

# 基于趋势融合 NWP 风速校正的短期风电功率预测

杨茂<sup>1</sup>, 车润棋<sup>1</sup>, 王勃<sup>2</sup>

(1. 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(东北电力大学), 吉林省 吉林市 132012; 2. 新能源与储能运行控制国家重点实验室, 中国电力科学研究院有限公司, 北京市 100192)

## Short-term Wind Power Prediction Based on Trend-fused NWP Wind Speed Correction

YANG Mao, CHE Runqi, WANG Bo

(1. Key Laboratory of Modern Power System Simulation Control and New Green Power Technology, Ministry of Education (Northeast Electric Power University), Jilin 132012, Jilin Province, China;

2. State Key Laboratory of New Energy and Energy Storage Operation Control, China Electric Power Research Institute Co, Beijing 100192)

**摘要:**近年来,随着风电并网装机容量的不断增长,准确的风电功率预测是保证电力系统安全稳定运行的基础之一。当前基于数据驱动模式的短期功率预测主要输入为数值天气预报,其预报准确性导致了短期功率预测的精度无法得到有效提升。针对这一问题,本文提出了一种基于 NWP 风速校正的短期风电功率预测方法,利用风速趋势构建新的输入特征,通过趋势和数值的耦合作用建立校正模型以校正 NWP 风速,并应用于短期风电功率预测中。将本文方法应用于中国蒙西两个风电场,预测精度分别提升了 2.3% 和 1.2%。验证了本文方法的有效性。

**关键词:** 数值天气预报; 趋势耦合; 注意力机制; 短期风电功率预测

**ABSTRACT:** In recent years, with the steady increase of installed wind capacity in the power grid, accurate wind power forecasting is one of the fundamentals to ensure safe and stable operation of the power system. The current data-driven short-term capacity prediction is mainly based on numerical weather prediction, and the accuracy of this prediction leads to the inability to effectively improve the accuracy of short-term capacity prediction. In response to this issue, this paper proposes a short-term wind power prediction method based on NWP wind speed correction, which utilizes the wind speed trend to construct a new input feature, and establishes a correction model through the coupling effect of the trend and the numerical value in order to correct the NWP wind speed, and applies it to the short-term wind power prediction. Applying the method of this paper to two wind farms in Mengxi, China, the prediction accuracy is improved by 2.3% and 1.2%, respectively. The effectiveness of the method of this paper is verified.

**KEY WORD:** numerical weather forecast; deep learning; trend coupling; short term wind power prediction

## 1 引言

为实现“碳达峰、碳中和”双碳目标,对构建以新能源为主的新型电力系统有重要意义<sup>[1]</sup>。并且在“四个革命、一个合作”国家电力安全新战略的科学指引下,我国的风能等新能源实现了飞跃式的突破发展。风能由于其自身蕴量丰富、无污染和可再生等独特优点,在能源系统转型的

当代,在时代理念、技术革命和供给转变的节点上,已逐步替代一次能源,推动能源经济的蓬勃发展<sup>[2-5]</sup>。随着风电并网装机容量的不断增长,风能其不可避免的间隙性、波动性和随机性,为电力系统的实时运行提出了挑战。短期风电功率预测主要针对未来一天的时间尺度,用于调整日发电计划与检修计划,以及计划冷备用等。由此,

实现风电功率的高精度的短期预测就格外重要。当前的风电功率预测方法根据建模原理和输入方式可分为两大类：物理方法和统计方法。其中物理方法主要借助目标风电场的各类气象信息，如数值天气预报(numerical weather prediction, NWP)中的风速，风向和气压等信息，进而使用数学模型，研究各气象信息的变化过程，从而完成对风电功率的预测。统计方法主要基于历史测量数据进行预测，其核心思想是映射序列之间的内部关系，并通过构建的模型学习样本数据间的映射关系，从而在未知时段的未知数据中进行泛化以实现功率预测。常见的统计模型有支持向量机回归、关联向量机(relevance vector machine, RVM)、随机森林(random forest, RF)、人工神经网络(artificial neural network, ANN)和深度学习等。当前，注意力机制(Attention)模型在处理有关自然语言领域内的问题获得了显著的效果，且其应用范围得到了进一步的扩展。而风电功率作为典型的时间序列，门控逻辑单元(gated recurrent unit, GRU)作为典型的深度学习模型，由其结构简单和计算速度快等优势作为当前时间序列预测的主要选择，Attention与GRU结合可使其突出预测时关键的信息。

统计方法根据预测模型的输入不同，又可分为两类，其中一类主要基于历史的测量功率进行预测，另一类为更能准确跟踪风电功率短期预测时段内的功率变化趋势，使用模型捕捉描述NWP数据和同时点的实测风电功率之间的关系，即在模型中将数值天气预报中的气象数据作为输入进行预测。由此，在以数据驱动模型为风电功率主流预测模型的背景下，NWP数据的准确性格外重要，其中风速作为关键气象要素更是对短期风电功率预测精度有着严重影响<sup>[6-9]</sup>。

而NWP数据的发布间隔长，报告的风速数据高度可能与风电机组的轮毂高度不一致，从而导致NWP风速数据与风电场测量的风速数据之间不可避免地存在差异，必须对这些差异进行修正，以进一步提高风功率预测的准确性。

当前已有学者针对NWP风速的校正进行了大量研究。文献[10]在风速空间相关性的基础上，利用高斯过程回归(Gaussian process, GP)对NWP风速进行修正。考虑到单一模型的泛化能力不足，

