

基于 CycleGAN 的区域风速网格化预测方法

冯双磊, 王铮*, 王伟胜, 宋宗朋, 王勃

(可再生能源并网全国重点实验室(中国电力科学研究院有限公司), 北京市 海淀区 100192)

Gridded Forecasting of Local Wind Speeds Based on CycleGAN

FENG Shuanglei, WANG Zheng*, WANG Weisheng, SONG Zongpeng, WANG Bo

(State Key Laboratory of Renewable Energy Grid-Integration (China Electric Power Research Institute),

Haidian District, Beijing 100192, China)

ABSTRACT: Considering the development of low-carbon and sustainable alternatives to traditional energy sources is a global goal, many countries aim to have non-fossil energy sources account for over 80% of their installed capacity and achieve carbon neutrality by 2060. However, to ensure the stable operation of power grids with a high penetration of renewable energy, it is essential to precisely predict output fluctuations, which requires accurate forecasting of parameters such as wind speed and solar radiation intensity. Currently, wind speed forecasting is largely based on relatively inaccurate numerical weather prediction models. We aim to address this limitation by developing an intelligent wind speed forecasting method based on image generation using generative adversarial networks (GANs). First, a target dataset is created using thin plate spline (TPS) interpolation to correct initial gridded forecasts of the wind speed based on observed wind speed data. The wind speed data are then transformed into gridded data images, and a GAN is used to generate intelligent wind speed forecasts. To validate the proposed method, a simulation analysis is performed using actual data from a region in North China, and the results are found to be 21.7% more accurate than those of the European Centre for Medium-Range Weather Forecasts.

KEY WORDS: generative adversarial network (GAN); image vision; thin plate spline (TPS) interpolation; wind power generation; wind speed forecasting

摘要: 实现传统能源的绿色、低碳和可持续替代是世界各国的普遍共识。中国 2060 年非化石能源装机占比将突破 80%, 实现“碳中和”。与传统能源不同, 新能源出力具有随机波动性, 为了确保新能源高占比电力系统的稳定运行, 高精度预测新能源出力是必要基础, 风速、辐照强度等资源参量的

准确预报是前提。针对当前以气象数值预报模式为基础的风速预报结果存在较大偏差的问题, 以网格化初始预报风速数据作为基本输入信息, 引入观测风能资源信息, 通过薄板样条插值理论订正初始预报风速, 形成目标数据集; 在网格化数据图像转化的基础上, 采用生成对抗网络, 提出一种图像生成思维的人工智能风速预报方法。该文以中国华北某区域的实际数据进行仿真分析, 结果发现, 所提出的方法能够实现风速的网格化预报, 且与欧洲中尺度气象预报中心结果相比, 精度提升 21.7%。

关键词: 生成对抗神经网络; 图像视觉; 薄板样条插值理论; 风力发电; 风速预报

0 引言

能源绿色低碳发展已成为世界各国的普遍共识^[1-2], 构建高比例可再生能源电力系统, 并开展能源的绿色电力替代是实现节能减排的具体举措^[3-4]。截止到 2023 年 12 月, 全球风电装机容量已达到 1.02 TW^[5], 随着全球能源供给的可持续性演进, 到 2060 年, 全球风电装机容量将成倍增长, 中国的非化石能源装机占比也将达到 80%以上^[6], 其中风电装机容量预计将突破 3 000 GW。与此同时, 受一次资源影响, 风电出力具有随机波动性^[7-8], 大规模并网带来了系统安全稳定运行和风电消纳的双重挑战^[9]。开展风电功率预测是应对随机波动风电大规模所带来挑战的重要应对手段之一^[10-13]。电力市场环境下, 风电功率预测是风电参与市场交易的必要前提^[14], 预测精度越高, 风电企业的经济效益越显著; 电力计划环境下, 风电功率预测是发电计划编制的基础, 预测精度越高, 越有利于保电力供应、促新能源消纳。风速预报是风电功率预测的必要基础, 对风电功率预测精度具有显著影响^[15]。同时,

基金项目: 国家电网有限公司科技项目(5108-202218280A-2-315-XG)。

Science and Technology Project of State Grid Corporation of China (5108-202218280A-2-315-XG).

风速预报也是气象领域研究的热点和难点之一^[16]。因此,提高风速预报精度具有十分重要的理论意义和现实意义。

针对支撑风电功率预测的风速预报方法及性能提升技术,国内学者开展了广泛的研究。梳理当前的研究,大体可分类两类。第一类可总结为物理方案。此类研究,主要是聚焦风速物理预报的主要技术环节分别进行攻关。具体来说,在风速预报的输入环节,针对背景场数据,利用卫星^[17]、雷达^[18-19]等观测数据,采用同化技术^[20-21],提高风速预测所需输入参量的准确度,进而实现预测性能提升的目的^[22];在风速预报的计算模型环节,除常规的改进预报模式^[23]之外,随着数据挖掘技术的发展,将卡尔曼滤波^[24]、深度学习^[25-26]等数学算法用于优化预报模式参数或替换参数化方案是当前研究的热点;在风速预报的结果订正环节,主要是利用统计或深度学习算法^[27-29]、引入实际观测数据,对预报结果的偏差进行订正,有效降低绝对偏差,但变化趋势的改进不显著。第二类可总结为统计方案。此类研究,主要是利用长短期记忆神经网络^[30-33]、门控循环神经网络^[34]、LightGBM^[35]、递归神经网络^[36]、分层神经网络^[37]、极限学习机^[38]、非线性自回归神经网络^[39]、图卷积神经网络^[40]和自编码深度学习网络^[41]等深度学习神经网络或其他统计算法^[42-46],以临近实测风速作为输入,通过学习临近风速与未来风速的非线性复杂映射关系,实现风速的预测,但针对不同的方法,具体的技术路线存在差异,比如利用风速序列不同频谱信号的差异性、利用风能资源的时空相关特性等。总体上来说,此类方法预测结果的时间长度一般较短,多在 4 h 左右,无法支撑 0~7 天的中长期发电功率预测,也无法适用于不具备风能资源观测点位的风速预报,对实际需求的支撑作用较弱。此外,统计方案中,还有少量研究聚焦概率分布模型实现风速的预测,所采取的具体方案是利用高斯分布^[47]、空间风速分布协方差^[48]等构建风速的概率模型,依据当前的风速状态,实现风速的区间预测。从结果来看,偏差较大,时间分辨率也不满足需求。

综上可知,当前在如何提升风速预报精度方面已开展了大量的研究,取得了一定的效果,但在物理与统计相结合方面还存在不足^[49-50],直接体现是风速预报的时间尺度不够、精度不高。本研究聚焦当前研究存在的不足,为了引入气象变化的物理过

程信息,以气象数值预报模式得到的网格化风速预报数据作为基础数据,采用薄板样条插值理论(thin plate spline, TPS)方法利用实际观测风能资源信息,形成目标数据;在网格化数据图像转化和上采样的基础上,通过生成对抗网络(generative adversarial network, GAN)构建网格化初始预报风速的优化模型,得到风速预报优化结果图像,利用下采样和图像数据的数值提取技术,实现风速的网格化优化预报,解决了当前存在的三大问题:1)预测精度不足;2)实时观测数据对 4 h 后的预报订正作用下降;3)无法适用于不具备风能资源观测点位的风速预报。

1 整体技术方案

本研究得到的物理与统计相结合的网格化风速人工智能预报技术方案如图 1 所示。

本研究的核心关键是综合利用气象观测站和风电场测风塔观测的实际风速,纠正物理预报风速存在的偏差(图 1 中的步骤 2),采用生成对抗神经网络,以图像化的思维(图 1 中的步骤 3),深度学习物理预报风速分布图中的预报偏差特征(图 1 中的步骤 4),最终实现风速的网格化智能预报。上述技术方案的合理性和先进性在下文中论证。

