

DOI: 10.19783/j.cnki.pspc.240541

# 计及 NWP 风速横纵向误差的循环确定性策略梯度 风速修正模型

黄南天<sup>1</sup>, 唐立鹏<sup>1</sup>, 戴千斌<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 吉林 132012;  
2. 辽宁蒲石河抽水蓄能有限公司, 辽宁 丹东 118216)

**摘要:** 目前数值天气预报(numerical weather prediction, NWP)风速修正方法大多基于纵向误差的幅值特性评估建模, 忽视了 NWP 风速序列与历史风速序列间超前或延迟效应导致的横向误差对 NWP 风速修正的潜在影响。因此, 提出计及 NWP 风速横纵向误差的循环确定性策略梯度(recurrent deterministic policy gradient, RDPG)风速修正模型。首先, 基于加权欧式距离相似度确定各个 NWP 风速待修正点超前/滞后时序区间(lead/lag timing interval, LLTI)边界, 构成强相关时序区间。然后, 采用 LLTI 内统计特征代替该区间 NWP 原始气象特征, 并基于沙普利可加性解释法(shapley additive explanation, SHAP)归因理论, 根据每个特征的边际贡献评估不同特征对模型输出的影响程度。最后, 建立基于 RDPG 的 NWP 风速修正模型。通过算例分析, 验证了所提方法在超短期、短期预测的不同时间尺度下修正 NWP 风速的有效性和可行性。

**关键词:** 数值天气预报; 横向误差; 纵向误差; 超前/滞后时序区间; 循环确定性策略梯度

## Wind speed correction method for numerical weather prediction based on a recurrent deterministic policy gradient algorithm considering lateral and longitudinal error

HUANG Nantian<sup>1</sup>, TANG Lipeng<sup>1</sup>, DAI Qianbin<sup>2</sup>

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education (Northeast Electric Power University), Jilin 132012, China; 2. Liaoning Pushihe Pumped Storage Co., Ltd., Dandong 118216, China)

**Abstract:** The current numerical weather prediction (NWP) wind speed correction methods are based on the amplitude characteristic evaluation modeling of the longitudinal error. They ignore the potential impact of the lateral error caused by the lead or delay effect between the NWP wind speed series and historical wind speed series on NWP wind speed correction. Therefore, an NWP wind speed reinforcement correction method based on the recurrent deterministic policy gradient (RDPG) algorithm and considering lateral and longitudinal errors is proposed. First, based on weighted Euclidean distance similarity, the lead/lag timing interval (LLTI) boundary of each NWP wind speed to be corrected is determined to form a strongly correlated timing interval. Subsequently, the statistical characteristics of the LLTI are used to replace the original meteorological characteristics of the NWP. Based on the Shapley additive explanations (SHAP) attribution theory, the influence of different features on the model output is evaluated using the marginal contribution of each feature. Finally, an NWP wind speed correction model based on the RDPG is established. Through an example analysis, the effectiveness and feasibility of the proposed method for modifying the NWP wind speed on different time scales of ultra-short-term and short-term predictions are verified.

This work is supported by the Science and Technology Development Plan of Jilin Province (No. 20210201126GX).

**Key words:** numerical weather prediction; longitudinal error; lateral error; lead/lag timing interval; recurrent deterministic policy gradient

## 0 引言

近年来, 以风电为代表的可再生能源经历了跨

越式发展。风电逐步由小规模、补充性电源向主力电源过渡<sup>[1-3]</sup>。然而, 受风资源时变特性的影响, 风电具有较强的波动性、间歇性和不确定性。随着风电装机规模的持续扩大, 高比例风电接入给电网调度、电力系统运行的安全性和稳定性等方面带来了

基金项目: 吉林省科技发展计划项目资助(20210201126GX)

挑战<sup>[4-5]</sup>。风速的准确预测可以使电力调度机构及时优化风电场运行, 是减轻风电并网不利影响的有效途径, 对提升风电功率预测精度和保证电网稳定运行具有重要意义<sup>[6-7]</sup>。

NWP 气象数据是风电功率预测模型的关键输入, 其中, NWP 风速是 NWP 应用于风电功率预测的重要基础<sup>[8-10]</sup>。文献[11]采用多元时间序列聚类算法和 Seq2Seq 深度学习算法, 通过输入 NWP 数据与风电场历史实测数据, 对风电功率进行预测。文献[12]采用特征提取技术挖掘 NWP 和历史风电数据非线性特征, 建立基于方差权重分配策略的风电功率组合预测模型。然而, 如果 NWP 风速预测存在误差, 则会严重影响预测精度<sup>[13]</sup>。因此, 有必要针对 NWP 风速预测误差进行修正, 提高 NWP 风速预测的准确性。

NWP 预测风速误差分为横/纵向误差, 横向误差为 NWP 风速序列和实际风速序列间的时间错位, 纵向误差为两者间的幅值偏差<sup>[14-15]</sup>。文献[16]采用主成分分析法对 NWP 信息进行分析处理, 建立基于深度信念网络的风速修正模型。文献[17]通过提取 NWP 风速纵向误差的标准差作为权重, 得到 NWP 风速权重时间序列, 建立基于门控神经网络的短期风电 NWP 风速误差修正模型。然而上述方法没有考虑 NWP 风速序列的横向误差对 NWP 风速修正的影响, 导致 NWP 风速和实际风速之间的映射关系具有一定的随机不确定性, 进而使预测模型精度受损。同时由于电力调度机构对风电出力上报的实际需求, NWP 风速修正结果需提前 12 h 给出, 进一步增大了 NWP 风速修正的难度, 影响了现有统计模型的校正精度。

基于 NWP 数据特征挖掘的风速修正研究已取得一定成果, 但是在处理风能不确定性更强的地区时, 缺乏自适应能力, 模型通用性不强<sup>[18-20]</sup>。深度强化学习(deep reinforcement learning, DRL)融合深度学习(deep learning, DL)的感知能力和强化学习(reinforcement learning, RL)的决策能力, 能够在复杂高维的状态动作空间中进行端到端的感知决策<sup>[21]</sup>。文献[22]提出用于短期负荷预测的新型异步深度强化学习模型, 相比于传统机器学习算法具有更高的预测精度和更稳定的收敛性。文献[23]建立基于数据自适应分解、强化学习集成和误差修正的短期风速预测混合模型。文献[24]提出基于 Actor-Critic 框架的深度确定性策略梯度算法(deep deterministic policy gradient, DDPG), 在解决连续动作空间的问题上具有较大优势。但是, NWP 数据具有强非线性, DDPG 算法中的多层感知器(multilayer perceptron,

MLP)作为 Critic 网络, 处理复杂非线性数据时对于目标 Q 值的评估不够精确, 不能有效更新 Actor 网络参数, 难以保证 NWP 风速修正模型的收敛性与稳定性。

综上所述, 为提高 NWP 风速修正精度, 消除 NWP 预测风速中存在的横/纵向误差, 同时优化 RDPG 算法, 提高模型稳定性, 本文提出基于循环确定性策略梯度的 NWP 风速修正模型。首先, 基于加权欧式距离相似度量不同 NWP 风速预测点横向误差偏移程度, 确定横向误差导致 NWP 风速序列的时序偏移性, 将 NWP 风速序列 LLTI 作为输入特征提取区间范围, 通过确定各个 NWP 风速待修正点 LLTI 边界, 划分最优 LLTI。然后, 为保证不同预测时间点下非一致性时序区间模型结构的统一, 采用 LLTI 统计特征代替 NWP 原始时序气象特征。在此基础上, 基于 SHAP 理论, 确定区间统计特征重要度排序, 分析不同特征对模型输出效果的相关影响。最后, 基于 Actor-Critic 框架建立循环确定性策略梯度的 NWP 风速修正模型。

## 1 计及 NWP 风速序列横纵向时序偏移性的超前/滞后时序区间确定

### 1.1 横纵向误差分析

风速误差主要包括横向误差与纵向误差两种。如图 1 所示, 将 NWP 风速与实际风速的纵向幅值误差定义为纵向误差, 用于描述预测数值高于或者低于实际数值的情况; 将 NWP 风速与实际风速在水平方向上的时间误差定义为横向误差, 用于描述预测风速序列超前或滞后实际风速序列的程度。

