

数据驱动的风电功率在线预测方法

何稷

广州大学 经济与统计学院, 广东 广州 510006

DOI:10.61369/ASDS.2026030010

摘要 : 随着风电装机容量的快速增长和新能源大规模并网运行, 对风电功率预测的实时性与准确性提出了更高要求, 传统离线建模方法难以适应运行环境的动态变化, 为此本文提出一种基于深度学习的风电功率在线预测方法。首先, 利用历史数据对预测模型进行批量训练, 构建初始模型; 然后引入 Wasserstein 距离度量新数据与历史数据之间的分布差异, 并据此检测数据分布是否发生变化; 当检测到显著变化时, 动态更新深度学习模型参数, 从而实现基于滚动时间窗口的在线预测。最后, 通过对两个风电场的实测数据进行仿真模拟, 实验结果表明, 所提出的方法在多种预测模型上表现出更高的预测精度与稳定性, 验证了本文所提方法的有效性。

关键词 : 风电功率预测; 动态深度学习; 在线预测

Data-Driven Online Wind Power Forecasting Method

He Ji

School of Economics and Statistics, Guangzhou University, Guangzhou, Guangdong 510006

Abstract : With the rapid growth of wind power installed capacity and the large-scale integration of renewable energy into power grids, higher requirements are imposed on the timeliness and accuracy of wind power forecasting. Traditional offline modeling methods are difficult to adapt to the dynamic changes in operating environments. Therefore, this paper proposes an online wind power forecasting method based on deep learning. First, historical data are used to perform batch training of the forecasting model to construct an initial model. Then, the Wasserstein distance is introduced to measure the distribution difference between newly arriving data and historical data, thereby detecting potential distribution changes. When significant changes are detected, the parameters of the deep learning model are dynamically updated to realize online forecasting based on a rolling time window. Finally, simulation experiments are conducted using measured data from two wind farms. The experimental results demonstrate that the proposed method achieves higher forecasting accuracy and stability across multiple prediction models, verifying the effectiveness of the proposed approach.

Keywords : wind power forecasting; dynamic deep learning; online prediction

引言

在全球能源结构持续向清洁化、低碳化方向转型的背景下, 风电作为最具发展潜力的可再生能源之一, 已成为现代电力系统的重要组成部分^[1]。然而, 风电出力受风速、气象条件及机组运行状态等多种因素影响, 具有显著的随机性、波动性和间歇性特征, 这给电力系统的安全稳定运行和调度决策带来了严峻挑战^[2]。因此, 提升对风电出力预测精度对于推动风能发展、促进新型电力系统构建具有重要意义^[3]。

现有风电功率预测方法主要包括物理建模方法、统计分析方法和数据驱动方法三类。物理建模方法通常基于风速与功率转换关系及机组运行机理构建预测模型^[4-6], 具有一定可解释性, 但对气象预测精度和设备参数依赖较强, 在复杂工况下性能易受影响。统计分析方法通过对历史时间序列进行建模实现预测, 如自回归滑动平均模型^[7]、概率预测法^[8]等。相较于物理模型, 这类方法更易建模, 但其通常基于线性假设, 难以有效刻画风电功率序列中蕴含的强非线性特征^[9-11]。相比之下, 数据驱动方法通过挖掘历史数据中的潜在规律进行建模, 在处理非线性和复杂时序关系方面具有明显优势^[12-14]。

近年来, 深度学习技术的快速发展进一步推动了风电功率预测研究。基于神经网络的预测模型, 如长短期记忆网络 (LSTM)、门控循环单元 (GRU)、Transformer 等神经网络模型在时序建模方面表现突出^[13,15], 在短期和超短期预测任务中取得了良好效果。同

时, DLinear 和 LightTS 等轻量化模型在保证预测精度的同时降低了计算复杂度^[16,17]。然而, 现有多数方法仍采用离线训练模式, 模型参数在部署后保持不变。在实际运行环境中, 由于气候条件、季节变化和和设备状态等因素的影响, 数据分布往往呈现非平稳特性, 导致离线模型预测性能逐渐下降^[18]。