2 实际观测风速利用方法

大量研究证实,充分利用实际观测风速能够有效降低风速预报的偏差。当前的实际风速数据利用方法仅能针对具有观测点位的预报风速。本研究提出一种基于 TPS^[51]的网格化风速修正技术,突破了观测点位的限制。

假定 $[x_i, y_i]$ 位置处第 t 时刻的实测风速值为 $v_{i,t}$ 、物理预报风速值为 $\hat{v}_{i,t}$ 。根据各实测风速的经纬度 $[x_i, y_i]$ 构建控制点矩阵:

$$\mathbf{C} = \begin{bmatrix} 1 & x_1 & y_1 \\ 1 & x_2 & y_2 \\ \vdots & \vdots & \vdots \\ 1 & x_n & y_n \end{bmatrix} \quad (1)$$

式中: $\mathbf{C}$ 为控制点矩阵, $n \times 3$ 维; n 为测风观测点位的个数; x_i 为测风观测点的经度; y_i 为测风观测点的纬度。

以 $[x_i, y_i]$ 位置处 t 时刻的实测风速 $v_{i,t}$ 与物理预报风速 $\hat{v}_{i,t}$ 的差值 $\Delta v_{i,t} = v_{i,t} - \hat{v}_{i,t}$ 构建高度矩阵:

$$\mathbf{Z}_t = [\Delta v_{1,t}, \Delta v_{2,t}, \dots, \Delta v_{n,t}, 0, 0, 0]^T \quad (2)$$




图1 风速人工智能预报整体技术方案

Fig. 1 Technical framework of the proposed artificial intelligence (AI)-based wind speed forecasting method

式中 $\mathbf{Z}_t$ 为 t 时刻的高度矩阵。

采用径向基函数，考虑各观测点实测风速的相互影响，形成相互影响矩阵：

$$\mathbf{K} = \begin{pmatrix} K_{1,1} & \cdots & K_{1,j} & \cdots & K_{1,n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ K_{i,1} & \cdots & K_{i,j} & \cdots & K_{i,n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ K_{n,1} & \cdots & K_{n,j} & \cdots & K_{n,n} \end{pmatrix} \quad (3)$$

式中 $\mathbf{K}$ 为相互影响矩阵，其元素 $K_{i,j}$ 按计算方法为

$$K_{i,j} = U(\|[\mathbf{x}_i, \mathbf{y}_i] - [\mathbf{x}_j, \mathbf{y}_j]\|) + I_{i,j} \alpha^2 \lambda \quad (4)$$

式中 λ 为形变控制系数，根据实际需求确定，需满足 $\lambda \geq 0$ ； $\|[\mathbf{x}_i, \mathbf{y}_i] - [\mathbf{x}_j, \mathbf{y}_j]\|$ 为范数，表示第 i 实测点位置与第 j 实测点位置的距离，计算方法如下：

$$d_{i,j} = \|[\mathbf{x}_i, \mathbf{y}_i] - [\mathbf{x}_j, \mathbf{y}_j]\| = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (5)$$

$U(\|[\mathbf{x}_i, \mathbf{y}_i] - [\mathbf{x}_j, \mathbf{y}_j]\|)$ 为径向基函数，计算方法为

$$U(d_{i,j}) = \begin{cases} d_{i,j}^2 \ln d_{i,j}, & i \neq j \\ 0, & i = j \end{cases} \quad (6)$$

$I_{i,j}$ 为单位矩阵的元素，计算方法为

$$I_{i,j} = \begin{cases} 0, & i \neq j \\ 1, & i = j \end{cases} \quad (7)$$

α 为观测点的平均距离，计算方法为

$$\alpha = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n d_{i,j} \quad (8)$$

为了在风速整体分布特征变化最小条件下，尽可能降低物理预报风速与实际观测风速的偏差，控制点矩阵、高度矩阵和相互影响矩阵等需满足如下关系：

$$\begin{bmatrix} \mathbf{K} & \mathbf{C} \\ \mathbf{C}^T & \mathbf{O} \end{bmatrix} \times [\omega_{1,t} \ \omega_{2,t} \ \cdots \ \omega_{n,t} \ a_{1,t} \ a_{2,t} \ a_{3,t}]^T = \mathbf{Z}_t \quad (9)$$

式中 $\mathbf{O}$ 为 3×3 的 0 值矩阵。对式(9)进行求解，可

获得修正物理预报风速的待求参量：

$$\begin{bmatrix} \omega_{1,t} \\ \omega_{2,t} \\ \vdots \\ \omega_{n,t} \\ a_{1,t} \\ a_{2,t} \\ a_{3,t} \end{bmatrix} = \begin{bmatrix} \mathbf{K} & \mathbf{C} \\ \mathbf{C}^T & \mathbf{O} \end{bmatrix}^{-1} \times \mathbf{Z}_t \quad (10)$$

根据式(10)获得的参量，可得到 $[x_i, y_j]$ 位置处 t 时刻物理预报风速 $\hat{v}_{i',j',t}$ 的修正结果：

$$v'_{i',j',t}(x_{i'}, y_{j'}) = a_{1,t} + a_{2,t}x_{i'} + a_{3,t}y_{j'} + \sum_{i=1}^n \omega_{i,t} U(\| [x_i, y_i] - [x_{i'}, y_{j'}] \|) + \hat{v}_{i',j',t} \quad (11)$$

式中 $v'_{i',j',t}$ 即为修正结果。

为了验证本文所提出历史物理预测网格化风速修正方法的有效性，采取中国华北某区域的数据进行验证。数据的时间范围为 2020 年 11 月 1 日—12 月 31 日，时间分辨率为 15 min，物理预报风速共具有 4641 个网格点，实际观测站点共 1549 座，其中随机选择 2 座站点的观测数据用于验证效果。观测站点分布情况如图 2 所示。




图 2 华北地区风速观测点位分布情况

Fig. 2 Distribution of wind speed metering sites in a region of North China

利用式(1)—(11)的方法，构建物理预报网格化风速的修正模型。其中，式(4)中的 λ 取 0.03。需要指出的是，当观测风速的有效点位数较少时，修正会产生异常，该时间断面下的修正取消。据此，计算得到的修正后风速与原始物理预报风速对比如图 3 所示，其中：图 3(a)为测试点 1(图 2 左上位置)2020 年修正后风速与实际风速对比；图 3(b)为测试点 1(图 2 左上位置)2020 年 11 月 11—16 日修正后风速与实际风速对比；图 3(c)为测试点 2(图 2 中右位置)2020 年修正后风速与实际风速对比；图 3(d)

为测试点 2(图 2 中右位置)2020 年 11 月 11—16 日修正后风速与实际风速对比。




图 3 基于 TPS 的预报风速修正前后对比

Fig. 3 Corrected wind speed with TPS vs. real wind speed

统计修正前后风速的偏差情况，结果如表 1 所示。

表 1 物理预报风速修正前后性能对比

Table 1 The Performance of corrected wind speed

状态		均方根误差/(m/s)	相关系数/%
测试点 1	修正前	1.774	76.8
	修正后	1.038	89.7
测试点 2	修正前	1.370	78.1
	修正后	1.384	93.1

由图 3 和表 1 可以看出，采用博班样条插值方法利用实际观测风速信息，将原始的物理预测风速与实际观测风速的相关系数分别提升了 17% 和 19%，测试点 1 的均方根偏差降低了 42%，测试点 2 变化不大，验证了所提方法的有效性。由此可知，问题的关键转变为如何利用观测风速提升未来风速预报结果的精度。