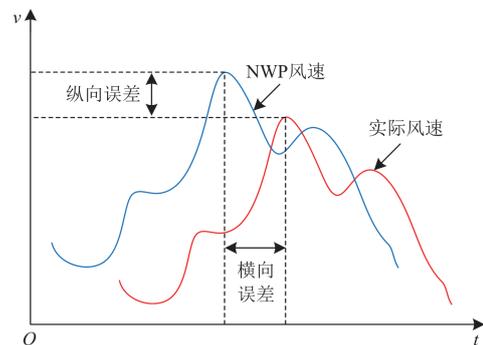


图 1 双向误差定义

Fig. 1 Definition of two types of wind forecasting error

纵向误差表现为 NWP 预报风速与实测风速的幅值差异, 本文采用基于 RDPG 的风速修正模型对其进行修正, 有效提高了修正精度。而横向误差表现为 NWP 预报风速与实测风速时间轴上的时序差

异, 本文采用超前/滞后时序区间表述横向误差后, 将其作为输入特征之一, 再通过基于 RDPG 的风速修正模型对其进行修正。

由于 NWP 风速序列与实际风速序列之间存在横向误差, NWP 风速序列相比实际风速序列会产生一定的横向偏移。因此, 有必要考虑 NWP 风速序列存在的时序效应, 采用超前时序区间和滞后时序区间共同构成模型输入特征提取时序区间范围, 建立 NWP 风速序列时序区间与 NWP 风速待修正点间的映射关系。

图 2 为超前/滞后时序区间划分过程。本文将给出 NWP 风速修正结论的时刻提前 12 h( $T_0$ , 即前一天 12:00), 满足电网实际调度需求。特征计算数据包括: 风速预测日前 12—24 h(即前一天 00:00 至 12:00)真实的历史气象数据、风速预测日前 0—12 h(即前一天 12:00 至 24:00)的 NWP 气象数据、预测日 NWP 气象数据以及预测日后一天的 NWP 气象数据。为了分析滞后时序区间修正效果, 需要人为增加待预测日后一日的 NWP 数据噪声, 以模仿因为预测时间增长带来的额外 NWP 预测误差。

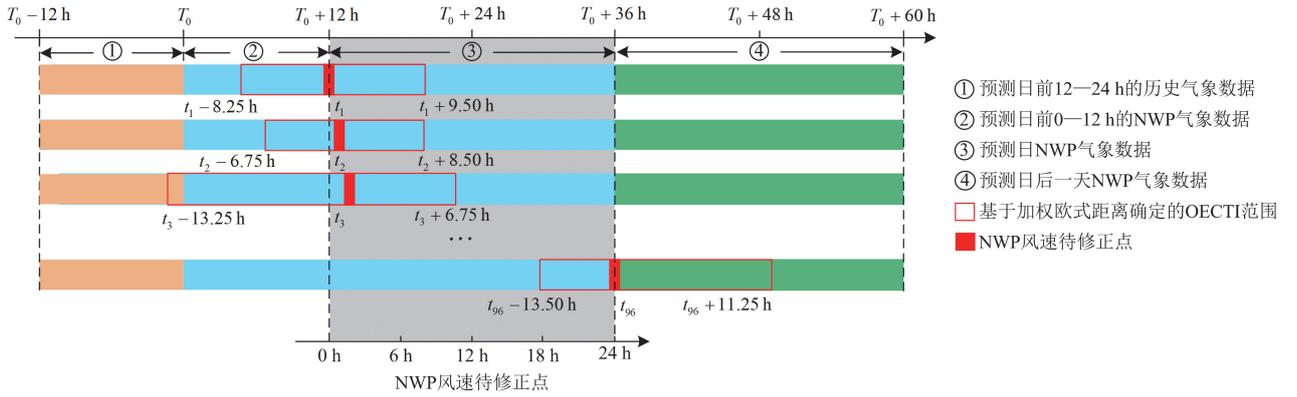


图 2 超前/滞后时序区间划分过程

Fig. 2 LLTI division process

### 1.2 NWP 风速待修正点的超前/滞后时序区间划分

考虑到不同气象参数在相似性度量中表现出的重要性不同, 本文采用加权欧式距离相似度分别确定各个风速预测点的强相关时序区间。根据特征中属性的重要性赋予不同气象参数权值系数, 解决参数差异化重要性对相似度衡量的影响<sup>[25]</sup>。

首先, 设 NWP 风速待修正点的气象参数特征向量为  $X = [V, D, T, H, P]$ , 其中  $V$ 、 $D$ 、 $T$ 、 $H$ 、 $P$  分别该点的风速、风向、温度、湿度、压强。然后对该特征向量进行归一化处理, 设处理后的第  $i$  个样本点的气象参数特征向量为  $X_i = [V(i), T(i), D(i), H(i), P(i)]$ , 则 NWP 风速待修正点气象参数特征向量为  $X_0 = [V_0(i), T_0(i), D_0(i), H_0(i), P_0(i)]$ , 计算第  $i$  个 NWP 风速样本点与该点的气象参数特征向量的加权欧式距离相似度  $S_i$ , 表示为

$$S_i = \frac{1}{1 + \left[ \sum_{j=1}^m \omega_j [x_0(j) - x_i(j)]^2 \right]^{\frac{1}{2}}} \quad (1)$$

式中:  $m$  为气象参数的数量;  $\omega_j$  为第  $j$  个气象参数的权重;  $j$  为气象参数的序号;  $x_0(j)$  为待修正点的

气象参数特征向量;  $x_i(j)$  为第  $i$  个 NWP 风速样本点的气象参数特征向量。

加权欧式距离相似度的取值范围为(0,1), 越靠近 1 表示两点的相关性越强。考虑到加权欧式距离相似度大于 0.8 时, 两点之间具有强相关性<sup>[26]</sup>, 因此设置样本最优时序区间边界点阈值  $D_0$  为 0.8。

基于熵权法确定各气象参数的权重。各评价对象中某项指标的差异越大, 对应指标的熵值越小, 所涵盖的有效信息量越多, 在评价对象中重要度越高<sup>[27]</sup>。设有  $n$  个历史日样本数据, 每个样本有  $m$  个的气象参数, 形成  $n \times m$  阶数据矩阵  $A = [z_{ij}]_{n \times m}$ , 其中  $z_{ij}$  表示第  $i$  个历史日中第  $j$  个气象参数的数值。第  $j$  个气象参数的熵  $H_j$  为

$$H_j = -\frac{1}{\ln n} \sum_{i=1}^n b_{ij} \ln b_{ij} \quad (2)$$

式中,  $b_{ij} = \frac{z_{ij}}{\sum_{i=1}^n z_{ij}}$ ,  $j = 1, 2, \dots, m$ 。

当  $b_{ij} = 0$  时, 设  $b_{ij} \ln b_{ij} = 0$ , 则第  $j$  个气象参数的权重  $\omega_j$  为

$$\omega_j = \frac{1 - H_j}{\sum_{j=1}^m (1 - H_j)} \quad (3)$$

式中,  $\omega_j \in [0, 1]$ , 则  $\sum_{j=1}^m \omega_j = 1$ 。

## 2 基于 SHAP 理论的非一致性区间特征评估

### 2.1 超前/滞后时序区间特征

为了保证每个预测时间点下非一致性最优时序相关区间预测模型结构的统一, 选择表 1 中 7 类区间统计特征作为本修正模型基本的输入特征<sup>[28]</sup>。

表 1 超前/滞后时序区间统计特征

Table 1 Statistical features of LLTI

特征标号	统计特征	描述
1	$V_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n v_i$	风速平均值
2	$V_{\text{max}} = \{\max(v_i), i = 1, \dots, n\}$	风速最大值
3	$V_{\text{min}} = \{\min(v_i), i = 1, \dots, n\}$	风速最小值
4	$D_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n d_i$	风向平均值
5	$T_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n t_i$	温度平均值
6	$H_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n h_i$	湿度平均值
7	$P_{\text{mean}} = \frac{1}{n} \sum_{i=1}^n p_i$	气压平均值