文献[11]结合注意力机制和门控逻辑单元对数值天气预报风速进行了校正，文献[12]在对时间序列进行相关性检验的基础上，应用残差通道注意力网络模型对NWP风速误差进行修正。文献[13]考虑NWP风速前后时点的序列传递关系，并通过5种常用算法模型进行验证，结果表明可有效改善NWP风速的校正精度。文献[14]定义NWP风速纵向误差，并计算提取其标准差作为权重，进而得到NWP风速的权重时间序列，通过门控神经网络模型进行短期的风电NWP风速误差校正。文献[15]从多位置NWP风速间的关联性出发，考虑各序列间的时空耦合特性，基于此提出一种多点的NWP风速集中式校正方法。

综上所述，当前短期风电功率预测依赖于NWP作为主要输入，NWP的精度导致短期功率预测精度无法得到有效提升，由于目前NWP风速的校正方法研究集中于对实测风速建立映射关系，其对风速物理变化过程的挖掘尚不完全，难以实现有效的NWP风速校正。针对上述问题，本文提出了一种基于趋势融合NWP校正的短期风电功率预测方法，本文主要贡献如下：首先提取风速趋势，充分挖掘NWP风速物理变化过程；其次融合风速趋势作为输入特征，采用Attention-GRU建立风速校正模型；最后通过耦合风速趋势和NWP风速提高校正精度，再将校正后的NWP风速作为预测输入。通过蒙西某两个风电场中不同模型的算例进行仿真，验证了本文方法的有效性。

## 2 NWP 风速误差的概率密度分布

NWP系统一般都能较好的模拟气象系统在较大区域的变化趋势，但由于NWP预报中心和风电场之间存在着天气条件、地形参数上的局地差别等，使得NWP风速中心和风电场实际速度之间的偏差，成为了风电功率短期预报偏差的重要来源。本文以蒙西某风电场以15min为时间分辨率的实测风速和NWP风速数据，采用高斯分布拟合不同场景下的风速误差。

NWP风速误差的计算公式如下：

$$v_{error}(t) = v_{NWP}(t) - v_m(t) \quad (1)$$

式中： $v_{NWP}(t)$ 表示在 $t$ 时刻的NWP风速， $v_m(t)$ 表示在 $t$ 时刻的实测风速。

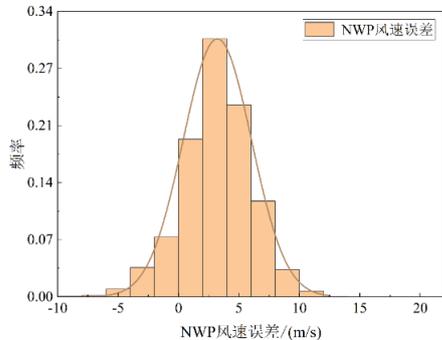


图1 风电场1中总体NWP风速误差的概率密度分布  
Fig.1 Probability density distribution of NWP total wind speed error in wind farm 1

对于案例风电场可以得出：

1) 采用ND对整体预报误差进行拟合，其概率密度分布如图1所示。对于正误差，最大值和平均值分别为20.356m/s和3.888m/s。对于负误差，最大值和平均值分别为-8.976m/s和-1.876m/s。然而，数值预报误差的分布范围较大，难以直接采用NWP风速与实测风速通过模型建立正确映射关系，因此需要构建新的输入特征以限制误差分布范围，从而建立正确的映射关系。

2) 将NWP风速分割成1m/s的间隔，并计算每个间隔的误差。如图2所示，即使考虑一个小的NWP风速间隔，NWP风速的误差范围依然很大。每个间隔的最大误差可达12m/s，最小误差约为2m/s。NWP预报误差在各个区间内都有较广的误差分布范围。

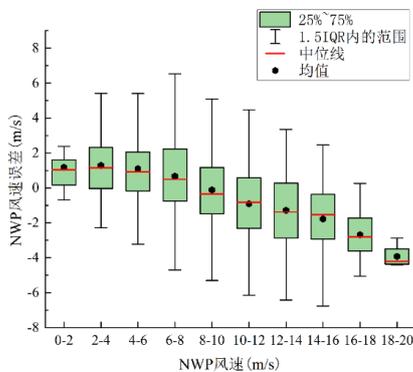


图2 风电场1中NWP风速误差范围箱线图  
Fig.2 Boxplot of NWP wind speed error range in wind farm 1

为了分析NWP风速误差在各间隔中的概率密度分布，根据NWP风速误差的范围和功率曲线，选取了2-4m/s、6-8m/s、10-12m/s和14-16m/s四个间隔。从图3中可以看出，在2-4m/s等尺度上，NWP风速误差在不同尺度上的频率呈现不同的形状，ND能很好地拟合。表1中列出了这些间隔中的NWP风速误差的统计。以6-8m/s的NWP风速间隔为例，误差范围为-6米/秒至7米/秒。这意味着即使在小间隔中，NWP风速与实测风速之间的对应关系仍然并不清晰，这是导致现有校正算法性能不佳的重要因素之一。因此，更多的影响因素应被作为在风速校正过程的输入。

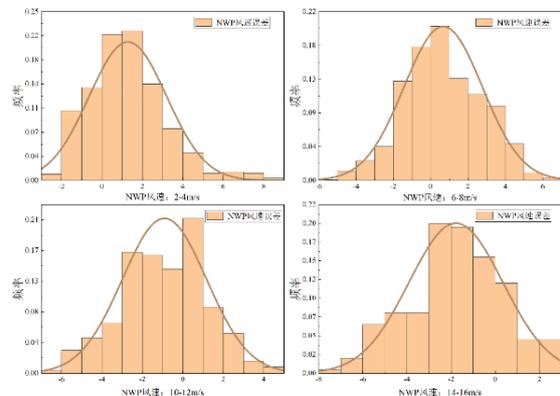


图3 风电场1中不同风速范围NWP风速误差的概率密度分布

Fig.3 Probability density distribution of NWP wind speed errors for different wind speed ranges in wind farm 1