3 基于 GAN 的风速预报方法

为了提升未来风速的预报准确度，需要学习物理预报风速的误差特点，并形成复杂非线性的误差矫正决策。其中，利用风速的空间相关特征，有助

于风速预报偏差的矫正。基于此,本文提出一种基于图像生成方法的风速预报方法,通过网格化风速的图像化,表征风速的空间相关规律;通过 GAN 挖掘和利用空间相关规律,矫正风速预报偏差。最终达到利用观测风速提升未来风速预报精度的目标。

3.1 网格化风速的图像化处理技术

网格化风速的图像化处理包括历史物理预报网格化风速的图像化处理和历史修正网格化风速的图像化处理。历史物理预报网格化风速的图像化处理方面,根据 t 时刻 $[x_i, y_j]$ 位置处的物理预报风速 $\hat{v}_{i,j,t}$, 构建物理预测风速矩阵:

$$\hat{\mathbf{V}}_t = \begin{pmatrix} \hat{v}_{1,1,t} & \cdots & \hat{v}_{1,j',t} & \cdots & \hat{v}_{1,n,t} \\ \vdots & \ddots & \vdots & \vdots & \vdots \\ \hat{v}_{i',1,t} & \cdots & \hat{v}_{i',j',t} & \cdots & \hat{v}_{i',n,t} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \hat{v}_{m,1,t} & \cdots & \hat{v}_{m,j',t} & \cdots & \hat{v}_{m,n,t} \end{pmatrix} \quad (12)$$

式中: $\hat{\mathbf{V}}_t$ 即为物理预测风速矩阵; m 为行数; n 为列数; 如果 $[x_i, y_j]$ 位置处无风速数据, 则令 $\hat{v}_{i',j',t} = -99$ 。

以所有样本风速的最大值 $\hat{v}_{\max}$, 并考虑 20% 的裕度, 对物理预测风速矩阵进行归一化处理:

$$\hat{\mathbf{V}}'_t = \begin{pmatrix} \frac{\hat{v}_{1,1,t}}{1.2\hat{v}_{\max}} & \cdots & \frac{\hat{v}_{1,j',t}}{1.2\hat{v}_{\max}} & \cdots & \frac{\hat{v}_{1,n,t}}{1.2\hat{v}_{\max}} \\ \vdots & \ddots & \vdots & \vdots & \vdots \\ \frac{\hat{v}_{i',1,t}}{1.2\hat{v}_{\max}} & \cdots & \frac{\hat{v}_{i',j',t}}{1.2\hat{v}_{\max}} & \cdots & \frac{\hat{v}_{i',n,t}}{1.2\hat{v}_{\max}} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \frac{\hat{v}_{m,1,t}}{1.2\hat{v}_{\max}} & \cdots & \frac{\hat{v}_{m,j',t}}{1.2\hat{v}_{\max}} & \cdots & \frac{\hat{v}_{m,n,t}}{1.2\hat{v}_{\max}} \end{pmatrix} \quad (13)$$

将归一化后的物理预报风速 $\hat{\mathbf{V}}'_t$ 转化为图像数据:

$$\hat{\mathbf{F}}_t = \begin{pmatrix} \left[\frac{255\hat{v}_{1,1,t}}{1.2\hat{v}_{\max}} \right] & \cdots & \left[\frac{255\hat{v}_{1,j',t}}{1.2\hat{v}_{\max}} \right] & \cdots & \left[\frac{255\hat{v}_{1,n,t}}{1.2\hat{v}_{\max}} \right] \\ \vdots & \ddots & \vdots & \vdots & \vdots \\ \left[\frac{255\hat{v}_{i',1,t}}{1.2\hat{v}_{\max}} \right] & \cdots & \left[\frac{255\hat{v}_{i',j',t}}{1.2\hat{v}_{\max}} \right] & \cdots & \left[\frac{255\hat{v}_{i',n,t}}{1.2\hat{v}_{\max}} \right] \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \left[\frac{255\hat{v}_{m,1,t}}{1.2\hat{v}_{\max}} \right] & \cdots & \left[\frac{255\hat{v}_{m,j',t}}{1.2\hat{v}_{\max}} \right] & \cdots & \left[\frac{255\hat{v}_{m,n,t}}{1.2\hat{v}_{\max}} \right] \end{pmatrix} \quad (14)$$

式中: $\hat{\mathbf{F}}_t$ 即为历史物理预报网格化风速转化后的图像数据, 无符号整数型; $[\cdot]$ 为取整函数。需要指出的是, 如果 $\hat{\mathbf{F}}_t$ 的元素小于 0, 则采取置 0 的处理方

式, 以确保图像数据不产生异常。

历史修正网格化风速的图像化处理方面, 根据 t 时刻 $[x_i, y_j]$ 位置处修正后的风速 $v'_{i,j,t}$, 构建修正风速矩阵 $\mathbf{V}'_t$, 构建方法与式(12)相同, 此处不再赘述。针对修正风速矩阵 $\mathbf{V}'_t$ 的归一化和图像化处理与式(13)、(14)相同, 主要差别是归一化参数为历史所有修正风速样本的最大值 $v'_{\max}$, 不再赘述。

3.2 风速预报 GAN 模型构建和训练方法

本研究在 GAN 算法方面, 主要是引入 CycleGAN 算法, 利用 CycleGAN^[52] 的图像迁移能力, 将物理预测网格化风速图像映射为引入实测风速修正后的网格化预报风速, 挖掘风速的空间相关特征, 提升风速预报结果的准确性。

3.2.1 模型构建方法

风速网格化优化预报模型(生成器 G)由卷积模块、残差模块、逆卷积模块和映射模块组成^[55], 输入数据为式(14)计算得到的物理预报网格化风速图像。其中, 卷积模块由 3 部分构成: 第 1 部分是滤波器数量为 64、步长为 1 的 7×7 卷积层-归一化层-激活层; 第 2 部分是滤波器数量为 128、步长为 2 的 3×3 卷积层-归一化层-激活层; 第 3 部分是滤波器数量为 256、步长为 2 的 3×3 卷积层-归一化层-激活层。特征图像的边缘填充方式采取反向填充方法^[52], 归一化方式采取 InstanceNorm 方法^[53], 激活函数采用修正线性单元(rectified linear unit, ReLU); 残差模块由 9 组滤波器数量为 256 的双层 3×3 卷积层构成^[54]; 逆卷积模块由滤波器数量为 128、步长为 0.5 的 3×3 逆卷积层-归一化层-激活层和滤波器数量为 64、步长为 0.5 的 3×3 逆卷积层-归一化层-激活层构成, 归一化方式也采取 InstanceNorm 方法, 激活函数也选择 ReLU; 映射模块由滤波器数量为 3、步长为 1 的 7×7 卷积层-归一化层-激活层构成^[52]。

为了训练上述网络, 需要构建一个识别器 D , 使之与生成器对抗。识别器采用感受域为 70×70 的 PatchGAN^[55] 构建, 包括滤波器数量为 64、步长为 2 的 4×4 卷积层-激活层, 滤波器数量为 128、步长为 2 的 4×4 卷积层-归一化层-激活层, 滤波器数量为 256、步长为 2 的 4×4 卷积层-归一化层-激活层, 以及滤波器数量为 512、步长为 2 的 4×4 卷积层-归一化层-激活层, 最后添加一个卷积层, 得到 1 维输出^[52]。其中, 激活层采用泄漏修正线性单元(leaky rectified linear unit, leakyReLU), 斜率取 0.2。