### 2.2 SHAP 理论

由于不同气象统计特征对 NWP 风速修正的影响程度不同, 本文采用 SHAP 理论评估上述特征的重要程度。SHAP 理论是基于博弈论中的 Shapley 值启发的加性解释模型, 用于量化每个特征对模型预测所做的贡献<sup>[29]</sup>。首先, 计算一个特征加入到模型中的边际贡献; 然后, 计算该特征在所有特征序列中不同的边际贡献; 最后, 计算该特征所有边际贡献的均值, 即对应的 Shapley 值。计算方法如式(4)、式(5)所示。

$$f(x) = g(x) = \phi_0 + \sum_{i=1}^M \phi_i \quad (4)$$

$$\left\{ \begin{array}{l} \phi_i = \sum_S \frac{|S|!(M - |S| - 1)!}{M!} [f_{S \cup \{x_i\}}(x_{S \cup \{x_i\}}) - f_S(x_S)] \\ S \subseteq \{x_1, x_2, \dots, x_M\} / \{x_i\} \end{array} \right. \quad (5)$$

式中:  $f(x)$  为预测模型;  $g(x)$  为用于解释模型评估结果的加性器;  $\phi_0$  为模型预测基准值;  $\phi_i$  为第  $i$  个特征的 Shapley 值;  $M$  为特征总数;  $\{x_1, x_2, \dots, x_M\}$  为所有输入特征的集合;  $x_S$  为子集  $S$  中的元素;  $S$  为集合  $\{x_1, x_2, \dots, x_M\}$  中不包含  $x_i$  的特征子集;  $|S|$  为子

集  $S$  中包含的特征数量;  $f_S(x_S)$  为在输入特征  $S$  时的预测模型, 将特征集合  $\{x_1, x_2, \dots, x_M\}$  中未包含在子集  $S$  的其他特征置零。

SHAP 理论中每个特征 Shapley 值绝对值越大表示对该样本预测结果的影响越大, Shapley 值的正负则反映特征将增大或减小模型的输出结果。而且当模型发生变化, 使得某一个特征的边际贡献增大或不变时, 那么反映该特征重要度的相应的归因值也应当增大或不变, 这一性质保证了 SHAP 归因分析的结果能正确反映特征对模型输出的贡献, 评估不同特征对模型输出的影响程度, 降低多特征引入对模型效果的负面影响<sup>[30]</sup>。

### 2.3 基于 SHAP 理论的区间特征评估

基于 SHAP 归因理论算法评估 NWP 气象数据中对实际风速影响最大的相关特征, 通过计算日内 NWP 风速待修正点 Shapley 值的平均绝对值大小, 确定各点多气象特征重要性排序, 如图 3 所示。

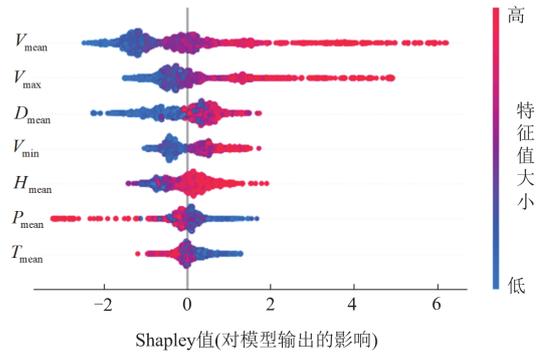


图 3 超前/滞后时序区间特征 Shapley 值排序

Fig. 3 LLTI feature Shapley value

图 3 中, 每个点代表单个样本的特征, 纵坐标是本文所考虑的 NWP 气象特征, 从上向下代表特征的重要程度逐渐降低, 横坐标为特征的 Shaply 值。利用不同颜色表示样本中每个特征值的大小, 颜色越红代表特征值越大, 越蓝表示特征值越小。从图 3 可以看出, 在所有 NWP 气象特征中, 特征重要度从高到底分别是  $V_{\text{mean}}$ 、 $V_{\text{max}}$ 、 $D_{\text{mean}}$ 、 $V_{\text{min}}$ 、 $H_{\text{mean}}$ 、 $P_{\text{mean}}$ 、 $T_{\text{mean}}$ 。本文采用  $|S_{\text{mean}}^{\text{HAP}}|$  表示样本 Shapley 值的绝对值相加后平均值的大小。表 2 展示了不同特征的  $|S_{\text{mean}}^{\text{HAP}}|$  值。其中,  $V_{\text{mean}}$  的  $|S_{\text{mean}}^{\text{HAP}}|$  值为 1.07, 对 NWP 风速修正的结果影响最大。

表 2 不同特征的  $|S_{\text{mean}}^{\text{HAP}}|$  值

Table 2  $|S_{\text{mean}}^{\text{HAP}}|$  value of different features

特征	$V_{\text{mean}}$	$V_{\text{max}}$	$D_{\text{mean}}$	$V_{\text{min}}$	$H_{\text{mean}}$	$P_{\text{mean}}$	$T_{\text{mean}}$
$ S_{\text{mean}}^{\text{HAP}} $	1.07	0.68	0.53	0.48	0.35	0.24	0.22

为了进一步评估特征是否对模型精度具有负面影响, 本文通过剔除单个气象因素特征来验证特征的有效性。首先, 将所有特征作为模型输入。然后, 根据特征  $|S_{\text{mean}}^{\text{HAP}}|$  值的大小, 按照特征重要程度的不同, 从高到低依次剔除 NWP 的风速、风向、湿度、气压、温度等单个气象特征因素, 再进行 NWP 风速修正。上述方法的 NWP 风速修正效果如图 4 所示。当剔除 NWP 风速特征时, 对 NWP 风速修正的影响最大, 其次剔除 NWP 风向特征。表 3 为缺失不同气象特征模型修正精度指标, 当剔除 NWP 的温度、湿度、气压特征时, 与考虑所有气象特征情况进行对比, 性能指标的数值反而提升, 而剔除 NWP 的风速、风向特征时, NWP 风速修正模型效果都有不同程度的降低。其中, 剔除 NWP 风速修正的效果最差。由此可以看出 NWP 风速、风向特征对 NWP 风速修正模型的正向贡献程度最大, NWP 温度、湿度、气压特征对 NWP 风速修正具有负面影响。因此, 本文结合不同特征的  $|S_{\text{mean}}^{\text{HAP}}|$  值, 确定 0.45 为阈值, 选定对模型具有正向增益效果的  $V_{\text{mean}}$ 、 $V_{\text{max}}$ 、 $D_{\text{mean}}$ 、 $V_{\text{min}}$  作为 NWP 风速修正模型的输入。

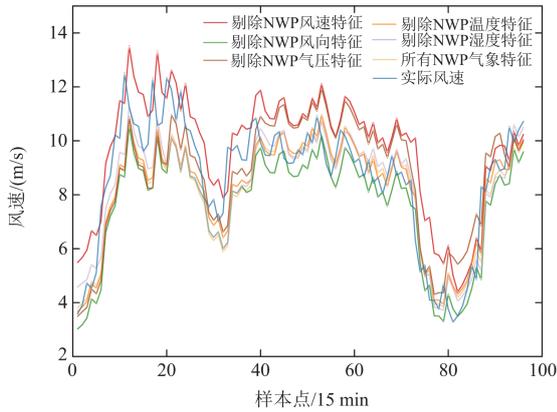


图 4 NWP 多气象特征缺失影响图

Fig. 4 Impact of eliminating NWP multi-meteorological features

表 3 缺失不同气象特征模型修正指标

Table 3 Correction indicators for eliminating different meteorological feature models

	MAE/(m/s)	RMSE/(m/s)	MAPE/%	$r$
不考虑风速	1.32	1.50	14.61	0.86
不考虑风向	1.06	1.29	13.12	0.87
不考虑温度	0.88	1.18	11.45	0.88
不考虑湿度	0.87	1.17	11.53	0.88
不考虑气压	0.90	1.22	12.56	0.89
所有气象特征	0.93	1.25	12.44	0.87
NWP 原始数据	3.66	4.72	89.69	0.10

### 3 计及 NWP 风速横纵向误差特性的 RDPG 风速修正模型构建

RDPG 属于基于策略梯度的 DRL 算法, 通过计算梯度来更新策略网络中的参数, 使得整个策略网络朝着奖励增高的方向更新<sup>[31]</sup>。本文首先定义状态值函数  $V^\pi(s)$  和状态动作值函数  $Q^\pi(s, a)$ , 如式(6)、式(7)所示。

$$V^\pi(s) = \sum_{k=0}^{\infty} \gamma^k r_{t+k} | s_t = s \quad (6)$$

$$Q^\pi(s, a) = \sum_{k=0}^{\infty} \gamma^k r_{t+k} | s_t = s, a_t = a \quad (7)$$