针对上述问题, 本文提出一种面向风电功率预测的在线学习框架, 以提升模型在非平稳环境下的适应能力与预测精度。该方法首先利用历史数据训练初始模型, 并进行性能评估; 随后引入基于 Wasserstein 距离^[19]的数据分布漂移检测机制, 对新旧数据分布差异进行度量; 最后根据检测结果自适应地进行模型在线更新, 并结合滚动时间窗口实现持续预测。基于两个实际风电场数据集的实验结果表明, 所提出方法在多种预测模型下均能有效提升预测精度与稳定性, 验证了其方法的有效性。

一、方法

针对风电功率时间序列在实际运行过程中存在的非平稳性和分布漂移问题, 本文构建了一种基于 Wasserstein 距离的触发式在线预测框架。本节首先给出在线预测任务的形式化定义, 随后分析概念漂移现象, 并介绍分布变化检测方法及相应的模型更新策略。

(一) 问题定义

设风电场在时刻 t 的实际功率输出为 y_t , 给定长度为 T 的滑动时间窗口, 其历史观测序列表示为

$$X_t = \{y_{t-T+1}, y_{t-T+2}, \dots, y_t\}.$$

在线预测任务的目标是在数据持续到达的条件下, 构建预测模型 $f(\cdot; \theta_t)$, 并基于当前时间窗口 X_t 生成未来 H 步的预测结果:

$$\hat{Y}_t = f(X_t; \theta_t),$$

其中 $Y_t = \{y_{t+1}, y_{t+2}, \dots, y_{t+H}\}$, H 表示预测步长, 模型参数 θ_t 允许随时间动态更新。

(二) 概念漂移

传统时间序列预测方法通常隐含假设训练阶段与预测阶段的数据服从相同的概率分布, 即

$$P_{\text{train}}(X, Y) = P_{\text{test}}(X, Y).$$

然而, 在真实风电场运行过程中, 受季节变化、气候演化、设备老化及运行策略调整等因素影响, 数据的统计特性往往随时间发生变化, 表现为

$$P_t(X, Y) \neq P_{t+\Delta t}(X, Y),$$

这种数据分布随时间变化的现象被称为概念漂移^[20]。在存在概念漂移的情况下, 采用固定参数的预测模型将逐渐偏离真实数据分布, 导致预测性能下降。因此, 在线预测模型需要具备在运行过程中识别分布变化并适时调整参数的能力。

(三) 基于 Wasserstein 距离的分布变化检测方法

在在线预测场景中, 准确刻画新到数据与历史数据之间的分布差异, 是实现概念漂移检测的关键。为此, 本文采用 Wasserstein 距离作为分布变化的度量指标。设参考时间窗口内的样本构成经验分布 P , 新到数据窗口构成经验分布 Q , 其一阶 Wasserstein 距离定义为

$$W(P, Q) = \inf_{\gamma \in \Pi(P, Q)} E_{(x, y) \sim \gamma} [\|x - y\|],$$

其中 $\Pi(P, Q)$ 表示以 P 和 Q 为边缘分布的联合分布集合。在本文中, 采用固定长度的滑动窗口构建分布。设

$$D_{\text{ref}} = \{y_{t-T+1}, \dots, y_t\}, D_{\text{new}} = \{y_{t+1}, \dots, y_{t+T}\},$$

则对应的分布差异定义为

$$d_t = W(D_{\text{ref}}, D_{\text{new}}).$$

当 $d_t > \delta$ 时, 判定当前数据分布发生显著变化, 从而触发模型更新机制。其中阈值 δ 通过实验进行选取。

(四) 触发式模型更新策略与实现流程

基于上述分布变化检测方法, 本文构建了一种模型无关的触发式在线预测框架。该方法以分布漂移检测结果作为模型更新依据, 仅在检测到显著分布变化时才对模型参数进行调整, 从而在保证自适应能力的同时, 降低频繁更新带来的噪声干扰与计算开销。总算法流程框架为图 1。

