) \times 100\% \ge 75\%, B_i = 1\\ \left(1 - \frac{|y_i - \hat{y}_i|}{C_{ap}}\right) \times 100\% < 75\%, B_i = 0 \end{cases}$$
(16)

式中: cov()表示协方差; D()表示方差; Bi表征了第

~1)

426

其中

i 个预测值是否满足合格率标准,若满足标准则 *Bi*=1,否则*Bi*=0。

4.2 结果分析

根据本文提出的预测方法,对测试集数据进行 实验。设置实验模型如下:输入特征为历史功率的 单一模型(P-GRNN、P-ELM、P-LSTM);无切换机 制的两种方法,即输入仅为历史功率的的组合模型 (combination model, CM)(输入仅为功率)和波动场 景划分后的风速-功率曲线模型(wind speed-power curve, WSPC)(输入仅为功率);基本对比方法持续 法(Persistence)及本文方法。测试集统计结果如表 3 所示。

由表3可知,根据均方根误差和平均绝对误差 统计可知,3种单一方法中,LSTM 模型的效果较 好,GRNN 模型会引入较大的误差区间,而不同运 行状态下的组合方法优于3种单一方法。超短期预 测中的WSPC模型结果的相关系数普遍优于仅采用 功率的建模方式,这说明基于天气信息的建模方法 对变化趋势的追踪效果较好;但是其 RMSE 较大, 即完全采用风速-功率曲线的建模并不适用于超短 期预测。而本文提出方法在功率突变的情景下引入 了精细化的风速-功率曲线,可降低整体误差,优 于两种不进行切换的建模方法;同时,弥补了传统 时序外推方法无法识别未来天气变化的缺陷。对切 换输出机制中时间建模部分的 CM 方法与单一模型 对于测试数据集的运行时间进行了统计,结果如表 4 所示。运行平台为 MATLAB 2018a。CM 方法的 运行时间与3种单一建模方法相比并无明显升高, 且对于测试数据集而言,其仍然满足预测的时效性。

极端误差事件的出现会造成对风场及电网的 冲击,本文对于各方法绝对误差绘制的箱线图进行 了统计,如图 6(a)所示。同时,设定误差超过容量 的 40%即为极端误差事件,分别对于极端正、负误 差事件的频率统计如图 6(b)所示。整体绝对误差区 间统计见附录 A 图 A1。结合表 3 合格率及极大误 差率统计结果分析可知,ELM、CM、WSPC 与本 文方法偏向于正向极端误差,而 GRNN、LSTM 与 持续法偏向于负向的极端误差;但是,本文所提方 法小误差分布较其他方法更为集中,中位线与上下 四分位线均低于其他几种方法,效果明显优于其他 模型;WSPC 模型与功率时序外推模型相比其误差 整体偏大,同时引入的极端正误差频率明显高于时 序外推模型,但是 WSPC 模型在极端负误差的消除

表 3 不同方法预测误差对比结果对比

Table 3 Comparison of prediction errors of different methods

方法	R _{rmse}	r_1	r_2	$M_{\rm mape}$	Ι
P-GRNN	0.163 9	0.711 8	0.867 7	0.135 0	0.178 4
P-ELM	0.149 2	0.571 5	0.855 9	0.122 7	0.171 1
P-LSTM	0.135 8	0.525 8	0.884 6	0.114 2	0.297 2
CM	0.129 1	0.569 7	0.905 8	0.108 4	0.265 8
WSPC	0.150 6	0.642 3	0.879 3	0.110 6	0.446 3
Persistence	0.167 8	0.651 9	0.842 4	0.130 8	0.250 1
本文方法	0.122 7	0.524 0	0.929 2	0.096 8	0.423 8

表4 时序外推 CM 方法与单一模型运行时间

 Table 4
 Running time of CM method and single Model

 to time series extrapolation

方法	P-GRNN	P-ELM	P-LSTM	СМ	
运行时间/s	161	12	166	171	

上具有明显优势,这同样体现在基于切换输出机制 所建立的模型中。

选择两次切换机制发生作用的预测进行对比, 结果如图 7 所示,图 7(a)中识别机制起到正向作用, 而图 7(b)中识别机制降低了预测的精度。对于造成 误判的原因,分析如下:

1) NWP 中风速值预报偏差。

 2)风电场自身设备故障或故障修复后重新启 动使得整场出力与风特性不相符。

3)风电场存在弃风限电现象。

但是,即使对于第2种误判场景来说,随后的时点也仍可以追踪功率变化,第7个时点重新调整为上升趋势,基于两次对比及定量统计结果可以看出,所提切换输出机制的多模式预测方法具有一定的优势。

5 结论

 超短期风电功率预测的切换输出机制可以 有效弥补时序外推模型无法识别未来天气变化的缺 陷,同时削弱 NWP 建模所引起的极端误差。

2)以NWP为输入的预测模型与功率时序外推模型相比,在波动趋势的识别中更有优势,超短期预测的切换输出机制在物理特征建模部分分别拟合上升、下降风速-功率曲线,可以及时追踪天气突变引起的功率变化。

3)单一模型在风电功率预测中的固有限制很 难消除,本文在时序外推建模部分所提出的模式划 分方法可有效结合多个模型的优点。



同时,本文所提方法仍存在提升空间。在时序 外推建模部分的模型库中,本文只选取了几种常用 的模型做为备选,随着更先进人工智能方法的发展, 该模型库仍可继续扩充,从而不断提高预测精度。 本文所提方法的缺陷在于对于 NWP 风速的精度具 有较高要求,下一步的工作重点是在论文所提方法 的基础上,减弱低精度预报时点的影响,考虑引入 NWP 的趋势特征。

附录见本刊网络版(http://hve.epri.sgcc.com.cn/ CN/volumn/current.shtml)。



参考文献 References

- International Energy Agency. Renewables 2019[EB/OL]. (2020-10-20). https://www.iea.org/reports/renewables-2019.
- [2] YANG M, SHI C Y, LIU H Y. Day-ahead wind power forecasting based on the clustering of equivalent power curves[J]. Energy, 2021, 218: 119515.
- [3] 杨子民,彭小圣,郎建勋,等.基于集群动态划分与 BLSTM 深度 学习的风电集群短期功率预测[J].高电压技术,2021,47(4): 1195-1203.
 YANG Zimin, PENG Xiaosheng, LANG Jianxun, et al. Short-term wind power prediction based on dynamic cluster division and BLSTM deep learning method[J]. High Voltage Engineering, 2021, 47(4): 1195-1203.
 [4] 孙荣富,张 涛,和 青,等.风电功率预测关键技术及应用综述
- [4] 孙禾富, 永 禄, 和 百, 寻. 风电为平顶侧天健设不及应用综定
 [J]. 高电压技术, 2021, 47(4): 1129-1143.
 SUN Rongfu, ZHANG Tao, HE Qing, et al. Review on key technologies and applications in wind power forecasting[J]. High Voltage Engineering, 2021, 47(4): 1129-1143.
- [5] 孟安波,陈嘉铭,黎湛联,等. 基于相似日理论和 CSO-WGPR 的 短期光伏发电功率预测[J]. 高电压技术, 2021, 47(4): 1176-1184. MENG Anbo, CHEN Jiaming, LI Zhanlian, et al. Short-term photo-

voltaic power generation prediction based on similar day theory and CSO-WGPR[J]. High Voltage Engineering, 2021, 47(4): 1176-1184.

- [6] 杨 茂, 王凯旋. 基于 CEEMD-DBN 模型的光伏出力日前区间预 测[J]. 高电压技术, 2021, 47(4): 1156-1164. YANG Mao, WANG Kaixuan. Day-ahead interval forecasting of PV power based on CEEMD-DBN model[J]. High Voltage Engineering, 2021, 47(4): 1156-1164.
- [7] 国家电网公司.风电功率预测功能规范:Q/GDW 10588-2015[S], 2016.

State Grid Corporation of China. Function specification of wind power forecasting: Q/GDW 10588-2015[S], 2016.