式中:  $V^\pi(s)$  表示从某个状态  $s$  开始执行策略  $\pi$  的累积折扣奖赏;  $Q^\pi(s, a)$  表示在某个状态  $s$  执行动作  $a$  并在后续执行策略  $\pi$  的累积折扣奖赏;  $\gamma$  为折扣因子;  $k$  为未来时间步骤;  $r_{t+k}$  表示智能体在时间步骤  $t+k$  上获得的即时奖励;  $s_t$  表示模型在时间点  $t$  的输入状态, 即 NWP 气象数据超前/滞后时序区间统计特征和历史风速;  $a_t$  表示模型在时间点  $t$  的动作行为, 即对应输出的风速值。

RDPG 采用 Actor-Critic 网络作为基础框架, 主要包括两个神经网络, 分别是 Actor 网络和 Critic 网络<sup>[32]</sup>。利用参数  $\theta$  评估当前 Actor 网络的执行策略  $\pi$ , 并根据输入状态  $s_t$ , 输出动作  $a_t$ , 环境接收智能体所选择的动作之后, 给予智能体相应的奖惩信号反馈  $r_{t+1}$ , 并转移到新的环境状态  $s_{t+1}$ , 进而输出新的动作  $a_{t+1}$ 。通过智能体与环境的交互, 将获得的转换变量  $(s_t, a_t, s_{t+1}, a_{t+1}, r_{t+1})$  输入到 Critic 网络。然后根据时序差分法(temporal difference, TD)计算出损失函数 TD\_error。TD\_error 用  $\delta$  表示。

$$\delta = r_{t+1} + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t) \quad (8)$$

式中,  $Q(s_t, a_t)$  表示模型在时间点  $t$  输入状态为  $s_t$ 、输出动作为  $a_t$ 。

本文所构建的 NWP 风速修正模型框架如图 5 所示。RDPG 中 Actor 及 Critic 网络均采用双网络结构, 包含结构相同的估值网络  $(\hat{\mu}, \hat{Q})$  和目标网络  $(\mu, Q)$ 。

$$\text{Actor} \supset \{ \mu(s | \theta^\mu), \hat{\mu}(s | \theta^\mu) \} \quad (9)$$

$$\text{Critic} \supset \{ Q(s, a | w^Q), \hat{Q}(s, a | w^Q) \} \quad (10)$$

式中,  $\theta$  和  $w$  分别表示不同的网络参数。

RDPG 具有经验回放机制。通过构造一个经验池, 在 Agent 学习前, 首先将状态转换过程储存在经验池中; 在学习时, 从经验池中随机采样。然后

在连续动作空间中基于式(11)进行探索, 以构建经验回放缓冲池  $R$ 。

$$a_t = \mu(s_t | \theta^\mu) + \xi_t \quad (11)$$

式中,  $\xi_t$  为噪声, 用于随机搜索动作。  $R$  由  $\left\{ a_t, s_t, r_t, \left[ s_t \rightarrow s_{t+1} \right] \mid t=1, \dots, T-1 \right\}, i \in \lambda$  构成,  $\lambda$  为 RDPG 的训练步数。

基于式(7)和式(8), 采用蒙特卡洛模拟建立  $Q$  网络和  $\mu$  网络的学习策略, 如式(12)和式(13)所示, 以  $R$  中随机抽取的 mini-batch 作为输入, 即可训练目

标网络  $(\mu, Q)$ 。

$$\min_{w^Q} L(Q) = \frac{1}{N} \sum_i (r_i + \gamma \hat{Q}(s_{i+1}, \hat{\mu}(s_{i+1} | \theta^\mu)) | w^Q) - Q(s_i, a_i | w^Q)^2 \quad (12)$$

$$\nabla_{\theta^\mu} \mu \approx \frac{1}{N} \sum_i \nabla_a Q(s, a | w^Q) \Big|_{\substack{s=s_i \\ a=\mu(s_i | \theta^\mu)}} \nabla_{\theta^\mu} \mu(s_i | \theta^\mu) \quad (13)$$

式中:  $\nabla$  为哈密顿算子;  $\nabla_{\theta^\mu} \mu$  表示参数为  $\theta^\mu$  的  $\mu$  网络的梯度;  $\{a_i, s_i, r_i, s_{i+1}\} \subset R$ 。

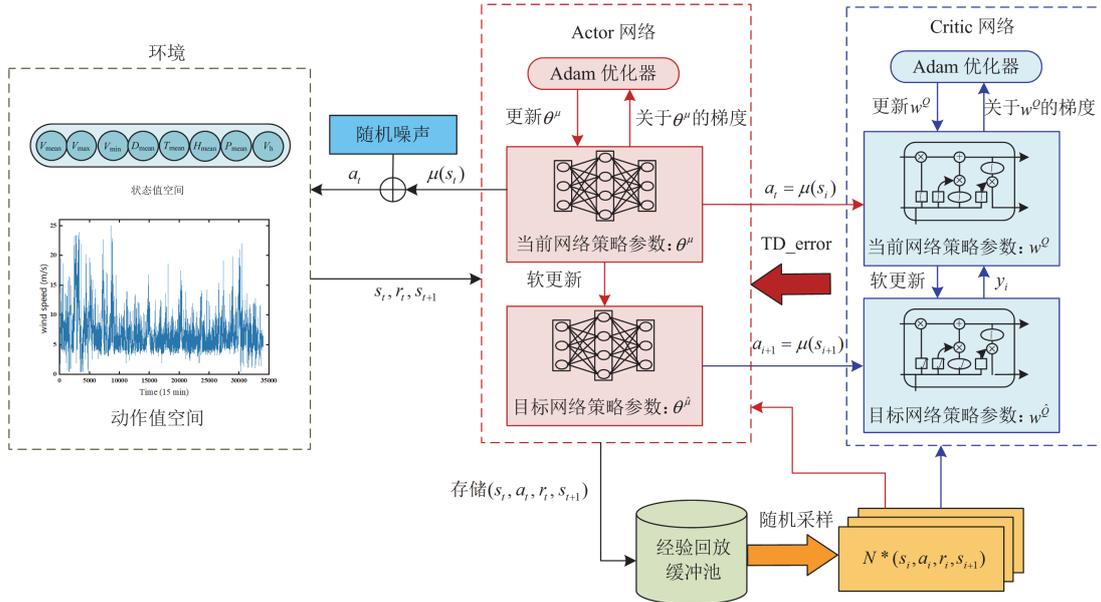


图5 基于 RDPG 的 NWP 风速修正模型框架

Fig. 5 NWP wind speed correction model framework based on RDPG algorithm

目标网络的参数通过缓慢跟踪原始网络进行更新。这种“软”更新策略可以约束快速变化的目标网络, 使训练过程稳定。

$$\begin{cases} \theta^{\hat{\mu}} = \tau \theta^\mu + (1 - \tau) \theta^{\hat{\mu}} \\ w^{\hat{Q}} = \tau w^Q + (1 - \tau) w^{\hat{Q}} \end{cases} \quad (14)$$

式中,  $\tau$  为目标网络参数的学习率。

本文中, 奖励函数  $r_{t+1}$  的定义为

$$r_{t+1} = -|v_t - a_t| \quad (15)$$

式中,  $v_t$  表示时间点  $t$  的实际风速值。如果输出的动作值, 即修正的 NWP 风速接近实际的风速, 则奖励接近 0, 否则远离 0 值的负方向。

通过式(10)一式(15)可以得到训练完整的 RDPG 网络。RDPG 中的状态由所提取  $s_t$  的气象特征表示, 即以 NWP 气象数据超前/滞后时段区间统计特征和历史风速  $V_h$  的输入作为状态, 动作由每个