通过有效的方法限制误差的分布范围是校正模型的核心，升降趋势作为风速的另一重要特征，有必要分析其是否能与数值大小共同作用以限制NWP风速误差的分布范围。

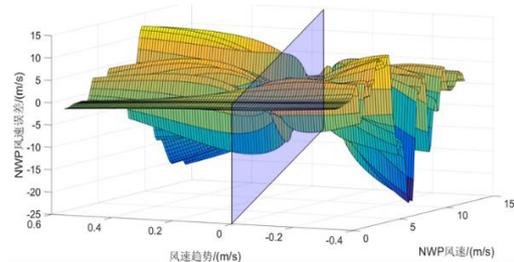


图4 风电场1的NWP风速误差三维分布示意图  
Fig.4 Schematic of the 3D distribution of NWP wind speed errors for wind farm 1

图4为误差的三维分布示意图。如图4所示，

误差在双重因素的影响下,形成了明显的波峰波谷式分布,在上升风和下降风的区域内,均有着不同长度、陡度的波峰波谷。

图5为NWP风速误差的类等高图。图中可以较为明显地看出波峰波谷的分布,发现以上升风、下降风划分成的两大区域,高误差大部分分布在上升风区域。但是即使在同一上升风区域,仍有较为明显的颜色分区,NWP风速较大区域的误差就要普遍高于NWP风速较小区域。所以依据风速趋势和NWP风速数值大小进行划分,图中划分为8个区域,可见同一区域的颜色相似,不同区域的颜色存在明显差异性,即NWP风速误差分布范围在双重因素的作用下得到了有效的限制。由此建立基于风速趋势的NWP风速校正模型,修正模型选择Attention-GRU模型,将风速趋势和NWP风速共同作为输入,有望进一步提高NWP风速的校正精度。

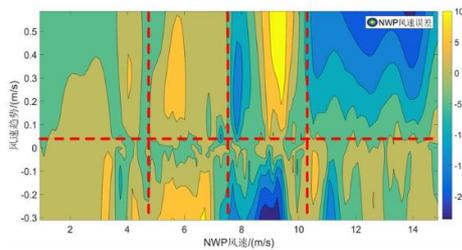


图5 风电场1的NWP风速误差的类等高图

Fig.5 Class contour map of NWP wind speed errors for wind farm 1

### 3 校正模型-Attention-GRU

#### 3.1 GRU神经网络

神经网络因其自身强大的学习能力被广泛应用于预测领域,然而传统RNN因其结构上的缺陷,普遍容易出现梯度爆炸和长期依赖等现象,于是为解决此类问题,Hochreiter等提出RNN基础上进行改进,由此诞生了长短期记忆神经网络(Long Short-Term Memory, LSTM)<sup>[16]</sup>,借助LSTM内部的独特存储结构:输入门、遗忘门、输出门与记忆单元之间进行信息的输入和输出。为了追求更简单的网络结构和更快的运算速度,Chung等[17]提出了在LSTM基础上改进得到GRU。LSTM模型是由三个门函数共同构成,分别是输

入门、遗忘门和输出门。而由LSTM网络改进得到的变体-GRU,创新性的设计了更新门,即由遗忘门和输入门合并而形成,如此GRU的结构更为简单,既能保证模型的性能,又可以减少计算量和运算时间。GRU模型的内部结构如图6所示。

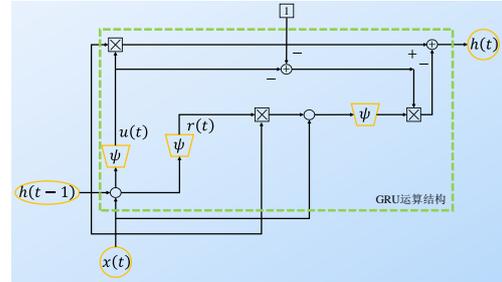


图6 GRU模型的内部结构

Fig.6 Internal structure of the GRU model

在 $t$ 时刻,GRU接收当前时刻的状态信息 $x(t)$ 与前一时刻的隐藏状态信息 $h(t-1)$ ,此时更新门正在同步进行遗忘与记忆两个过程,进而得到了进入网络的信息量和被遗忘的历史信息量,其中重置门决定历史消息的遗忘。也就是更新门与重置门是结合使用的,两者结合可以动态控制GRU的输出 $h(t)$ 。内部运算结构的各变量间计算公式如下:

$$u(t) = \psi(W_u h(t-1) + U_u x(t)) \quad (2)$$

$$r(t) = \psi(W_r h(t-1) + U_r x(t)) \quad (3)$$

$$h(t) = \varphi(W_c(r(t) \square h(t-1)) + U_c x(t)) \quad (4)$$

$$h(t) = u(t) \square h(t-1) + (1 - u(t)) \square h(t) \quad (5)$$

式中: $\psi(\square)$ 为激活函数,一般是sigmoid激活函数; $\varphi(\square)$ 为任意非线性函数; $U_u, U_r, U_c$ 为连接输入信号参数矩阵; $w_u, w_r, w_c$ 为连接隐藏层输出信号参数矩阵; $h(t)$ 为混合了细胞状态和隐藏状态的中间记忆状态; $\square$ 为逻辑运算符,表示矩阵中对应的元素相乘。