以 3.1 节中式(14)计算得到的物理预报网格化风速图像为输入, 采用与式(14)类似方法计算得到的修正后网格化风速图像为目标, 训练构建的生成器 G 和识别器 D 。训练的目标函数由 3 部分构成, 与文献[52]相类似。第 1 部分是由物理预报网格化风速图像作为输入生成的图像与修正后网格化风速图像区别最小, 而识别器 D_Y 判断 G 生成图像的能力最大, 即 $\min_G \max_{D_Y} \ell_{GAN}(G, D_Y, \hat{F}_{t,256}, F'_{t,256})$, $\hat{F}_{t,256}$ 和 $F'_{t,256}$ 分别为将分辨率调整至 256×256 之后的物理预报网格化风速图像和修正后网格化风速图像; 第 2 部分是由修正后网格化风速图像作为输入生成 (映射函数 F) 的图像与物理预报网格化风速图像区别最小, 而识别器 D_X 判断 F 生成图像的能力最大, 即 $\min_F \max_{D_X} \ell_{GAN}(F, D_X, F'_{t,256}, \hat{F}_{t,256})$; 第 3 部分是由物理预报网格化风速图像生成的图像 $G(\hat{F}_{t,256})$ 作为输入的生成图像 $F(G(\hat{F}_{t,256}))$, 与物理预报网格化风速图像 $\hat{F}_{t,256}$ 偏差最小, 由修正后网格化风速图像生成的图像 $F(F'_{t,256})$ 作为输入的生成图像 $G(G(F'_{t,256}))$, 与修正后网格化风速图像 $F'_{t,256}$ 偏差也最小, 即 $\min \ell_{cyc}(G, F)$ 。在此目标函数下训练得到的生成器 G , 即为最终的网格化风速智能优化预报模型。

3.2.2 样本数据处理方法

3.2.1 节中构建的风速预报模型, 受采样算法、计算资源等限制, 要求训练样本图像数据和输入图像数据的分辨率为 256×256 。实际工程中, 大部分数据无法直接满足, 因此需对训练模型用的样本数据和模型应用阶段的输入数据进行预处理。主要是对图像数据进行插值, 使之满足分辨率要求。分辨率的调整采取图像失真度最小的原则, 即当图像的横向或纵向分辨率低于 256 时, 采取插值的方式; 当横向或纵向分辨率高于 256 时, 按照 256 的分辨率对图像进行切割, 针对切割出的图像, 分别构建预测模型。

为了兼顾计算资源、计算速度以及插值后的高保真性, 本研究采用双线性内插值算法对数据进行预处理。假定 t 时刻 $[x_i, y_j]$ 位置处的预报风速为 $\hat{v}_{i,j,t}$, $[x_{i+1}, y_j]$ 位置处的预报风速为 $\hat{v}_{i+1,j,t}$, $[x_i, y_{j+1}]$ 位置处的预报风速为 $\hat{v}_{i,j+1,t}$, $[x_{i+1}, y_{j+1}]$ 位置处的预报风速为 $\hat{v}_{i+1,j+1,t}$, 按照双线性内插算法, $[x_{i'+\Delta i'}, y_{j'+\Delta j'}]$ ($\Delta i', \Delta j' \in [0, 1]$) 位置处的预报风速 $\hat{v}_{i'+\Delta i', j'+\Delta j', t}$ 应由相邻 4 个位置的风速 $\hat{v}_{i,j,t}$ 、 $\hat{v}_{i+1,j,t}$ 、 $\hat{v}_{i,j+1,t}$ 和

$\hat{v}_{i+1,j+1,t}$ 加权得到, 权重根据距离确定, 距离越远、权重越低。于是有:

$$\begin{aligned} \hat{v}_{i'+\Delta i', j'+\Delta j', t} = & [i'+1-(i'+\Delta i')][j'+1-(j'+\Delta j')] \cdot \\ & \hat{v}_{i,j,t} + [i'+1-(i'+\Delta i')](j'+\Delta j'-j') \hat{v}_{i,j+1,t} + \\ & (i'+\Delta i'-i')[j'+1-(j'+\Delta j')] \hat{v}_{i+1,j,t} + \\ & (i'+\Delta i'-i')(j'+\Delta j'-j') \hat{v}_{i+1,j+1,t} \end{aligned} \quad (15)$$

对式(15)进一步处理, 得到:

$$\begin{aligned} \hat{v}_{i'+\Delta i', j'+\Delta j', t} = & (1-\Delta i')(1-\Delta j') \hat{v}_{i,j,t} + \Delta j'(1-\Delta i') \cdot \\ & \hat{v}_{i,j+1,t} + \Delta i'(1-\Delta j') \hat{v}_{i+1,j,t} + \Delta i' \Delta j' \hat{v}_{i+1,j+1,t} \end{aligned} \quad (16)$$

式中 $\hat{v}_{i'+\Delta i', j'+\Delta j', t}$ 即为分辨率调整之后的风速图像数据。

为了验证本研究所采用图像分辨率调整方法的合理性, 同样采用 2 节算例部分数据所在区域的物理预报风速进行分析, 覆盖该区域的物理预报网格共 4641 个, 随机选取 2022 年 11 月 3 日 00:00 的风速, 采用 3.1 节的方法对其进行图像化处理, 结果如图 4(a)所示。采用式(16)的方法, 对其进行分辨率调整, 结果如图 4(b)所示。图 4(a)为原始网格化风速图像, 分辨率 51×91 ; 图 4(b)为调整后网格化风速图像, 分辨率为 256×256 。




图 4 风速图像分辨率调整前后对比

Fig. 4 Comparison of wind speed image resolution

由图 4 可以看出, 分辨率调整后的风速图像反应的风速分布信息与调整前一致, 说明采用双线性内插值算法对风速图像的分辨率进行调整具有可行性和合理性。

另一项重要的数据处理是训练样本图像数据的命名。本研究的目标是实现风速的网格化优化预报, 在强调物理预报网格化风速图像特征向修正网格化风速图像特征迁移的同时, 更重要的是学习相同时刻输入图像与目标图像的像素幅值映射关系。为支撑该目标的实现, 需要将相同时刻的输入图像

和目标图像关联,本研究采取的方案是针对相同时刻的图形数据,采取相同的命名,由于样本量较大,避免命名的重复性,直接以风速的时间作为图像数据的名称,比如 yyyymmddHHMM.jpg,可以规避名称重复问题,关联输入和目标数据,也明确了数据的时间。

3.3 预报风速图像逆处理技术

由 3.2 节所构建模型得到的 $G(\hat{F}_{t,256})$ 即为优化预报结果,其为图像化数据,需进行逆处理,提取其中的风速预报值。

由于 $G(\hat{F}_{t,256})$ 的分辨率为 256×256 , 首先需将 $G(\hat{F}_{t,256})$ 的分辨率通过式(16)调整至与物理预报网格化风速图像 $\hat{F}_t$ 相同的分辨率。令 F_t'' 为分辨率调整之后的优化预报结果图像,即 $F_t'' \sim G(\hat{F}_{t,256})$ 。

F_t'' 可表示为

$$F_t'' = \begin{bmatrix} p_{1,1,t} & \cdots & p_{1,j',t} & \cdots & p_{1,n,t} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ p_{i',1,t} & \cdots & p_{i',j',t} & \cdots & p_{i',n,t} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ p_{m,1,t} & \cdots & p_{m,j',t} & \cdots & p_{m,n,t} \end{bmatrix} \quad (17)$$