预测时间点的实际风速构成。在模型训练过程中, 模型根据观察到的状态从动作空间中输出相应的风速值, 通过设置奖励函数判断模型输出是否准确。

本文所提出的 NWP 风速修正流程如图 6 所示。

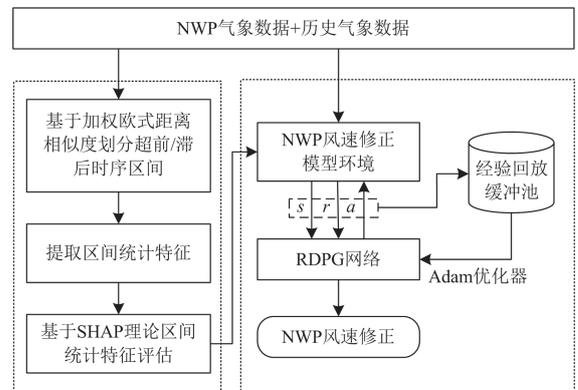


图6 NWP 风速修正流程

Fig. 6 NWP wind speed correction process

首先, 考虑 NWP 气象数据与历史气象数据, 基于加权欧式距离相似度确定各个 NWP 风速待修正点超前和滞后时序区间边界, 划分最优超前/滞后时序区间, 量化不同 NWP 风速预测点横纵向误差偏移程度; 然后, 提取超前/滞后时序区间统计特征代替 NWP 原始时序气象特征, 通过确定各个 NWP 风速待修正点的超前/滞后时序区间边界, 划分最优超前/滞后时序区间, 并基于 SHAP 理论评估不同区间统计特征对模型输出效果的影响程度; 最后, 建立基于循环确定性策略梯度的 NWP 风速修正模型, 提高 NWP 风速修正精度, 确保 NWP 风速数据应用质量, 降低 NWP 风速误差对风电功率预测模型的不利影响, 进一步提升风电功率预测模型精度。

#### 4 算例分析

本文利用位于内蒙古克旗风电场(117.510593°N, 43.139382°E)的 2019 年数据集进行算例分析, 该数据集由场站实测的历史风速、风向以及相应的 NWP 数据构成, 时间分辨率为 15 min。其中, NWP 数据包括该风电场的风速、风向、温度、湿度和气压等气象数据<sup>[33]</sup>。考虑到风速具有季节性变化规律, 本文随机使用各个季节 30 天的数据作为模型的测试数据集, 4 个季节剩余天数的数据作为训练集。

本文选定的横纵向误差指标如表 4 所示。纵向误差评估指标包括平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)。横向误差的指标为相关系数(correlation coefficient) $r$ , 相关系数  $r$  可以对比实测序列和预测序列之间的相似程度, 间接判断预测横向误差的

大小。其中:  $N$  为样本总数;  $x_i$  为第  $i$  个样本点的修正风速;  $y_i$  为第  $i$  个样本点的 NWP 风速;  $\bar{x}_i$  为修正风速的平均值;  $\bar{y}_i$  为 NWP 风速的平均值。

表 4 评估指标

Table 4 Evaluation indicators		指标	公式
纵向误差	MAE		$M_{AE} = \frac{1}{N} \sum_{i=1}^N  x_i - y_i $
	RMSE		$R_{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2}$
	MAPE		$M_{APE} = \frac{1}{N} \sum_{i=1}^N \left  \frac{y_i - x_i}{x_i} \right  \times 100\%$
横向误差	$r$		$r = \frac{\sum_{i=1}^N ((x_i - \bar{x}_i)(y_i - \bar{y}_i))}{\sqrt{\sum_{i=1}^N (x_i - \bar{x}_i)^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y}_i)^2}}$

#### 4.1 NWP 风速预测点的超前/滞后时序区间分布规律分析

本文选取的 NWP 风速待修正点为  $d_0$ , 其中, 超前  $d_0$  的 NWP 气象参数特征向量  $X_q = [d_t, t = 1, \dots, 96]$ , 滞后  $d_0$  的 NWP 气象参数特征向量序列可以表示为  $X_h = [d_t, t = -1, \dots, -96]$ , 其中  $t$  表示超前或滞后  $d_0$  的区间样本点, 负号表示区间样本点滞后  $d_0$ , 则本文选取的 NWP 风速待修正点为  $d_0$ , 基本时序区间范围为  $[d_{t-96}, d_{t+96}]$ , 且包含  $d_0$ 。然后基于加权欧式距离的方法, 计算该基本时序区间内各点与  $d_0$  之间的加权欧式距离相似度, 设置样本最优时序区间边界点阈值  $D_0$  为 0.8, 确定其各样本点强相关时序区间, 各样本点超前/滞后时序区间分布情况如图 7 所示。

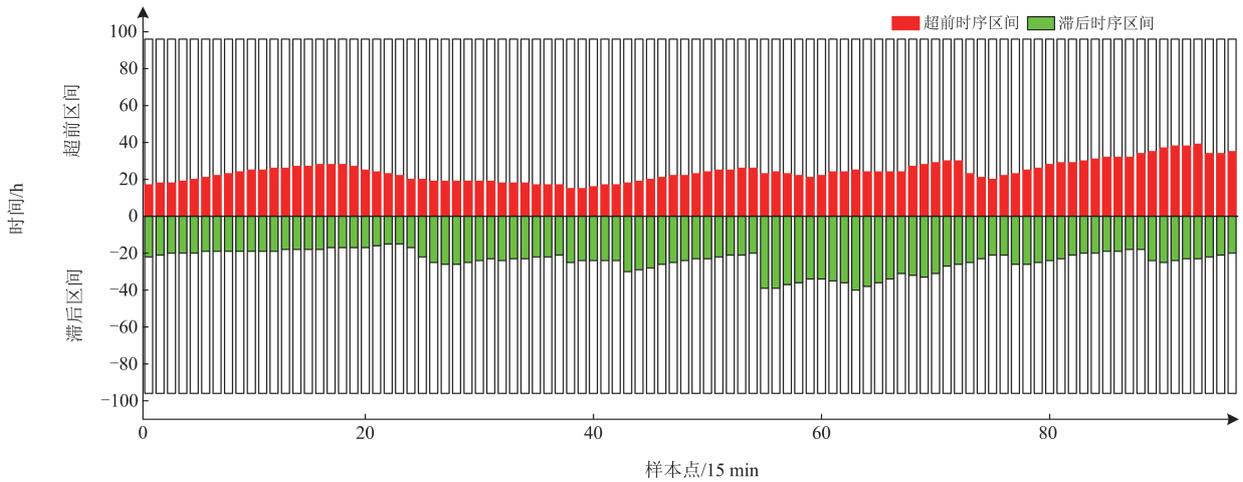


图 7 各样本点超前/滞后时序区间分布情况

Fig. 7 Optimal LLTI distribution of each sample point

由图 7 可知, 各个样本点的最优超前/滞后时序区间分布范围具有差异化特性。其中, 最优超前/滞后时序区间的最大范围为 $[d_{t-40}, d_{t+25}]$ , 最小范围为 $[d_{t-17}, d_{t+20}]$ , 两者之间相差 6 h 左右的时序区间间隔。因此, 有必要确定不同 NWP 风速待修正点的最优超前/滞后时序相关区间, 进而提取各点的 NWP 数据区间特征。

#### 4.2 横向误差对风速修正效果的影响分析

为了验证横向误差对风速修正效果的影响, 本文将考虑超前/滞后区间的 SVM、LSTM、DDPG、RDPG 模型与未考虑超前/滞后区间的 SVM、LSTM、DDPG、RDPG 模型进行风速修正效果对比, 实验选取 12 月 12 日作为典型日进行结果展示, 实验结果如图 8 所示。表 5 为各模型在考虑超前/滞后区间与未考虑超前/滞后区间时的 NWP 风速修正指标情况。

由表 5 可以看出, 横向误差对 NWP 风速修正存在一定的影响, 在考虑超前/滞后区间后, 各模型风速修正精度均有不同程度的提高。LLTI-RDPG 相较于未考虑超前/滞后区间的 RDPG 模型, MAE 降低了 0.17 m/s、RMSE 降低了 0.2 m/s、MAPE 降低了 1.52%、 $r$  提高了 0.03。由此可见, 不宜忽略横向误差对风速预测精度的影响, 考虑超前/滞后区间能有效提高模型修正精度。因此有必要考虑 NWP 风速