- [8] POTTER C W, NEGNEVITSKY M. Very short-term wind forecasting for Tasmanian power generation[J]. IEEE Transactions on Power Systems, 2006, 21(2): 965-972.
- [9] 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.
- [10] ERNST B, OAKLEAF B, AHLSTROM M L, et al. Predicting the wind[J]. IEEE Power and Energy Magazine, 2007, 5(6): 79-89.
- [11] 彭晨宇,陈 宁,高丙团.结合多重聚类和分层聚类的超短期风电 功率预测方法[J]. 电力系统自动化, 2020, 44(2): 173-180. PENG Chenyu, CHEN Ning, GAO Bingtuan. Ultra-short-term wind power forecasting method combining multiple clustering and hierarchical clustering[J]. Automation of Electric Power Systems, 2020, 44(2): 173-180
- [12] ZHANG Y C, LE J, LIAO X B, et al. A novel combination forecasting model for wind power integrating least square support vector machine, deep belief network, singular spectrum analysis and locality-sensitive hashing[J]. Energy, 2019, 168: 558-572.
- [13] WANG C, ZHANG H L, MA P. Wind power forecasting based on singular spectrum analysis and a new hybrid Laguerre neural network[J]. Applied Energy, 2020, 259: 114139.
- [14] 肖 白,房龙江,李介夫,等.空间负荷预测中确定元胞负荷最大 值的经验模态分解方法[J]. 东北电力大学学报, 2018, 38(3): 8-14. XIAO Bai, FANG Longjiang, LI Jiefu, et al. An EMD method for ascertaining maximal value of cellular load in spatial load forecasting[J]. Journal of Northeast Electric Power University, 2018, 38(3): 8-14.
- [15] 杨 茂,刘慧宇,孙 勇,等.基于原子稀疏分解和支持向量机的 风电功率实时预测研究[J]. 东北电力大学学报, 2020, 40(3): 1-7. YANG Mao, LIU Huiyu, SUN Yong, et al. A study on real-time prediction of wind power based on atomic sparse decomposition and support vector machine[J]. Journal Of Northeast Electric Power University, 2020, 40(3): 1-7.
- [16] 李国庆,张 钰,张明江,等. 基于 MRMR 的集合经验模态分解 和支持向量机的风电功率实时预测[J]. 东北电力大学学报, 2017, 37(2): 39-44 LI Guoqing, ZHANG Yu, ZHANG Mingjiang, et al. The wind power real-time diction on the EEMD and SVM of the MRMR[J]. Journal of

Northeast Electric Power University, 2017, 37(2): 39-44. [17] 郁 琛,薛禹胜,文福拴,等.按时序特征优化模型后在线选配的 超短期风电预测[J]. 电力系统自动化, 2015, 39(8): 5-11. YU Chen, XUE Yusheng, WEN Fushuan, et al. An ultra-short-term

wind power prediction method using "offline classification and optimization, online model matching" based on time series features[J]. Automation of Electric Power Systems, 2015, 39(8): 5-11.

- [18] ZHANG Y, DONG J J. Least squares-based optimal reconciliation method for hierarchical forecasts of wind power generation[J]. IEEE Transactions on Power Systems, 2018: 1.
- [19] KORPRASERTSAK N, LEEPHAKPREEDA T. Robust short-term prediction of wind power generation under uncertainty via statistical interpretation of multiple forecasting models[J]. Energy, 2019, 180:

387-397.