式中 $p_{i',j',t}$ 为 t 时刻 $[x_{i'}, y_{j'}]$ 位置处的优化预报图像像素值。计算优化预报风速值:

$$v_{i',j',t}'' = \frac{p_{i',j',t} \times 1.2v_{\max}'}{255} \quad (18)$$

式中 $v_{i',j',t}''$ 即为 t 时刻 $[x_{i'}, y_{j'}]$ 位置处的优化预报风速值。需要注意的是,针对式(12),当 $\hat{v}_{i',j',t} = -99$ 时, $[x_{i'}, y_{j'}]$ 位置处无风速值或风速值异常,此时优化预测风速值 $v_{i',j',t}''$ 也应等于 -99 , 即无风速值或风速值异常。

4 算例分析

同样以 2 节算例部分所在区域的数据对本研究进行仿真分析。建模数据为 2020 年 11 月 1 日—2022 年 11 月 1 日,测试数据为 2022 年 11 月 2—21 日,数据的时间分辨率为 1h,层高中 10m,预报时间尺度为第 28~51h。物理预报风速仍取 4641 个网格点,实际观测站点 1549 座,为了验证方法的整体性能,测试点位拓展至 38 个,如图 5 所示。其中,实心蓝色点位观测数据用于模型训练和有效性验证,空心红色点位观测数据用于测试模型性能。

具体建模流程如下。




图 5 华北某区域观测风速建模和测试点位分布

Fig. 5 Training and testing sites of wind metering in North of China

1) 数据处理: 对物理预报网格化风速和观测风速进行处理,按照时标对齐两类风速,针对风速超过合理范围的值,置为 -99 。

2) 风速修正: 采用式(1)~(11)的方法,利用实测风速对物理预报网格化风速进行订正。其中,形变控制系数 λ 取 0.03,当某一时刻实际观测风速的有效点位少于 20 个时,为了避免修正异常,该时刻的数据从样本集中剔除。

3) 数据图像化: 采用式(14)的方法对物理预报网格化风速数据进行图像化处理,采用类似式(14)的方法对 2) 中的修正后网格化风速数据进行图像化处理。归一化参数均取 30 m/s。

4) 分辨率调整: 针对 3) 获得的图像数据,采用式(16)的方法对其分辨率进行调整,由原始的 51×91 调整为 256×256 。

5) CycleGAN 模型搭建: 采用 3.2.1 节介绍的方法,构建 CycleGAN 模型。目标函数中, $\min \ell_{\text{cyc}}(G, F)$ 的权重取为 10, 其余 2 项的权重均取 1。输入图像数据和输出图像数据的维度均设定为 1。迭代计算次数设定为 200, 前 100 次的学习率保持为 0.0002, 后 100 的学习率线性下降为 0。

6) 模型训练: 针对 5) 构建的模型,引入 4) 获得的图像样本数据,以物理预报网格化风速图像数据作为输入,以修正后网格化风速图像数据作为目标,对网络进行训练。本研究中,根据仿真环境, batch_size 设定为 40。

7) 模型应用: 根据 6) 训练得到的生成器网络,引入测试时段或预报应用时段内的物理预报网格化风速图像数据,输入图像数据和输出图像数据的维度均设定为 1, 计算得到网格化风速预报结果图像。

8) 风速提取: 针对 7) 得到的网格化风速预报结果图像, 采用 3.3 节的方法对图像进行分辨率调整, 在此基础上, 采用式(18)的方法, 计算最终的风速预报结果值。

按照上述步骤, 基于 GPU 计算服务器, 训练 CycleGAN 网络模型, 并计算测试结果, 所采用 GPU 计算服务器具有 2 核 CUP 和 4 核 GPU, 其中 CPU 型号为 Intel(R) Xeon(R) Silver 4110 CPU@2.10 GHz, 内存为 128 GB; GPU 型号为 Tesla V100, 内存为 32 GB。随机选取 2022 年 11 月 4 日 09:00 的结果进行对比, 如图 6 所示。其中, 图 6(a)为原始物理预报风速图像, 图 6(b)为 TPS 修正后的风速图像, 图 6(c)为 CycleGAN 模型预报的风速图像。





图 6 网格化风速预报结果图像对比

Fig. 6 Grid wind speed forecasting results images


通过图(6)可以看出, 预报结果风速图像在保持风速整体分布特征的同时, 对局部风速的大小(图像明暗)和分布区域边界进行了调整, 说明本文得到的结果具有同时改变局部风速幅值和相关性的能力。

针对图 5 中的 38 个测试点位, 分别提取实测风速、欧洲中尺度气象预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)预报风速和本研究得到的预报风速。需要指出的是, 为了利用风速的空间分布特征, 按照时间断面对风速序列进行分割, 抹去了风速序列的时间相关性, 为了弥补此不足, 针对最终提取获得的预报结果序列, 进行滑动平均滤波。随机选取其中一个测试点位的序列对比结果如图 7 所示, 黑色曲线为 ECMWF 物理预报风速曲线, 绿色曲线为 CycleGAN 预报风速曲线, 红色曲线为实测风速曲线。

针对图 7 的结果, 从幅值偏差来看, 本研究获



(a) 2022-11-01—2022-11-21



(b) 2022-11-14—2022-11-20

图 7 风速预报结果对比

Fig. 7 Forecasted wind speed vs. real wind speed

得的风速预报结果与实际风速的偏离程度明显低于 ECMWF 预报风速, 但高风速的预报能力较差, 偏离较大; 从趋势来看, 14 日下午时段, 实际呈现下降趋势, ECMWF 预报风速的趋势与实际相背离, 而本研究给出的预报风速修正了 ECMWF 预报风速的背离趋势, 使之与实际风速较为一致的下降。验证了本研究的可行性和先进性。进一步统计 38 个测试点位预报结果与实际风速的平均均方根误差和平均相关系数情况, 结果如表 2 所示, 详细统计结果如附表 A1 所示。

表 2 38 个测试点位预报结果总体性能对比

Table 2 Forecasting performance results of 38 sites

参数	ECMWF	本文结果	改进情况
均方根误差	2.352 m/s	1.841 m/s	21.7%
相关系数	64.8%	65.8%	1.0%

由表 2 可以看出, 本研究得到的风速预报结果均方根误差较 ECMWF 预报结果平均降低了 21.7%, 相关系数提升了 1.0 个百分点, 进一步验证了本文方法的可行性和先进性。

为了验证本模型通用性, 在中国西北某气候和地形条件均与华北地区差异显著的地区再次进行了模拟分析。数据时段及其规格参数与上述实例相近, 物理预报风速仍设定为 5 041 个网格点, 实际气象观测站点为 1 672 个, 测试站点(红色点)数量为 16 个, 如图 8 所示。




图 8 中国西北某区域观测风速建模和测试点位分布

Fig. 8 Training and testing sites of wind metering in Northwest of China

采用相同方法进行预报,图 9 比较了其中一个测风站点(图 8 红色点)全年风速序列,其中黑色曲线为 ECMWF 物理预报风速,绿色曲线为 CycGAN 模型的预报风速,红色曲线为真实风速。




图 9 中国西北某站点预报风速与真实风速对比

Fig. 9 Forecasted wind speed vs. actual wind speed for one of site in the northwest of China

表 3 列出了 16 个测风站点全年预报风速与实测风速的均方根误差和相关系数。

表 3 中国西北某区域 16 个点位预报结果平均性能对比
Table 3 Forecasting performance results of 16 sites in the Northwest of China

参数	ECMWF	本文结果	改进情况
均方根误差	2.680 m/s	2.553 m/s	4.72%
相关系数	64.0%	67.5%	3.49%

由图 9 和表 3 可知,所提方法的均方根误差比 ECMWF 预报平均降低 4.72%,相关系数提高 3.49%,验证了本文方法的通用性。

5 结论及展望

本研究聚焦风速准确预报问题,提出一种物理与统计相结合的风速网格化预报技术,给出详细的建模方案,算例仿真验证了所提出方法的可行性和先进性,达到了支撑风电功率预测精度提升、进而促进新能源消纳、保障电力供应的目标。主要结论如下:

1) 采用薄板样条插值方法,可有效利用离散化的实测风速信息订正区域网格化风速预报偏差,解决观测数据缺失地理点位预报风速偏差无法订正的问题。

2) 充分挖掘和利用气象参量的空间关联规律,有利于感知气象参量预报结果的潜在偏差。

3) 图像生成技术可用于挖掘风速的空间关联规律,且由于图像数据对风速空间分布特征的良好体现,对提高风速预报结果的性能具有重要作用。

从仿真结果细节来看,所提出的方法在高风速区间的预报能力不足,可能是受损失函数整体均态偏差最小的影响,后续将引入注意力机制,增强高风速水平区域的偏差影响权重,开展进一步探索。此外,受算力资源限制,各时刻风速预报考虑了空间相关性的影响,但未引入前后时刻风速分布情况,导致风速序列的时间相关信息没有充分利用,待后续提升算力资源后,将通过增加样本维度的方法引入时间相关信息,继续研究利用时间相关规律对提升风速预报性能的价值。

参考文献

[1] United Nations . The Paris agreement[M] . Paris : UNFCCC, 2016.

[2] United Nations. The sustainable development goals report 2022 [R]. UNEP, 2022.

[3] IEA. Clean energy transitions programme 2021[R]. Paris: IEA, 2022.

[4] IEA. Renewable energy market update-May 2022 [R]. Paris: IEA, 2023.

[5] Global Wind Energy Council. Global wind report 2024 [R]. 2024: 138.

[6] 中华人民共和国中央人民政府. 中共中央 国务院关于完整准确全面贯彻新发展理念做好碳达峰碳中和工作的意见[EB/OL]. 北京: 新华社, (2021-10-24). http://www.gov.cn/zhengce/2021-10/24/content_5644613.htm. Central People's Government of the People's Republic of China. Central Committee of the Communist Party of China and the State Council opinions on completely, accurately, and comprehensively implementing the new development philosophy and effectively advancing carbon peak and carbon neutrality work[EB/OL]. Beijing: Xinhua News Agency, (2021-10-24). http://www.gov.cn/zhengce/2021-10/24/content_5644613.htm(in Chinese).

[7] 王铮, 王伟胜, 刘纯, 等. 基于风过程方法的风电功率预测结果不确定性估计[J]. 电网技术, 2013, 37(1): 242-247. WANG Zheng, WANG Weisheng, LIU Chun, et al. Uncertainty estimation of wind power prediction result based on wind process method[J]. Power System Technology, 2013, 37(1): 242-247(in Chinese).

[8] 冯双磊, 胡菊, 宋宗朋, 等. 新能源资源评估与中长期电量预测[M]. 北京: 中国电力出版社, 2020. FENG Shuanglei, HU Ju, SONG Zongpeng, et al. Evaluation of renewable energy resources and medium to

- long term electricity forecast[M]. Beijing: China Electric Power Press, 2020(in Chinese).
- [9] 黄越辉, 王伟胜, 董存, 等. 新能源发电调度运行管理技术[M]. 北京: 中国电力出版社, 2019.
- HUANG Yuehui, WANG Weisheng, DONG Cun, et al. Renewable energy power generation dispatching and operation management technology[M]. Beijing: China Electric Power Press, 2019(in Chinese).
- [10] 王伟胜, 王铮, 董存, 等. 中国短期风电功率预测技术现状与误差分析[J]. 电力系统自动化, 2021, 45(1): 17-27.
- WANG Weisheng, WANG Zheng, DONG Cun, et al. Status and error analysis of short-term forecasting technology of wind power in China[J]. Automation of Electric Power Systems, 2021, 45(1): 17-27(in Chinese).
- [11] 王铮, PESTANA R, 冯双磊, 等. 基于加权系数动态修正的短期风电功率组合预测方法[J]. 电网技术, 2017, 41(2): 500-507.
- WANG Zheng, PESTANA R, FENG Shuanglei, et al. Short-term wind power combination forecasting method based on dynamic coefficient updating[J]. Power System Technology, 2017, 41(2): 500-507(in Chinese).
- [12] 李丹, 唐建, 缪书唯, 黄烽云, 罗娇娇. 考虑时序特征缺失值动态插补的超短期风电功率预测[J]. 中国电机工程学报, 2024, 45(17): 6790-6803.
- LI Dan, TANG Jian, MIAO Shuwei, HUANG Fengyun, LUO Jiaojiao. Ultra-short-term Wind Power Prediction Considering Dynamic Interpolation of Missing Values of Time Series Features[J]. Proceedings of the CSEE, 2024, 45(17): 6790-6803(in Chinese).
- [13] 杨茂, 张书天, 王勃, 苏欣. 基于门控循环加权共形分位数回归的风电功率短期区间预测[J]. 中国电机工程学报, 2024, 45(19): 7565-7574.
- YANG Mao, ZHANG Shutian, WANG Bo, SU Xin. Short-term Wind Power Interval Prediction Based on Weighted Gated Recurrent Conformalized Quantile Regression[J]. Proceedings of the CSEE, 2024, 45(19): 7565-7574(in Chinese).
- [14] MÖHRLÉN C, ZACK J W, GIEBEL G. IEA wind recommended practice for the implementation of renewable energy forecasting solutions[M]. London: Academic Press, 2023.
- [15] 王勃, 王铮, 刘纯, 等. 风力发电功率预测技术及应用[M]. 北京: 中国电力出版社, 2019.
- WANG Bo, WANG Zheng, LIU Chun, et al. Wind generation power forecasting technology and application[M]. Beijing: China Electric Power Press, 2019(in Chinese).
- [16] 刘桂艳, 连喜虎, 高松, 等. WRF 模式对渤海和黄海海面风预报误差分析[J]. 防灾科技学院学报, 2023, 25(1): 40-48.
- LIU Guiyan, LIAN Xihu, GAO Song, et al. Analysis of sea surface wind prediction error in the Bohai Sea and the Yellow Sea by WRF model[J]. Journal of Institute of Disaster Prevention, 2023, 25(1): 40-48(in Chinese).
- [17] 许冬梅, 沈菲菲, 李泓, 等. 新一代静止气象卫星葵花 8 号的晴空红外辐射率资料同化对台风“天鸽”的预报影响研究[J]. 海洋学报, 2022, 44(3): 40-52.
- XU Dongmei, SHEN Feifei, LI Hong, et al. The impact of assimilation of Himawari-8 clear-sky data from the new generation geostationary meteorological satellite on the forecast of super Typhoon Hato[J]. Haiyang Xuebao, 2022, 44(3): 40-52(in Chinese).
- [18] 王学森. 多普勒雷达径向风退模糊及反演同化研究[D]. 兰州: 兰州大学, 2022.
- WANG Xuesen. Study on dealiasing and retrieval assimilation of Doppler radar radial velocity[D]. Lanzhou: Lanzhou University, 2022(in Chinese).
- [19] 刘瑞婷, 陈明轩, 肖现, 等. 雷达资料快速更新四维变分同化中增加地面资料同化对强对流临近数值预报的影响[J]. 气象学报, 2021, 79(6): 921-942.
- LIU Ruiting, CHEN Mingxuan, XIAO Xian, et al. The impact of assimilating surface observations in rapid-refresh four-dimensional variational radar data assimilation system on model-based severe convection nowcasting[J]. Acta Meteorologica Sinica, 2021, 79(6): 921-942(in Chinese).
- [20] 路佩瑶. WRF-3DVAR 的气象资料同化对近地面风速及大气重污染过程模拟的改进[D]. 南京: 南京信息工程大学, 2021.
- LU Peiyao. Improvement of meteorological data assimilation for WRF-3DVAR in simulating near surface wind speed and atmospheric heavy pollution processes[D]. Nanjing: Nanjing University of Information Science & Technology, 2021(in Chinese).
- [21] 冯佳宁. 雷达径向风资料同化对登陆台风数值预报的改进[D]. 北京: 中国气象科学研究院, 2021.
- FENG Jianing. Improved prediction of landfalling typhoon in China based on assimilation of radar radial winds[D]. Beijing: University of Chinese Academy of Sciences, 2021(in Chinese).
- [22] 盛春岩, 刘诗军, 范苏丹, 等. 不同 AMDAR 资料同化时间窗对台风“摩羯”预报影响研究[J]. 海洋气象学报, 2021, 41(4): 11-25.
- SHENG Chunyan, LIU Shijun, FAN Sudan, et al. Effect study of different AMDAR data assimilation time window to Typhoon Yagi[J]. Journal of Marine Meteorology, 2021, 41(4): 11-25(in Chinese).
- [23] 张鑫宇, 陈敏, 范水勇. 基于莫宁-奥布霍夫相似理论的地面站点风速预报偏差订正[J]. 气象, 2023, 49(5):