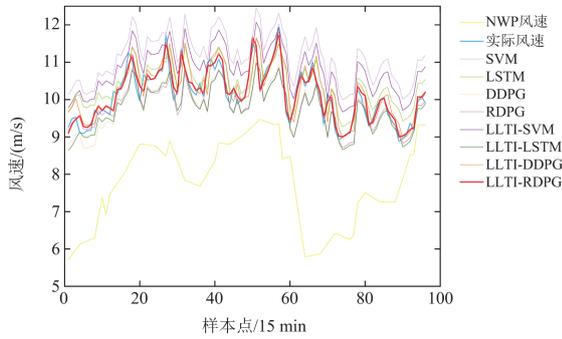


图 8 不同模型的 NWP 风速修正结果

Fig. 8 NWP wind speed correction results of different models

表 5 不同模型的 NWP 风速修正指标

Table 5 Different models' NWP wind speed correction indicators

实验方法	MAE/(m/s)	RMSE/(m/s)	MAPE/%	$r$
NWP	2.51	2.89	84.03	0.61
SVM	1.44	1.77	9.51	0.73
LSTM	1.07	1.47	8.19	0.79
DDPG	0.65	0.83	7.74	0.85
RDPG	0.49	0.68	6.53	0.88
LLTI-SVM	1.28	1.50	8.57	0.77
LLTI-LSTM	0.94	1.33	7.90	0.83
LLTI-DDPG	0.46	0.62	6.55	0.88
LLTI-RDPG	0.32	0.48	5.01	0.91

序列的时序效应, 采用超前/滞后区间共同构成模型输入特征, 建立 NWP 风速时序区间与 NWP 风速待修正点间的映射关系。

#### 4.3 差异化时序区间范围影响分析

为了验证差异化时序区间范围对 NWP 风速修正效果的影响, 本文考虑区间一致和区间不一致两种时序区间形式。区间一致是指每个样本提取 NWP 气象数据特征时所考虑的超前/滞后时序区间时间范围相同; 区间不一致是指根据每个样本点的气象特征向量, 针对性构建每个样本点的最优时序区间。本文选定 5 种时序区间一致的区间范围进行实验, 分别是 10%时序区间范围、20%时序区间范围、30%时序区间范围、40%时序区间范围和 50%时序区间范围。

从表 6 可以看出, 选择不同的时序区间对 NWP 风速修正存在一定的影响。其中, 本文采用的基于加权欧式距离确定各个样本点最优时序区间的方法, 模型修正 NWP 风速的效果最好, MAE、RMSE、MAPE、 $r$  分别为 0.75 m/s、1.02 m/s、9.86%和 0.90。由此可见, 考虑不同样本点间的互异性, 确定相应差异化时序区间进行特征提取, 能够有效提升 NWP 风速修正模型的预测精度。

表 6 差异化时序区间范围模型修正效果

Table 6 Correction effect of the differential time series interval range model

超前/滞后时序区间范围	MAE/(m/s)	RMSE/(m/s)	MAPE/%	$r$
超前/滞后时序区间范围	1.20	1.50	17.82	0.90
超前/滞后时序区间范围	1.00	1.38	14.05	0.84
一致	0.99	1.30	13.54	0.90
一致	1.39	1.67	21.84	0.89
一致	0.92	1.21	12.04	0.89
本文方法	0.75	1.02	9.86	0.90

#### 4.4 不同季节 NWP 风速横纵向误差修正效果分析

考虑到风速大小以及波动特性对 NWP 风速修正模型的潜在影响, 本文选择各个季节的典型日作为结果展示, 如春季 2 月 18 日、夏季 5 月 26 日、秋季 8 月 10 日和冬季 11 月 5 日, 并对比分析考虑超前/滞后时序区间与只考虑超前时序区间范围的 NWP 风速修正效果。各个季节典型日 NWP 风速修正的结果如图 9 所示。由图 9 可知, 各个季节的风速并不是处于较为平稳的状态, 均有一定波动。其中, 春季的风速波动范围以及幅值区间最大, 导致风速修正的误差也最大, 其次分别是冬季和秋季, 夏季的风速相对较小, 风速修正的误差值也相应的小于其他季节。

表 7 为不同季节所选测试集的 NWP 风速修正指

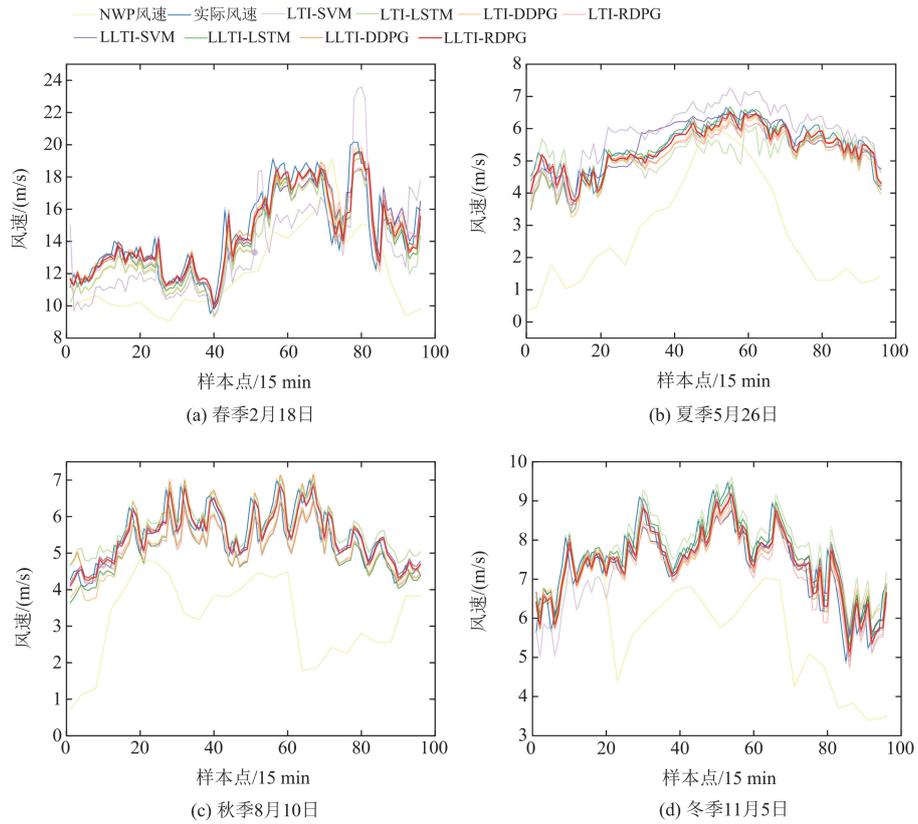


图 9 各个季节不同模型的 NWP 风速修正结果

Fig. 9 NWP wind speed correction results of different models in each season

表 7 各个季节测试集下不同模型修正指标

Table 7 Different model correction indicators under test sets in each season

季节	方法	MAE(m/s)		RMSE(m/s)		$r$		MAPE/%	
		超前/滞后 时序区间 (LLTI)	只考虑超 前时序区 间(LTI)	超前/滞后 时序区间 (LLTI)	只考虑超 前时序区 间(LTI)	超前/滞后 时序区间 (LLTI)	只考虑超 前时序区 间(LTI)	超前/滞后 时序区间 (LLTI)	只考虑超 前时序区 间(LTI)
春季	NWP	2.89		3.21		0.69		24.65	
	SVM	1.05	1.91	1.41	2.24	0.85	0.78	7.07	12.74
	LSTM	0.96	1.23	1.30	1.54	0.87	0.87	6.84	8.33
	DDPG	0.92	1.09	1.28	1.41	0.88	0.88	6.26	7.43
	RDGP	0.89	0.99	1.24	1.35	0.89	0.87	6.24	6.73
夏季	NWP	2.46		2.78		0.69		146.59	
	SVM	0.34	0.56	0.41	0.63	0.84	0.87	6.39	10.59
	LSTM	0.29	0.35	0.38	0.46	0.88	0.71	5.95	8.61
	DDPG	0.26	0.34	0.33	0.43	0.89	0.89	4.98	6.50
	RDGP	0.25	0.33	0.32	0.39	0.90	0.89	4.96	6.10
秋季	NWP	2.17		2.43		0.75		93.73	
	SVM	0.35	0.44	0.43	0.52	0.83	0.82	6.18	8.47
	LSTM	0.43	0.69	0.55	0.90	0.83	0.93	8.52	10.13
	DDPG	0.37	0.42	0.46	0.53	0.82	0.83	6.54	7.47
	RDGP	0.33	0.40	0.42	0.53	0.84	0.82	6.01	6.89
冬季	NWP	1.71		1.99		0.51		34.07	
	SVM	0.41	0.51	0.52	0.63	0.86	0.83	5.78	7.37
	LSTM	0.42	0.48	0.54	0.62	0.85	0.84	5.64	6.73
	DDPG	0.41	0.44	0.52	0.51	0.86	0.82	5.62	8.47
	RDGP	0.39	0.43	0.51	0.55	0.87	0.86	5.61	6.03