1. 数据预处理与归一化

考虑到风电功率数据在不同时间段存在尺度差异, 本文在模型训练与在线预测前对数据进行标准化处理。采用单位方差归一化方法, 其形式为

$$\tilde{x} = \frac{x - \mu}{\sigma},$$

其中 μ 和 σ 分别表示样本均值和标准差。

2. 数据集划分与离线初始化

标准化后的数据集被划分为训练集、验证集和测试集, 分别表示为

$$D_{\text{train}} = \{(X_i, Y_i), i \in I_1\}, D_{\text{val}} = \{(X_i, Y_i), i \in I_2\}, D_{\text{test}} = \{(X_i, Y_i), i \in I_3\}.$$

在离线初始化阶段, 模型首先在训练集 D_{train} 上进行批量训练, 并通过随机打乱样本顺序提升泛化能力; 随后在验证集 D_{val} 上进行性能评估与参数选择, 该阶段保持时间顺序不变, 以维持时序结构完整性。最终获得初始模型参数 θ_0 , 作为在线预测阶段的基准模型。

3. 在线预测与分布检测机制

在在线阶段, 将验证集与测试集合并构成连续数据流, 使模型逐步过渡至真实在线环境。在每一时刻 t , 模型根据当前参数

θ_t 和历史序列 X_t 生成预测结果:

$$\hat{Y}_t = f(X_t; \theta_t).$$

当新的真实观测值到达后, 构建参考窗口 D_{ref} 和新数据窗口 D_{new} , 并计算对应的分布距离 d_t , 用于评估当前数据分布与历史分布之间的差异程度。

4. 触发式模型更新策略

当分布距离满足 $d_t \leq \delta$, 认为当前数据分布未发生显著变化, 已有模型参数仍然适用于当前预测任务, 此时模型参数保持不变。当 $d_t > \delta$, 则判定发生概念漂移, 触发模型更新机制。此时, 模型利用最新时间窗口内的数据进行微调:

$$X_t^{window} = \{y_{t-T-H+1}, y_{t-T-H+2}, \dots, y_{t-H}\}$$

$$Y_t^{window} = \{y_{t-H+1}, y_{t-H+2}, \dots, y_t\}$$

基于上述样本对模型参数进行有限轮数的增量训练, 得到更新后的参数 θ_{t+1} , 并将当前数据窗口作为新的参考分布用于后续检测。该更新方式能够充分利用历史观测信息, 同时避免引入未来数据, 从而有效防止信息泄露问题的发生。

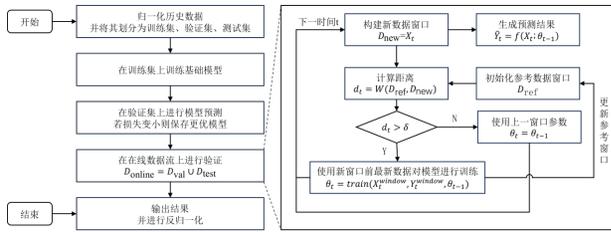


图1: 数据驱动的风电功率在线预测流程图

Figure 1: Data-driven online wind power forecasting flowchart

二、实验设计

为验证所提在线风电功率预测方法的有效性, 本文选取中国风电场 SCADA 数据集 (DatasetA)^[21] 和 GEFCom2014 风电数据集 (DatasetB)^[22] 进行实验分析。其中, DatasetA 为 15 分钟采样数据 (2020 年全年), DatasetB 为 1 小时采样数据 (2012 年全年)。两者均仅使用功率序列进行建模, 数据按时间顺序划