### 3.2 时序注意力机制

注意力机制首次在视觉图像领域中被提出，Google Mind 团队为解决图像分类的有关难题，构造了 RNN-Attention 模型并取得良好的效果<sup>[18]</sup>。其核心思想是增强对结果影响占比大的关键信息并削弱影响占比小的冗余信息，表现为设定关键信息的权重更高，冗余信息的权重更小<sup>[19-20]</sup>，在 GRU 模型中加入该机制能有效提升预测效果<sup>[21]</sup>。

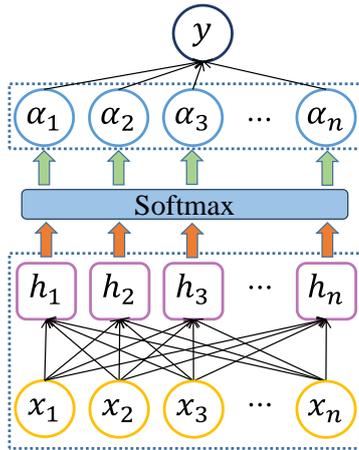


图 7 Attention 单元结构

Fig.7 Attention unit structure

Attention 原理如图 7 所示，首先将第 1, 2, 3, ..., n 时刻的输入，即  $x_1, x_2, x_3, \dots, x_n$  输入到模型中；进而得到未归一化的权值向量，即  $h_1, h_2, h_3, \dots, h_n$ 。然后使用 softmax 函数对最终的注意力权重向量  $\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n$  进行归一化处理。并乘以模型输入时间序列的相应位置，从而由注意力机制估算后的时间序列，将其作为后续 GRU 的输入。实际计算过程如下：

$$h = f_a(W_a x + b) \quad (6)$$

$$\alpha_i = \frac{\exp(h_i)}{\sum_{i=1}^n \exp(h_i)} \quad (7)$$

$$\alpha = [\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n] \quad (8)$$

$$y = [\alpha_1 x_1, \alpha_2 x_2, \alpha_3 x_3, \dots, \alpha_n x_n] \quad (9)$$

式中： $f_a(\square)$  为神经网络输出激活函数； $W_a$

为注意力机制神经网络权重矩阵； $b$  为偏置系数； $h$  为经过神经网络输出得到的未归一化权重矩阵； $y$  为评估后的时间序列； $\alpha$  为通过 softmax 函数归一化得到的时序注意力分布矩阵。

### 3.3 Attention-GRU 模型

本文提出的 Attention-GRU 风速校正模型如图 8 所示。模型由输入层、GRU 层、Attention 层、输出层构成，增加了 Attention 的 GRU 模型在分类效果上有了一定程度的提升<sup>[22]</sup>。为增强模型对输入数据的时间敏感性和加大模型对数据本质规律的学习程度，在 GRU 模型的输入侧引入时序注意力机制。输入层输入经注意力机制评估后特征向量，经过 GRU 隐藏层，GRU 模型对输入向量的特征进行充分学习，获取其规律得到校正结果。

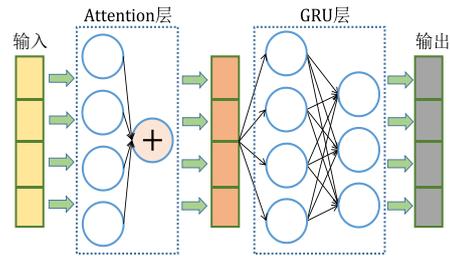


图 8 Attention-GRU 模型

Fig.8 Attention-GRU model

## 4 NWP 风速校正的过程及其在风电功率预测中的应用

第三节的结果表明，即使 NWP 风速在一个很小的间隔内，NWP 风速与同一时刻的实测风速之间的对应关系仍然并不清晰。因此，现有的校正算法，仅采取 NWP 风速在时间  $t+1$  作为输入变量，很难实现良好的性能。为了提高 NWP 风速校正和预测功率的精度，如前文所述，应考虑 NWP 风速和风速趋势与风速误差的耦合关系，如图 9 所示。此外，为了得到不同时间范围下的校正结果，该校正算法采用动态滚动迭代方式，根据实际情况更新校正模型和输入变量。

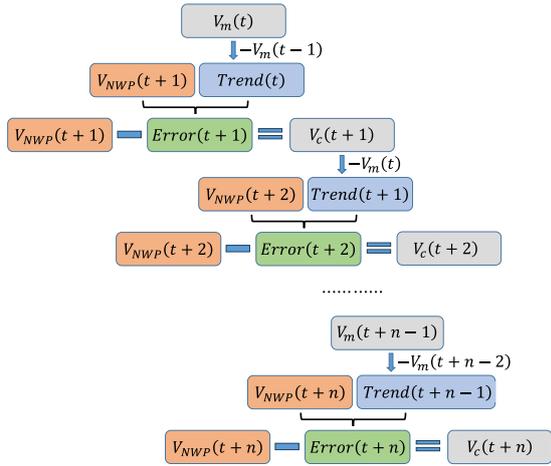


图9 NWP 风速校正滚动迭代模式

**Fig.9 NWP Wind Speed Correction Rolling Iterative Model**

NWP 风速校正的过程及其在风电功率预测中的应用如图 10 所示:

1) 构造校正模型的输入和输出。输入变量是时间  $t+1$  处的 NWP 风速和时间  $t$  处的风速趋势。输出变量是在时间  $t+1$  处风速误差。

2) 建立输入输出间的映射关系, 训练校正模型。校正模型的参数被存储以用于将来的校正。

3) 采用滚动迭代方式订正 NWP 风速, 如图所示, 除了第一个 NWP 风速实测点之外, 在校正时间范围期间, 校正的风速代替测量的风速作为输入变量。

4) 以校正风速和其他气象因素, 风向、湿度、温度、气压组合成的多维数据作为输入, 利用 Attention-GRU 模型对风电功率预测建立预测模型, 输出风电功率预测结果。