- 624-632.
- ZHANG Xinyu, CHEN Min, FAN Shuiyong. Correction of wind speed forecast deviations at ground stations based on Monin-Obukhov similarity theory[J]. *Meteorological Monthly*, 2023, 49(5): 624-632(in Chinese).
- [24] 辛德根. 基于 Kalman 滤波的风速预测和分析[D]. 兰州: 兰州大学, 2017.
- XIN Degen. Prediction and analysis of wind speed based on Kalman filter[D]. Lanzhou: Lanzhou University, 2017(in Chinese).
- [25] 马婉贞. 基于 WRF 的 DBN 风速预测与并行优化研究[D]. 乌鲁木齐: 新疆大学, 2017.
- MA Wanzhen. Study of WRF Wind speed prediction based on DBN model and optimization in parallel[D]. Urumqi: Xinjiang University, 2017(in Chinese).
- [26] 孙亦皓, 刘浩, 胡天宇, 等. 基于时空关联特征与 GCN-FEDformer 的风速短期预测方法[J]. *中国电机工程学报*, 2024, 44(21): 8496-8506.
- SUN Yihao, LIU Hao, HU Tianyu, et al. Short-term wind speed forecasting based on GCN and FEDformer[J]. *Proceedings of the CSEE*, 2024, 44(21): 8496-8506(in Chinese).
- [27] 刘志杰, 刘彬贤, 王锐, 等. 基于传统和深度学习技术的黄渤海海域大风预报方法研究[J]. *海洋预报*, 2022, 39(6): 34-43.
- LIU Zhijie, LIU Binxian, WANG Rui, et al. Research on the gale prediction methods in the Yellow Sea and Bohai Sea based on traditional and deep learning technologies[J]. *Marine Forecasts*, 2022, 39(6): 34-43(in Chinese).
- [28] 肖寅. 基于 WRF 模式的短期风速预测及订正方法研究[D]. 南京: 南京信息工程大学, 2016.
- XIAO Yin. WRF model-based short-term wind speed forecasting and correction[D]. Nanjing: Nanjing University of Information Science & Technology, 2016(in Chinese).
- [29] 林智琛, 陈晓梦, 李白良, 等. 福建省沿海风电场短时预报风速的订正[J]. *气象与环境科学*, 2023, 46(1): 23-31.
- LIN Zhichen, CHEN Xiaomeng, LI Bailiang, et al. Revision of short-time wind speed forecast in Fujian coastal wind power plant[J]. *Meteorological and Environmental Sciences*, 2023, 46(1): 23-31(in Chinese).
- [30] 方楠, 姜舒婕, 闫晓敏, 等. 基于长短期记忆神经网络的风速超短期快速滚动预报技术[J]. *气象科技*, 2022, 50(6): 842-850.
- FANG Nan, JIANG Shujie, YAN Xiaomin, et al. Research on ultra short-term fast rolling prediction technology of wind speed based on LSTM neural network[J]. *Meteorological Science and Technology*, 2022, 50(6): 842-850(in Chinese).
- [31] 刘志丰, 丁锋. 基于人工神经网络的沿海风速多步预测研究[J]. *气象科技*, 2022, 50(6): 851-858.
- LIU Zhifeng, DING Feng. Research on application of artificial neural network for sea surface wind speed forecasting[J]. *Meteorological Science and Technology*, 2022, 50(6): 851-858(in Chinese).
- [32] WANG Shijun, LIU Chun, LIANG Kui, et al. Wind speed prediction model based on improved VMD and sudden change of wind speed[J]. *Sustainability*, 2022, 14(14): 8705.
- [33] ULYANOV D, VEDALDI A, LEMPITSKY V. Instance normalization: the missing ingredient for fast stylization[J]. *arXiv*: 1607. 08022, 2016.
- [34] 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.
- YANG Guoqing, LIU Shilin, WANG Deyi, et al. Short-term wind power forecasting based on Attention-GRU wind speed correction and stacking[J]. *Acta Energiæ Solaris Sinica*, 2022, 43(12): 273-281(in Chinese).
- [35] 许立兵, 孔扬, 周峥, 等. 基于机器学习的风场预报订正方法研究[J]. *陕西气象*, 2023(1): 15-20.
- XU Libing, KONG Yang, ZHOU Zheng, et al. Research on prediction and correction method of wind field based on machine learning[J]. *Journal of Shaanxi Meteorology*, 2023(1): 15-20(in Chinese).
- [36] LI Fei, REN Guorui, LEE J. Multi-step wind speed prediction based on turbulence intensity and hybrid deep neural networks[J]. *Energy Conversion and Management*, 2019, 186: 306-322.
- [37] YOSHIDA S, SUZUKI H, KITAJIMA T, et al. Correction method of wind speed prediction system using predicted wind speed fluctuation[C]//*Proceedings of the 55th Annual Conference of the Society of Instrument and Control Engineers of Japan*. Tsukuba: IEEE, 2016.
- [38] PAN Chao, TAN Qide, QIN Benshuang. A new method of wind speed prediction based on weighted optimal fuzzy c-means and modular extreme learning machine[J]. *Wind Engineering*, 2018, 42(5): 447-457.
- [39] BLANCHARD T, SAMANTA B. Wind speed forecasting using neural networks[J]. *Wind Engineering*, 2020, 44(1): 33-48.
- [40] KHODAYAR M, WANG Jianhui. Spatio-temporal graph deep neural network for short-term wind speed forecasting[J]. *IEEE Transactions on Sustainable Energy*, 2019, 10(2): 670-681.
- [41] KHODAYAR M, KAYNAK O, KHODAYAR M E. Rough deep neural architecture for short-term wind speed