分为训练集、验证集和测试集, 比例为 0.20:0.05:0.75。并且采用历史 24h 数据预测未来 1h、3h 和 6h 功率。同时选取多种代表性时间序列预测模型进行对比, 包括 DLinear^[16], LightTS^[17], GRU^[23], LSTM^[24], TCN^[25], iTransformer^[26], Fredformer^[27], Crossformer^[28]。所有模型在相同数据划分下进行训练与测试, 并使用平均绝对误差 (Mean Absolute Error, MAE) 与均方根误差 (Root Mean Square Error, RMSE) 作为评价指标分别评估离线预测和在线预测性能。实验基于 PyTorch 框架实现。各模型采用统一优化器与损失函数设置。在线阶段结合 Wasserstein 距离检测结果进行参数更新。主要超参数如表 2 所示, 其中 DatasetA 和 DatasetB 的批量大小分别设为 256 和 128, 其余参数采用默认配置, 其相关参数来自代码 <https://github.com/thuml/Time-Series-Library>。

表 1: 模型参数

Table 1: Model parameters

参数名称	值
离线学习率	0.0001
在线学习率	0.00001
离线 epoch	200
在线 epoch	1
网络层数	2

(一) 离线与在线预测结果对比分析

表 2 给出了 DatasetA 与 DatasetB 两个数据集上, 不同预测模型在离线预测模式 (BL) 与在线滚动预测模式 (OL) 下的性能对比结果。在该实验设置中, 在线模式仅采用滚动时间窗口进行预测, 且 Wasserstein 参数设为 0, 即模型在每一轮新数据到达后均进行更新。实验结果表明, 与离线模式相比, 在线预测模式在多数模型及不同预测步长条件下均取得了更优的预测性能, 且这一优势在中长期预测任务中表现得更为明显。这表明持续引入最新观测数据进行模型更新能够有效缓解数据分布漂移对预测性能带来的不利影响, 提升模型的动态适应能力。以 iTransformer 模型为例, 其在两种数据集上的预测结果如图 2 所示。可以观察到, 相较于离线模型, 在线模型在面对数据分布变化时能够更快完成参数调整, 预测误差波动幅度更小, 整体表现更加稳定, 体现出更强的环境适应能力。

表 2: 离线模型与在线模型在两个数据集上的测试结果

Table 2: Test results of offline and online models on two datasets

Model	DatasetA						DatasetB					
	1h		3h		6h		1h		3h		6h	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
Dlinear-BL	4.5097	8.5684	7.796	13.9643	10.9825	18.398	0.0678	0.1024	0.1064	0.1504	0.1404	0.1912
Dlinear-OL	4.3558	8.4585	7.4613	13.7774	10.5223	18.1097	0.0676	0.1012	0.1053	0.1497	0.1398	0.1906
GRU-BL	4.3695	8.3473	7.8826	13.8346	11.0097	18.3757	0.0708	0.1037	0.109	0.1524	0.141	0.1937
GRU-OL	4.1572	8.1632	7.4861	13.5576	10.7599	17.9771	0.0677	0.101	0.1042	0.1495	0.1384	0.1903
LSTM-BL	4.1337	8.2387	7.5752	13.8381	10.8707	18.1491	0.0694	0.1035	0.1093	0.1546	0.1521	0.1988
LSTM-OL	4.1082	8.113	7.5125	13.5582	10.7934	17.9801	0.0675	0.1011	0.1045	0.1498	0.1438	0.1923
TCN-BL	5.5495	9.8565	9.3561	16.0037	12.2871	20.0525	0.075	0.1072	0.1131	0.1559	0.1468	0.1926
TCN-OL	5.3824	9.6132	9.158	15.5966	11.9933	19.4748	0.0732	0.1052	0.1108	0.1539	0.1412	0.1894