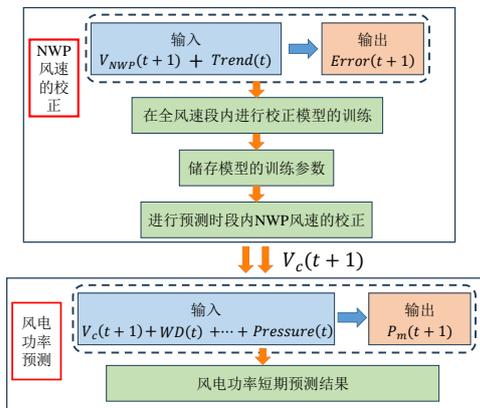


图 10 NWP 风速校正的过程及其在风电功率预测中的应用

**Fig.10 The process of NWP wind speed correction and its application to wind power prediction**

## 5 算例分析

### 5.1 数据集和实验环境

本文选取蒙西两个风电场数据作为仿真样本进行算例分析。两个风电场的装机容量分别为 99.5MW 和 200MW, 本仿真数据包括实测数据和 NWP 预报数据, 时间分辨率均为 15min。实测数据包含风电功率和风电场轮毂高度风速; NWP 数据包含风速、风向、温度、湿度、气压的预报值。数据发生时间为 2020 年 3 月 1 日—9 月 30 日, 使用 2020 年 3 月 1 日—2020 年 6 月 30 日的数据作为训练集, 2020 年 7 月 1 日—2020 年 9 月 30 日的数据作为测试集。

### 5.2 模型评价指标

为评价本文所提模型的有效性, 本文选择均方根误差(root mean square error, RMSE)<sup>[23]</sup>作为预测模型的评价指标。 $RMSE_v$  用于评估风速校正误差,  $RMSE_p$  用来评估功率预测误差。

$$RMSE_v = \sqrt{\frac{\sum_{t=1}^n (v_c(t) - v_m(t))^2}{n}} \quad (10)$$

$$RMSE_p = \sqrt{\frac{\sum_{t=1}^n (P_f(t) - P_m(t))^2}{P_r}} \quad (11)$$

式中:  $P_r$  表示风电场装机容量;  $n$  表示样本个数;  $v_c(t)$  为校正风速;  $v_m(t)$  为实测风速;

$P_f(t)$  为预测功率;  $P_m(t)$  为实际功率。

### 5.3 NWP 风速校正结果

针对 NWP 风速和实际风速存在偏差的情况, 使用本文方法分别对风电场 1 和风电场 2 的预报风速进行校正。为验证所提出预测方法的有效性和在复杂工况下的泛用性, 本文分别选取了 NWP 预报精度较高和 NWP 预报精度较低的两个风电场进行验证。以  $RMSE_v$  作为标准, 通过本文方

法和两个对比算法的校正结果进行评估。一个对比算法是输入预报风速，输出风速误差，另一个对比算法是输入预报风速，输出实测风速。本文的基本校正模型分别为逻辑回归模型(Logistic Regression, LR)、RF、极限梯度提升模型(eXtreme Gradient Boosting, XGBoost)、LSTM 和 Attention-GRU。

首先，Attention-GRU 作为基本的校正模型，用于校正本文方法和两个对比算法。校正前后两座风电场某一天预报风速与实际风速对比如图 11 所示。在图中 NWP 表示原始 NWP 风速的误差；Model1 表示输入为 NWP 风速，输出为实测风速；Model2 表示输入为 NWP 风速，输出为误差；Model3 为本文方法。

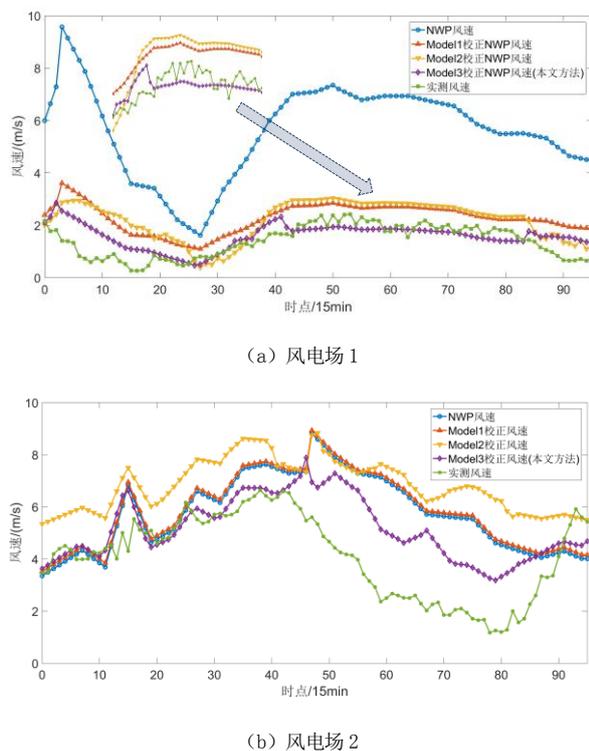


图 11 风电场 1、2 的 NWP 风速修正结果对比  
Fig.11 Comparison of NWP wind speed correction results for wind farms 1 and 2