标情况, 本文随机选择各个季节 30 天的数据作为模型的测试数据集。以春季为例, LLTI-RDPG 模型的 MAE、RMSE、MAPE、相关系数  $r$  分别为 0.89 m/s、1.24 m/s、6.24% 和 0.89, 通过比较两种时序区间范围下不同模型的 NWP 风速修正效果可知, 采用本文提出的超前/滞后时序区间作为模型特征提取区间, 能有效改善模型的预测精度。同时相比于 NWP 原始数据, 基于 LLTI-RDPG 模型的 MAE 降低了 2 m/s、RMSE 降低了 1.97 m/s、MAPE 降低了 18.41%、相关系数  $r$  提高了 0.2。由此可见, 本文方法可以有效降低 NWP 预测风速的横向和纵向误差, 验证了所提模型进行 NWP 风速修正的有效性。

#### 4.5 不同预测时长下 NWP 风速横纵向误差修正效果分析

本文采用滚动修正的方式对 NWP 风速进行修正, 比较不同预测时长下模型的修正效果, 如图 10 所示。由于采用滚动修正的模式, NWP 风速修正的误差随着预测时长的增加而累积, MAE、RMSE 在 8 h 之前显著增加, 但是在 8 h 之后, MAE、RMSE 基本保持不变。因此, 本文提出的方法可以应用于超短期和短期时间尺度下的 NWP 风速修正。在日内 24 h 的预测时长下, 本文所用 NWP 风速修正模型的 MAE 在 0.8 m/s 左右波动, RMSE 在 1.0 m/s 左右波动。当修正的时间范围变小时, 所提出的算法具有更好的性能。

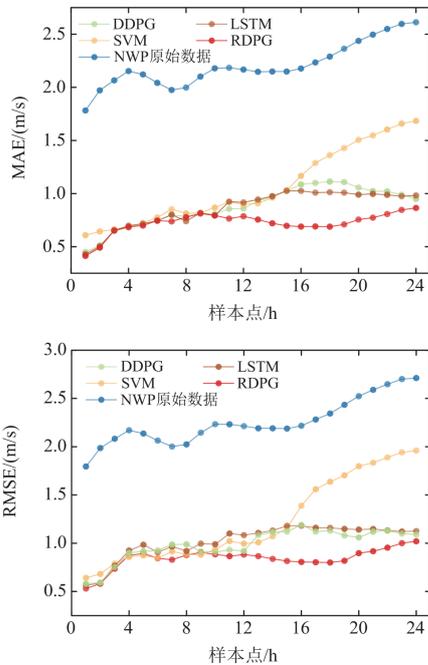


图 10 不同时间尺度下 NWP 风速修正误差的比较  
Fig. 10 Comparison of NWP wind speed correction errors under different time scale

表 8 为不同预测时长下模型修正 NWP 风速指标的情况, 本文选取了 1 h、4 h、12 h 和 24 h 对模型的修正结果进行比较。在预测时长为 1 h 时, 本文 RDPG 算法的 MAE 为 0.41 m/s、RMSE 为 0.53 m/s、MAPE 为 9.35%、相关系数  $r$  为 0.93, 相比于原始 NWP 风速预测精度, RDPG 的修正精度显著提高, 同时与 SVM、BPNN、LSTM 三种基准算法相比, RDPG 的修正效果均有一定程度的提高。随着预测时长的增加, 在时间尺度为 4 h、12 h 以及 24 h 时, 基于 RDPG 的 NWP 风速修正精度的表现更加稳定。

表 8 不同预测时长下模型修正 NWP 风速指标

Table 8 Model-corrected NWP wind speed indices under different forecast durations

时间	方法	MAE/(m/s)	RMSE/(m/s)	$r$	MAPE/%
1 h	NWP	1.78	1.80	0.63	85.5
	SVM	0.61	0.64	0.68	15.7
	LSTM	0.43	0.56	0.90	9.56
	DDPG	0.45	0.58	0.89	9.61
	RDPG	0.41	0.53	0.93	9.35
4 h	NWP	2.15	2.17	0.41	99.4
	SVM	0.69	0.92	0.65	18.5
	LSTM	0.70	0.92	0.67	18.2
	DDPG	0.68	0.90	0.69	18.1
	RDPG	0.68	0.87	0.85	17.7
12 h	NWP	2.17	2.21	0.38	100.1
	SVM	0.90	1.00	0.55	20.5
	LSTM	0.92	1.08	0.53	20.8
	DDPG	0.86	0.92	0.65	19.9
	RDPG	0.79	0.88	0.82	19.6
24 h	NWP	2.61	2.71	0.62	88.2
	SVM	1.68	1.96	0.68	30.3
	LSTM	0.98	1.13	0.74	24.4
	DDPG	0.95	1.09	0.77	23.1
	RDPG	0.87	1.02	0.80	21.3

## 5 结论

为降低 NWP 风速误差对风电功率预测精度的不利影响, 保证高比例风电接入后电力系统运行的安全性和稳定性。本文提出了计及 NWP 风速双向误差特性的 RDPG 风速修正模型, 通过本文研究可以得出以下结论:

1) 基于加权欧式距离相似度, 划分各个 NWP 风速待修正点差异化最优超前/滞后时序相关区间, 反映了横向误差对 NWP 风速修正的潜在影响, 有效改善模型的预测效果。