- [20] 杨 茂, 白玉莹. 基于多位置 NWP 和门控循环单元的风电功率超 短期预测[J]. 电力系统自动化, 2021, 45(1): 177-183. YANG Mao, BAI Yuying. Ultra-short-term prediction of wind power based on multi-location numerical weather prediction and gated recurrent unit[J]. Automation of Electric Power Systems, 2021, 45(1): 177-183
- [21] YIN H, OU Z H, HUANG S Q, et al. A cascaded deep learning wind power prediction approach based on a two-layer of mode decomposition[J]. Energy, 2019, 189: 116316.
- [22] LAHOUAR A, SLAMA J B H. Hour-ahead wind power forecast based on random forests[J]. Renewable Energy, 2017, 109: 529-541.
- [23] 薛禹胜,郁 琛,赵俊华,等.关于短期及超短期风电功率预测的 评述[J]. 电力系统自动化, 2015, 39(6): 141-151. XUE Yusheng, YU Chen, ZHAO Junhua, et al. A review on short-term and ultra-short-term wind power prediction[J]. Automation of Electric Power Systems, 2015, 39(6): 141-151.
- [24] 薛禹胜, 雷 兴, 薛 峰, 等. 关于风电不确定性对电力系统影响 的评述[J]. 中国电机工程学报, 2014, 34(29): 5029-5040. XUE Yusheng, LEI Xing, XUE Feng, et al. A review on impacts of wind power uncertainties on power systems[J]. Proceedings of the CSEE, 2014, 34(29): 5029-5040.
- [25] GALLEGO-CASTILLO C, CUERVA-TEJERO A, LOPEZ-GARCIA O. A review on the recent history of wind power ramp forecasting[J]. Renewable and Sustainable Energy Reviews, 2015, 52: 1148-1157.
- [26] 乔 颖,鲁宗相,闵 勇.提高风电功率预测精度的方法[J]. 电网 技术, 2017, 41(10): 3261-3268. QIAO Ying, LU Zongxiang, MIN Yong. Research & application of raising wind power prediction accuracy[J]. Power System Technology, 2017, 41(10): 3261-3268.
- [27] FAN H, ZHANG X M, MEI S W, et al. M2GSNet: multi-modal multi-task graph spatiotemporal network for ultra-short-term wind farm cluster power prediction[J]. Applied Sciences, 2020, 10(21): 7915.
- [28] JIANG X Y, LI S. BAS: beetle antennae search algorithm for optimization problems[J]. International Journal of Robotics and Control, 2018, 1(1): 1.
- [29] WANG H, HAN S, LIU Y Q, et al. Sequence transfer correction algorithm for numerical weather prediction wind speed and its application in a wind power forecasting system[J]. Applied Energy, 2019, 237: 1-10.



1982--, 男, 博士, 教授, 硕导 主要研究方向为新能源并网及电力系统稳定性分 析等 E-mail: yangmao820@163.com

YANG Mao Ph.D., Professor



许传宇(通信作者) 1996--,男,硕士生 主要研究方向为新能源发电功率预测 E-mail: 2463584212@qq.com

XU Chuanyu Corresponding author

收稿日期 2020-10-25 修回日期 2021-05-10 编辑 何秋萍

附录 A

对误差的修正通过灰色关联分析 NWP 与误差的关联特性,基于 ELMAN 神经网络建立天气特征-误差的映射模型,本文对于 NWP 24 个特征进行关联度计算,所统计的 NWP 特征名称及含义如表 A1 所示,按关联程度从高至低计算结果如表 A2 所示,选择前 9 名特征输入误差修正模型。

			e e		
特征名称	特征含义	特征名称	特征含义	特征名称	特征含义
momf	动量通量	Ps	压强	pr	对流降水
Т	温度	prt	总降水	T2m	2 m 温度
ws170	170 m 风速	dir170	170 m 风向	senf	潜热通量
ws100	100 m 风速	dir100	100 m 风向	latf	感热通量
ws30	30 m 风速	dir30	30 m 风向	swr	短波辐射
ws10	10 m 风速	dir10	10 m 风向	lwr	长波辐射
ws10s	10 m 海上风速	dir10s	10 m 海上风向	prl	大尺度降水
mslp	10 m 海平面气压	clc	分数云[0-1]	RH	2m相对湿度

表 A1 NWP 特征名称及含义

Table A1 NWP feature name and meaning

表 A2 NWP 特征与误差关联度统计

Table A2 NWP characteristics and error correlation statistics

特征名称	关联度	特征名称	关联度	特征名称	关联度
momf	0.798 9	ws170	0.780 7	ps	0.764 8
ws10	0.797 0	prl	0.780 2	lwr	0.763 7
ws30	0.794 0	prt	0.779 4	RH	0.756 9
ws10s	0.790 9	mslp	0.775 8	dir170	0.745 2
Т	0.787 6	prc	0.774 7	dir100	0.744 7
T2m	0.785 8	senf	0.772 8	dir30	0.743 9
ws100	0.784 4	latf	0.771 1	dir10s	0.731 8
swr	0.780 9	clc	0.769 5	dir10	0.731 8