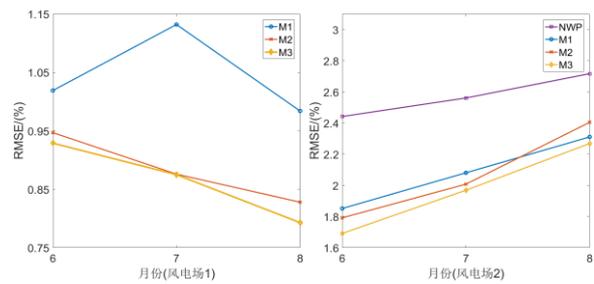


图 12 风电场 1、2 在不同月份 NWP 风速校正误差指标

Fig.12 Wind farms 1 and 2 in different months NWP wind speed correction error indicators

校正前后两座风电场在不同月份的预报风速与实际风速的误差结果曲线如图 12 所示。从图中可以看出，虽然在风电场 1 的 8 月份 Model3 和 Model2 的误差大致相同，但在其他时刻 Model3 的误差低于 Model1 和 Model2。Model3 在风电场 1 中的误差波动约为 0.86m/s，在风电场 2 中的误差波动约为 1.97m/s。

表 1 风电场 1、2NWP 风速误差校正结果

Tab.1 Correction results of NWP wind speed error for wind farms 1 and 2

场站号	模型	7月(m/s)	8月(m/s)	9月(m/s)
场站 1	NWP	5.145	4.903	5.033
	Model1	1.019	1.132	0.984
	Model2	1.852	0.876	0.828
	Model3	0.929	0.875	0.793
场站 2	NWP	2.442	2.561	2.717
	Model1	1.852	2.081	2.311
	Model2	1.792	2.008	2.405
	Model3	1.692	1.969	2.269

校正前后两座电场的校正风速和实际风速误差分析结果如表所示，从表 1 中可以看出：

1) 由于风电场 1 的 NWP 风速与实测风速差异较大，本文方法和两个对比算法分别对 NWP 风速校正后的精度提升较明显。在风电场 1 中，由于原始 NWP 的预报精度较高，误差在 5.023m/s 左右，所以本文方法的校正误差  $RMSE_v$  提升较高约为 4.216m/s。在风电场 2 中，由于原始 NWP 的预报精度较低，误差在 2.573 m/s 左右，所以本文方法的校正误差  $RMSE_v$  提升较低约为 1.032m/s。

2) 与 Model1 和 Model2 相比，本文方法在两个风电场的不同月份均具有较好的性能。这是

因为本文方法考虑了风速趋势和 NWP 风速的耦合作用,两者共同限制了NWP 风速的误差分布,使模型能更好地捕捉输入输出间的映射关系。例如,在 7 月份,本文方法与原始 NWP、Model1 和 Model2 相比,风电场 1 的校正精度分别提高了 4.216m/s、0.072m/s、0.090m/s,风电场 2 的校正精度分别提高了 0.750m/s、0.160m/s、0.100m/s。

为了进一步研究本文方法的泛化能力,本文还将 LR、RF、XGBoost 和 LSTM 模型作为 NWP 风速修正的基本模型。表 2 中列出了使用五种校正模型(LR、RF、XGBoost、LSTM 和 Attention-GRU)的  $RMSE_v$ 。

表 2 五种模型的 NWP 风速误差校正结果

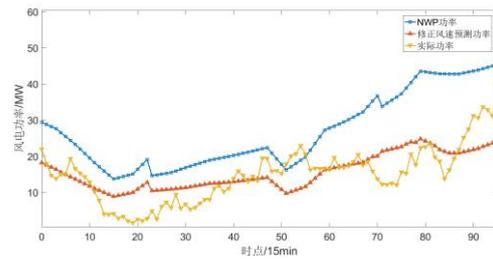
Tab.2 NWP wind speed error correction results for five models

场站	模型	7月(m/s)	8月(m/s)	9月(m/s)
场站 1	LR	0.938	0.877	1.069
	RF	1.001	0.898	1.063
	Xgboost	1.036	0.922	1.072
	LSTM	1.069	0.986	1.059
	Attention-GRU	0.929	0.876	0.824
场站 2	LR	2.218	2.346	2.315
	RF	2.236	2.366	2.238
	Xgboost	2.306	2.461	2.253
	LSTM	2.362	2.51	2.414
	Attention-GRU	1.692	1.969	2.311

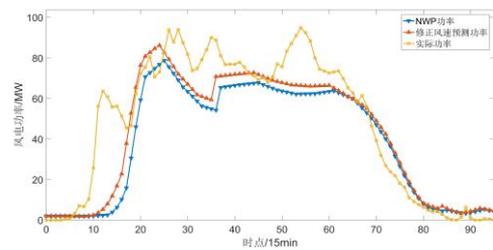
从表中可以看出,虽然基本校正模型不同,NWP 风速经本文方法修正后精度都得到了提高。所以本文方法对不同的算法模型有较强的泛化能力。

#### 5.4 风电功率短期预测中的应用

为了表明本文提出的 NWP 风速修正的方法具有适用性,将其应用于上述两个风电场的风电功率预测中。本节使用修正风速和其他气象因素,风向、湿度、温度、气压组合成的多维数据作为输入,利用 Attention-GRU 模型对风电功率预测。



(a) 风电场 1



(b) 风电场 2

图 13 风电场 1、2 预测结果对比

Fig.13 Comparison of Forecast Results for Wind Farm 1 and 2

图 13 分别选取了风电场 1 和风电场 2 中某一天的修正前后风速预测功率与实际功率进行对比。从图中可以看出以本文方法修正后的风速预测功率与原始 NWP 相比更加接近实际功率,证明了本文方法的实用性。