2) 采用区间统计特征代替 NWP 原始气象特征

作为模型输入,并基于 SHAP 理论实现非一致性时序区间 NWP 气象特征评估,获取对模型具有正向增益的特征,降低了模型的复杂度。

3) 基于 RDPG 的 NWP 风速修正模型,降低了不同 NWP 风速波动水平下预测风速的横纵向误差,增强了模型的泛化能力和处理非线性数据的能力。

经研究表明,循环确定性策略梯度在风速修正领域具有较大的应用潜力,在未来的工作中,可以进一步考虑将其应用到风电功率预测中。

## 参考文献

- [1] 胡宇晗,朱利鹏,李佳勇,等.融合深度误差反馈学习和注意力机制的短期风电功率预测[J].电力系统保护与控制,2024,52(4):100-108.  
HU Yuhan, ZHU Lipeng, LI Jiayong, et al. Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism[J]. Power System Protection and Control, 2024, 52(4): 100-108.
- [2] 朱显辉,于越,师楠,等.BP神经网络的分层优化研究及其在风电功率预测中的应用[J].高压电器,2022,58(2):158-163.  
ZHU Xianhui, YU Yue, SHI Nan, et al. Research on hierarchical optimization of BP neural network and its application in wind power prediction[J]. High Voltage Apparatus, 2022, 58(2): 158-163.
- [3] 江友华,屈靖洁,曹以龙,等.考虑风电-负荷及综合需求响应不确定性的能量枢纽双层优化运行及配置方法[J].电测与仪表,2022,59(3):117-124,162.  
JIANG Youhua, QU Jingjie, CAO Yilong, et al. Double-layer optimal operation and configuration method for energy hub considering uncertainty of wind power-load and integrated demand response[J]. Electrical Measurement & Instrumentation, 2022, 59(3): 117-124, 162.
- [4] 杜刚,赵冬梅,刘鑫.计及风电不确定性优化调度研究综述[J].中国电机工程学报,2023,43(7):2608-2627.  
DU Gang, ZHAO Dongmei, LIU Xin. Research review on optimal scheduling considering wind power uncertainty[J]. Proceedings of the CSEE, 2023, 43(7): 2608-2627.
- [5] 刘刚,王秀茹,李华,等.考虑风电不确定性的配电网区间潮流计算[J].电测与仪表,2022,59(2):126-132.  
LIU Gang, WANG Xiuru, LI Hua, et al. Interval power flow calculation for distribution networks considering the uncertainty of wind power[J]. Electrical Measurement & Instrumentation, 2022, 59(2): 126-132.
- [6] 刘新宇,蒲欣雨,李继方,等.基于贝叶斯优化的 VMD-GRU 短期风电功率预测[J].电力系统保护与控制,2023,51(21):158-165.  
LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. Power System Protection and Control, 2023, 51(21): 158-165.
- [7] 翟保豫,张龙,徐志,等.基于 WRF 模式和风速误差修正的中期风电功率预测方法[J].智慧电力,2023,51(7):31-38.  
ZHAI Baoyu, ZHANG Long, XU Zhi, et al. Mid-term wind power forecasting based on WRF mode and wind speed error correction[J]. Smart Power, 2023, 51(7): 31-38.
- [8] 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 Energetica Solaris Sinica, 2022, 43(12): 273-281.
- [9] 赵永宁,李卓,叶林,等.基于时空相关性的风电功率超短期自适应预测方法[J].电力系统保护与控制,2023,51(6):94-105.  
ZHAO Yongning, LI Zhuo, YE Lin, et al. A very short-term adaptive wind power forecasting method based on spatio-temporal correlation[J]. Power System Protection and Control, 2023, 51(6): 94-105.
- [10] 王勃,冯双磊,刘晓琳,等.计及转折性天气过程识别与检验的短期风电功率预测[J].南方电网技术,2023,17(12):52-62.  
WANG Bo, FENG Shuanglei, LIU Xiaolin, et al. Short-term wind power prediction considering identification and testing of transitional weather processes[J]. Southern Power System Technology, 2023, 17(12): 52-62.
- [11] ZHANG Yu, LI Yanting, ZHANG Guangyao. Short-term wind power forecasting approach based on Seq2Seq model using NWP data[J]. Energy, 2020, 213.
- [12] LU Peng, YE Lin, ZHAO Yongning, et al. Feature extraction of meteorological factors for wind power prediction based on variable weight combined method[J]. Renewable Energy, 2021, 179: 1925-1939.
- [13] 李嘉文,盛德仁,李蔚,等.基于多目标优化和误差修正的短期风速预测[J].太阳能学报,2022,43(8):273-280.  
LI Jiawen, SHENG Deren, LI Wei, et al. Short-term wind speed prediction based on multi-objective optimization and error correction[J]. Acta Energetica Solaris Sinica, 2022, 43(8): 273-280.
- [14] LU Peng, YU Lin, ZHAO Yongning, et al. Review of meta-heuristic algorithms for wind power prediction: methodologies, applications and challenges[J]. Applied Energy, 2021, 301.
- [15] AN Jianqi, YIN Feng, WU Min, et al. Multi-source wind

- speed fusion method for short-term wind power prediction[J]. IEEE Transactions on Industrial Informatics, 2021, 17(9): 5927-5937.
- [16] HU Shuai, XIANG Yue, HUO Da, et al. An improved deep belief network based hybrid forecasting method for wind power[J]. Energy, 2021, 224.
- [17] DING Min, ZHOU Hao, XIE Hua, et al. A gated recurrent unit neural networks based wind speed error correction model for short-term wind power forecasting[J]. Neurocomputing, 2019, 365: 54-61.
- [18] 魏翔宇, 向月, 沈晓东, 等. 考虑台风影响的风速多步预测模型[J]. 电力系统自动化, 2021, 45(14): 30-37.  
WEI Xiangyu, XIANG Yue, SHEN Xiaodong, et al. Multi-step forecasting model of wind speed considering influence of typhoon[J]. Automation of Electric Power Systems, 2021, 45(14): 30-37.
- [19] 王斌, 魏成伟, 谢丽蓉, 等. 基于风速误差校正和 ALO-LSSVM 的风电功率预测[J]. 太阳能学报, 2022, 43(1): 58-63.  
WANG Bin, WEI Chengwei, XIE Lirong, et al. Wind power forecasting based on wind speed error correction and ALO-LSSVM[J]. Acta Energetica Solaris Sinica, 2022, 43(1): 58-63.
- [20] 刘晓楠, 周介圭, 贾宏杰, 等. 基于非参数核密度估计与数值天气预报的风速预测修正方法[J]. 电力自动化设备, 2017, 37(10): 15-20.  
LIU Xiaonan, ZHOU Jiegui, JIA Hongjie, et al. Correction method of wind speed prediction based on non-parametric kernel density estimation and numerical weather prediction[J]. Electric Power Automation Equipment, 2017, 37(10): 15-20.
- [21] JEONG J, KIM H. DeepComp: deep reinforcement learning based renewable energy error compensable forecasting[J]. Applied Energy, 2021, 294.
- [22] ZHANG Wenyu, CHEN Qian, YAN Jianyong, et al. A novel asynchronous deep reinforcement learning model with adaptive early forecasting method and reward incentive mechanism for short-term load forecasting[J]. Energy, 2021, 236.
- [23] LIU Hui, YU Chengqing, WU Haiping, et al. A new hybrid ensemble deep reinforcement learning model for wind speed short term forecasting[J]. Energy, 2020, 202: 117794.
- [24] LILLICRAP T P, HUNT J J, PRITZEL A, et al. Continuous control with deep reinforcement learning[J]. arXiv.1509.02971, 2015.
- [25] 杨茂, 张书天, 王勃. 基于因果正则化极限学习机的风电功率短期预测方法[J]. 电力系统保护与控制, 2024, 52(11): 127-136.  
YANG Mao, ZHANG Shutian, WANG Bo. Short-term wind power forecasting method based on a causal regularized extreme learning machine[J]. Power System Protection and Control, 2024, 52(11): 127-136.
- [26] PENG Xiaosheng, CHEN Yuzhu, CHENG Kai, et al. Wind power prediction for wind farm clusters based on the multi-feature similarity matching method[C]// 2019 IEEE Industry Applications Society Annual Meeting, September 29-October 3, 2019, Baltimore, MD, USA.
- [27] AZECEDO M C, RAMIRO R, BRIOSCHI L M, et al. Dynamic time scan forecasting for multi-step wind speed prediction[J]. Renewable Energy, 2021, 177: 584-595.
- [28] WANG Shuai, LI Bin, LI Guanzheng, et al. Short-term wind power prediction based on multidimensional data cleaning and feature reconfiguration[J]. Applied Energy, 2021, 292.
- [29] GU Xinyu, SEE KW, WANG Yunpeng, et al. The sliding window and SHAP theory-an improved system with a long short-term memory network model for state of charge prediction in electric vehicle application[J]. Energies, 2021, 14(12).
- [30] GEORGIOS M, HENDRIK L. An interpretable probabilistic model for short-term solar power forecasting using natural gradient boosting[J]. Applied Energy, 2022, 309.
- [31] LIU Boming, AKCAKAYA M, MCDERMOTT T E. Automated control of transactive HVACs in energy distribution systems[J]. IEEE Transactions on Smart Grid, 2021, 12(3): 2462-2471.
- [32] YU Zhenping, TAN Panlong, SUN Qinglin, et al. Longitudinal wind field prediction based on DDPG[J]. Neural Computing and Applications, 2021, 34(1).
- [33] 杨茂, 彭天, 苏欣. 基于预测信息二维坐标动态划分的风电集群功率超短期预测[J]. 中国电机工程学报, 2022, 42(24): 8854-8864.  
YANG Mao, PENG Tian, SU Xin. Ultra-short term wind power prediction based on two-dimensional coordinate dynamic division of prediction information[J]. Proceedings of the CSEE, 2022, 42(24): 8854-8864.

收稿日期: 2024-05-06; 修回日期: 2024-08-20

作者简介:

黄南天(1980—), 男, 通信作者, 博士, 教授, 博士生导师, 主要研究方向为含高比例可再生能源电力系统运行控制与规划等; E-mail: huangnantian@126.com

唐立鹏(1999—), 男, 硕士研究生, 主要研究方向为风电功率预测; E-mail: 897773510@qq.com

戴千斌(1998—), 男, 硕士, 主要研究方向为风电功率预测。E-mail: dqianbin@126.com

(编辑 许威)