- forecasting[J]. IEEE Transactions on Industrial Informatics, 2017, 13(6): 2770-2779.
- [42] LIN Li, XIA Dandan, DAI Liming, et al. Chaotic analysis and prediction of wind speed based on wavelet decomposition[J]. Processes, 2021, 9(10): 1793.
- [43] NAN Xiaoqiang, LI Qunzhan, QIU Daqiang, et al. Short-term wind speed syntheses correcting forecasting model and its application[J]. International Journal of Electrical Power & Energy Systems, 2013, 49: 264-268.
- [44] MOGOS A S, SALAUDDIN M, LIANG Xiaodong, et al. An effective very short-term wind speed prediction approach using multiple regression models[J]. IEEE Canadian Journal of Electrical and Computer Engineering, 2022, 45(3): 242-253.
- [45] JIN Ji, WANG Bin, YU Min, et al. A novel self-adaptive wind speed prediction model considering atmospheric motion and fractal feature[J]. IEEE Access, 2020, 8: 215892-215903.
- [46] KARAKUŞ O, KURUOĞLU E E, ALTINKAYA M A. Long term wind speed prediction with polynomial autoregressive model[C]//Proceedings of the 23rd Signal Processing and Communications Applications Conference. Malatya: IEEE, 2015: 645-648.
- [47] MONAHAN A H. The Gaussian statistical predictability of wind speeds[J]. Journal of Climate, 2013, 26(15): 5563-5577.
- [48] SURYAWANSHI A, GHOSH D. Wind speed prediction using spatio-temporal covariance[J]. Natural Hazards, 2015, 75(2): 1435-1449.
- [49] 徐景峰, 宋林烨, 陈明轩, 等. 冬奥会复杂山地百米尺度 10m 风速预报的机器学习订正对比试验[J]. 大气科学, 2023, 47(3): 805-824.
- XU Jingfeng, SONG Linye, CHEN Mingxuan, et al. Comparative machine learning-based correction experiment for a 10m wind speed forecast at a 100m resolution in complex mountainous areas of the Winter Olympic Games[J]. Chinese Journal of Atmospheric Sciences, 2023, 47(3): 805-824(in Chinese).
- [50] 毛波, 杨昊, 周世杰, 等. 基于 CMA-REPS 格点预报数据的深度学习风速订正方法[J]. 成都信息工程大学学报, 2023, 38(3): 264-270.
- MAO Bo, YANG Hao, ZHOU Shijie, et al. A deep learning method for wind speed grid point forecasting data correction based on CMA-REPS[J]. Journal of Chengdu University of Information Technology, 2023, 38(3): 264-270(in Chinese).
- [51] BOOKSTEIN F L. Principal warps: thin-plate splines and the decomposition of deformations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11(6): 567-585.
- [52] ZHU Junyan, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 2242-2251.
- [53] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [54] JOHNSON J, ALAHI A, LI Feifei. Perceptual losses for real-time style transfer and super-resolution[C]//Proceedings of the 14th European Conference on Computer Vision. Amsterdam: Springer, 2016.
- [55] ISOLA P, ZHU Junyan, ZHOU Tinghui, et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 5967-5976.

附录 A

表 A1 38 个测试点位的均方根误差和相关系数

Table A1 RMSE and correlation coefficient of 38 sites

编号	均方根误差			相关系数		
	ECMWF/ (m/s)	本文结果/ (m/s)	降低率/ %	ECMWF	本文结果	提升百分点/ %
1	1.851	1.948	-5.2	0.711	0.737	2.6
2	2.862	2.778	2.9	0.583	0.581	-0.1
3	2.845	2.564	9.9	0.567	0.562	-0.5
4	2.637	2.014	23.6	0.673	0.676	0.3
5	2.245	2.597	-15.7	0.672	0.658	-1.4
6	2.470	2.748	-11.2	0.697	0.700	0.3
7	2.332	2.505	-7.4	0.470	0.468	-0.3
8	1.736	2.174	-25.2	0.740	0.753	1.3
9	3.012	1.861	38.2	0.782	0.776	-0.6
10	1.978	2.112	-6.8	0.781	0.786	0.5
11	3.657	2.369	35.2	0.501	0.519	1.8
12	3.400	2.156	36.6	0.526	0.556	3.0
13	1.709	1.801	-5.4	0.420	0.395	-2.5
14	2.470	2.357	4.6	0.657	0.657	0.0
15	3.488	2.283	34.5	0.544	0.556	1.2
16	1.804	1.088	39.7	0.632	0.662	3.0
17	1.927	2.157	-12.0	0.687	0.719	3.2
18	1.630	1.271	22.0	0.708	0.702	-0.6
19	2.286	1.313	42.6	0.652	0.656	0.4
20	1.757	1.283	27.0	0.705	0.709	0.4
21	2.306	1.493	35.3	0.639	0.646	0.7
22	2.576	2.088	18.9	0.695	0.703	0.8
23	2.005	1.386	30.9	0.728	0.733	0.5
24	2.645	1.639	38.0	0.669	0.678	0.9

续表

编号	均方根误差			相关系数		
	ECMWF/ (m/s)	本文结果/ (m/s)	降低率/ %	ECMWF	本文结果	提升百分点/ %
25	2.010	1.304	35.1	0.685	0.697	1.2
26	2.542	1.878	26.1	0.688	0.681	-0.7
27	3.754	2.566	31.6	0.547	0.567	1.9
28	2.025	1.141	43.7	0.690	0.710	2.0
29	3.427	2.243	34.6	0.548	0.564	1.6
30	1.631	1.215	25.5	0.734	0.745	1.1
31	1.646	1.854	-12.6	0.716	0.707	-0.9
32	1.883	1.031	45.3	0.692	0.704	1.2
33	2.714	1.639	39.6	0.524	0.557	3.3
34	2.433	2.279	6.3	0.626	0.638	1.2
35	2.055	0.981	52.3	0.675	0.703	2.8
36	2.101	1.078	48.7	0.622	0.644	2.2
37	1.513	1.642	-8.5	0.718	0.748	3.1
38	2.015	1.106	45.1	0.721	0.736	1.5
平均	2.352	1.841	21.7	0.648	0.658	1.0

表 A2 中国西北某地区 16 个测试点位的
均方根误差和相关系数

Table A2 Root mean square error and correlation
coefficient of 16 sites in the Northwest of China

编号	均方根误差			相关系数		
	ECMWF/ (m/s)	本文结果/ (m/s)	降低率/ %	ECMWF	本文结果	提升百分点/ %
1	2.680	2.553	4.72	0.640	0.675	3.49
2	2.147	1.881	12.39	0.531	0.577	4.55
3	1.984	1.803	9.15	0.435	0.493	5.84
4	1.470	1.395	5.14	0.505	0.602	9.69

续表

编号	均方根误差			相关系数		
	ECMWF/ (m/s)	本文结果/ (m/s)	降低率/ %	ECMWF	本文结果	提升百分点/ %
5	1.748	1.572	10.02	0.532	0.583	5.07
6	1.806	1.648	8.76	0.551	0.582	3.07
7	2.002	1.852	7.50	0.566	0.600	3.35
8	1.402	1.342	4.23	0.200	0.214	1.40
9	1.940	1.807	6.82	0.393	0.390	-0.30
10	3.123	2.955	5.39	0.372	0.408	3.65
11	2.161	1.986	8.08	0.813	0.833	1.94
12	1.865	1.641	12.02	0.484	0.552	6.83
13	1.934	1.808	6.53	0.667	0.705	3.80
14	1.878	1.690	10.02	0.517	0.563	4.63
15	1.816	1.630	10.22	0.453	0.481	2.79
16	2.376	2.373	0.14	0.623	0.618	-0.53
平均	2.680	2.553	4.72	0.640	0.675	3.49



冯双磊

在线出版日期：2025-08-19。

收稿日期：2025-04-10。

作者简介：

冯双磊(1980)，男，博士，教授级高级工程师，研究方向为人工智能、气象预报、新能源发电功率预测、新能源建模仿真等，
fengsl@epri.sgcc.com.cn；

*通信作者：王铮(1986)，男，博士，高级工程师，研究方向为人工智能、气象预报和新能源发电预测技术等，
wangz@epri.sgcc.com.cn。

(责任编辑 李泽荣)