表 3 风电场 1 预测指标对比

Tab.3 Comparison of Forecast Indicators for Wind Farm 1

风电场 1	未修正风速(%)	修正后风速(%)
6月第一周	0.123	0.099
6月第二周	0.210	0.189
6月第三周	0.132	0.127
6月第四周	0.162	0.118
6月份平均	0.156	0.133

表 4 风电场 2 预测指标对比

Tab.4 Comparison of Forecast Indicators for Wind Farm 2

风电场 2	未修正风速(%)	修正后风速(%)
6月第一周	0.143	0.129
6月第二周	0.179	0.167
6月第三周	0.134	0.118
6月第四周	0.152	0.148
6月份平均	0.153	0.141

表 3 和表 4 中展示了 6 月份 4 周平均误差,

以更小的时间尺度来观察模型的预测效果,避免出现某周误差很大,某周误差极小,从而出现表面上月误差小,但实际上掩盖了某一周误差很大的情况。从表3和表4中可以看出,通过本文方法进行风速修正后,风电场1和风电场2在6月的RMSE分别降低2.3%、1.2%。风电场1在6月四周内RMSE最多降低4.4%,最少降低0.5%;风电场2在6月四周内RMSE最多降低1.6%,最少降低0.4%。

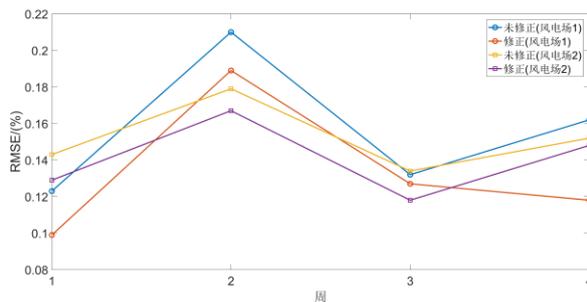


图14 风电场1、2校正前后预测误差对比

Fig.14 Comparison of prediction errors before and after correction for wind farms 1 and 2

风电场1和风电场2每周修正前后风速预测功率与实际功率的误差结果曲线如图14所示,可以看出,修正后的风电功率预测模型在一个月4周内上的表现均优于未修正风速。

综上所述,以NWP修正风速训练的风电预测模型的功率预测精度更高,进一步说明本文提出的NWP风速修正模型确实减少了风电功率预测误差,并提高了一定的预测精度。

## 6 结论

本文以风速趋势及NWP风速共同作为输入,以NWP风速与实测风速间的误差作为输出,增强了输入输出间的映射关系,并将本文方法应用于风电功率短期预测中。以蒙西两个风电场的实际运行数据为例,进行NWP风速修正和短期风电功率预测仿真验证,得出以下主要结论:

1) 即使考虑一个很小的NWP风速间隔,NWP风速与同一时刻的实测风速间的映射关系仍然是模糊的,NWP风速误差变化仍然很大,这是导致现有校正算法性能差的重要因素之一。本文方法增加了风速趋势作为输入,限制了误差分布,使输入输出间映射关系更加明显。

2) 本文方法能有效减少风电场预报风速和实际风速间的偏差,在两个风电场中的表现均优于Model1和Model2, RMSE<sub>v</sub>平均降低4.160 m/s、0.597 m/s。此外,本文方法的精度提高与修正模型的相关性较弱,所提出的修正算法对不同的数值预报风速修正模型具有较强的泛化能力。

3) 通过应用本文方法,算例验证:风电场1和风电场2在6月份的预测精度分别提高了2.3%和1.2%,提高了风电功率短期预测的准确性,具有更高的适用性。

## 参 考 文 献

- [1] 国家电网公司发布“碳达峰、碳中和”行动方案[N]. 国家电网报, 2021-03-02(001).
- [2] CHEN G P. Analysis and Reflection on High-quality Development of New Energy With Chinese Characteristics in Energy Transition[N]. State Grid News, 2021-03-02(001).
- [3] 余光正, 陆柳, 汤波, 等. 考虑转折性天气的海上风电功率超短期分段预测方法研究[J]. 中国电机工程学报, 2022, 42(13): 4859-4871.
- [4] YU Guangzheng, LU Liu, YANG BO, et al. Research on Ultra-short-term Subsection Forecasting Method of Offshore Wind Power Considering Transitional Weather[J]. Proceedings of the CSEE, 2022, 42(13): 4859-4871(in Chinese).
- [5] 陈国平, 董昱, 梁志峰, 等. 能源转型中的中国特色新能源高质量发展分析与思考[J]. 中国电机工程学报, 2020, 40(17): 5493-5505.
- [6] Chen Guoping, Dong Yu, Liang Zhifeng, et al. Analysis and reflection on high-quality development of new energy with Chinese characteristics in energy transition[J]. Proceedings of the CSEE, 2020, 40(17): 5493-5505(in Chinese).
- [7] 杨茂, 于欣楠. 考虑风电场功率爬坡的超短期组合预测[J]. 东北电力大学学报, 2022, 42(01): 1005-2992.
- [8] Yang Mao, Yu Xinnan. Ultra-short-term portfolio forecasts considering power creep in wind farms[J]. Journal of Northeast Power University, 2022, 42(01): 1005-2992(in Chinese).
- [9] 杨茂, 代博社, 刘蕾, 等. 风电功率率预测研究综述[J]. 东北电力大学学报, 2020, 40(02): 1005-2992.
- [10] Yang Mao, Dai Bozhi, Liu lei, et al. A Review of Probabilistic Wind Power Prediction Studies[J]. Journal of Northeast Power University, 2020, 40(02): 1005-2992(in Chinese).
- [11] Allen D, Tomlin A, Bale C, et al. A boundary layer scaling technique for estimating near-surface wind energy using numerical weather pre-diction and wind map data. Applied Energy, 2017: 208: 1246-57.
- [12] 戴千斌, 黄南天. 短期风电功率预测误差修正研究综述[J]. 东北电力大学学报, 2023, 43(02): 1005-2992.
- [13] Dai Qinbin, Huang Nantian. A review of short-term wind power prediction error correction studies[J]. Journal of Northeast Power University, 2023, 43(02): 1005-2992(in Chinese).
- [14] Dadkhah M, Rezaee M, Chavoshi A. Short-term power output forecasting of hourly operation in power plant based on

- climate factors and effects of wind direction and wind speed. *Energy* 2018; 148: 775-88.
- [15] Loukatou A, Howell S, Johnson P, Peter Duck. Stochastic wind speed modelling for estimation of expected wind power output. *Applied Energy*, 2018; 228: 1328-40.
- [16] 胡帅, 向月, 沈晓东, 等. 计及气象因素和风速空间相关性的风电功率预测模型[J]. *电力系统自动化*, 2021, 45(7): 28-36.
- [17] HU Shuai, XIANG Yue, SHEN Xiaodong, et al. Wind power prediction model considering meteorological factor and spatial correlation of wind speed[J]. *Automation of electric power systems*, 2021, 45(7): 28-36(in Chinese).
- [18] 杨国清, 刘世林, 王德意, 等. 基于 Attention-GRU 风速修正和 Stacking 的短期风电功率预测[J]. *太阳能学报*, 2022, 43(12): 273-281.
- [19] YANG Guoqing, LIU Shilin, WANG Deyi, et al. Short-term wind power forecasting based on Attention-GRU wind speed correction and stacking[J]. *Acta energiae solaris sinica*, 2022, 43(12): 273-281(in Chinese).
- [20] 苗长新, 王霞, 李昊, 等. 基于数值天气预报风速误差修正的风电功率日前预测[J]. *电网技术*, 2022, 46(09): 3455-3464.
- [21] MAO Changxin, WANG Xia, LI hao, et al. Day-ahead Prediction of Wind Power Based on NWP Wind Speed Error Correction[J]. *Power System Technology*, 2022, 46(09): 3455-3464(in Chinese).
- [22] Wang H, Han S, Liu Y, 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.
- [23] 黄南天, 刘德宝, 蔡国伟, 等. 基于多相关日场景生成的电动汽车充电负荷区间预测[J]. *中国电机工程学报*, 2021, 41(23): 7980-7990.
- [24] HUANG Nantian, LIU Debao, CAI Guowei, et al. Interval Prediction of Electric Vehicle Charging Load Based on Scene Generation With Multiple Correlation Days[J]. *Proceedings of the CSEE*, 2021, 41(23): 7980-7990(in Chinese).
- [25] 李福东, 曾旭华, 魏梅芳, 等. 基于聚类分析和混合自适应进化算法的短期风电功率预测[J]. *电力系统保护与控制*, 2020, 48(22): 151-158.
- [26] LI Fudong, ZENG Xuhua, WEI Meifang, et al. Short-term wind power forecasting based on cluster analysis and a hybrid evolutionary-adaptive methodology[J]. *Power system protection and control*, 2020, 48(22): 151-158(in Chinese).
- [27] HOCHREITER S, SCHMIDHUBER J. Long short- term memory[J]. *Neural computation*, 1997, 9(8): 1735-1780.
- [28] CHUNG J Y, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling: Eprint Arxiv, 10.48550/arXiv. 1412.3555[P]. 2014.
- [29] Shen H, Chen L. Distributed Autonomous Virtual Resource Management in Datacenters Using Finite-Markov Decision Process[J]. *IEEE/ACM Transactions on Networking (TON)*, 2017, 25(6).
- [30] 冯斌, 张又文, 唐昕, 等. 基于 BiLSTM-Attention 神经网络的电力设备缺陷文本挖掘[J]. *中国电机工程学报*, 2020, 40(S1): 1-10.
- [31] FENG Bin, ZHANG Youwen, TANG Xin, et al. Power equipment defect record text mining based on BiLSTM-Attention neural network[J]. *Proceedings of the CSEE*, 2020, 40(S1): 1-10(in Chinese).
- [32] XIONG L, ZHOU W, WANG W, et al. Attention-based relation extraction with bidirectional gated recurrent unit and highway network in the analysis of geological data[J]. *IEEE access*, 2018, 6: 5705-5715.
- [33] Xiong L, Wenwen Z, Weiping W, et al. Attention-Based Relation Extraction With Bidirectional Gated Recurrent Unit and Highway Network in the Analysis of Geological Data[J]. *IEEE Access*, 2018, 6.
- [34] 孙明敏. 基于 GRU-Attention 的中文文本分类[J]. *现代信息技术*, 2019, 3(03): 10-12.
- [35] SUN Mingmin. Chinese Text Classification Based on GRU-Attention[J]. *Modern Information Technology*, 2019, 3(03): 10-12.
- [36] Song J, Wang J, Lu H. A novel combined model based on advanced optimization algorithm for short-term wind speed forecasting[J]. *Applied Energy*, 2018, 215.

#### 作者简介:

杨茂(1982—), 男, 博士, 教授, 博士生导师, 主要研究方向: 新能源发电功率预测、微网优化调度、综合能源系统。E-mail: yangmao820@163.com

车润棋(2000—), 女, 硕士研究生, 主要研究方向: 风电功率预测。E-mail: 2645035221@qq.com

王勃(1983—), 男, 硕士, 教授级高工, 主要研究方向: 新能源功率预测。E-mail: wangbo@epri.sgcc.com.cn