iTransformer-BL	5.4461	9.7885	9.2502	15.276	12.1217	19.8306	0.0781	0.1085	0.1145	0.1551	0.1485	0.196
iTransformer-OL	4.9324	9.1534	8.465	14.8229	11.4447	19.0812	0.0705	0.1033	0.1044	0.1491	0.1384	0.1891
Fredformer-BL	4.8543	8.6204	8.0863	14.127	11.2042	18.8066	0.0709	0.1021	0.1048	0.149	0.1423	0.1897
Fredformer-OL	4.2835	8.2782	7.5871	13.7701	10.7409	18.1282	0.0679	0.1	0.1026	0.1466	0.1364	0.1859
Crossformer-BL	6.052	10.0447	9.1077	15.6898	12.2496	19.3787	0.0711	0.1046	0.1125	0.1557	0.1474	0.1952
Crossformer-OL	4.4764	8.5386	7.95	14.2132	10.8937	18.1725	0.0679	0.0998	0.1022	0.1453	0.1356	0.1846
LightTS-BL	4.4954	8.4956	7.7233	13.9698	11.0889	18.6188	0.0659	0.0992	0.1027	0.1478	0.1406	0.1899
LightTS-OL	4.3412	8.4355	7.5936	13.8355	10.8548	18.4085	0.0658	0.0985	0.1024	0.1473	0.1385	0.189

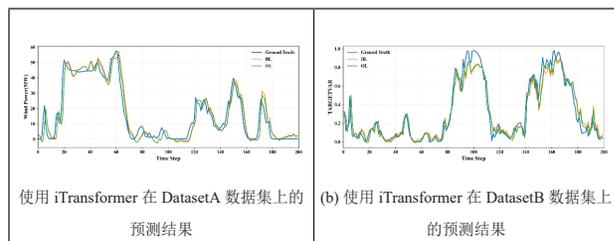


图2: 使用 iTransformer 在两个数据集上的预测时间为 1h 的预测结果图

Figure 2: Prediction results using iTransformer with a 1-hour forecast horizon on Two datasets

(二) Wasserstein 阈值参数分析

为分析 Wasserstein 距离阈值对在线更新参与率 (Participation

Ratio, PA) 及预测性能的影响, 本文在在线批量大小均设为 16 的条件下进行了对比实验。结合表 3 与表 4 的结果可以发现, 阈值参数与模型更新参与率呈现明显的负相关关系。较小的阈值能够提高模型更新频率, 使其更快适应数据分布变化, 从而提升预测精度; 而较大的阈值则有助于降低计算开销, 但会削弱模型的动态适应能力。从不同数据集的实验结果来看, 在 Dataset A 上, 较小阈值设置能够获得更优的预测性能; 而在 Dataset B 上, 阈值变化对预测精度的影响相对有限, 表明其数据分布较为稳定。总体表明合理设置 Wasserstein 距离阈值, 有助于在预测性能与计算成本之间实现有效平衡。

表 3: 不同阈值下使用 DLinear 模型在 Dataset A 上的在线预测结果

Table 3: Online prediction results using the DLinear model on Dataset A under different thresholds

Dataset A									
δ	1h			3h			6h		
	MAE	RMSE	PA	MAE	RMSE	PA	MAE	RMSE	PA
0	4.2473	8.4442	1	7.2204	13.7545	1	10.1358	18.0385	1
0.02	4.2479	8.445	0.9804	7.2207	13.7556	0.9794	10.1368	18.0373	0.9846
0.05	4.247	8.4507	0.8021	7.2197	13.775	0.7962	10.1201	18.0608	0.7941
0.07	4.2606	8.4631	0.6594	7.2239	13.7833	0.666	10.133	18.0693	0.6685
0.1	4.2697	8.4701	0.5058	7.2541	13.7929	0.5003	10.1657	18.1019	0.5029
0.2	4.2857	8.5058	0.2381	7.3288	13.843	0.2307	10.2946	18.1064	0.2397
0.3	4.3124	8.5011	0.1344	7.3766	13.8626	0.1382	10.3899	18.1268	0.1402
0.4	4.3314	8.5206	0.0839	7.4481	13.8612	0.0848	10.5034	18.1955	0.0857
0.5	4.3563	8.5231	0.0559	7.5151	13.865	0.0531	10.6254	18.2295	0.0514
0.6	4.3721	8.5443	0.0297	7.5976	13.8849	0.034	10.6595	18.2454	0.0383
0.7	4.3905	8.5474	0.0154	7.6478	13.8949	0.0211	10.7098	18.2548	0.0236

表 4: 不同阈值下使用 DLinear 模型在 Dataset B 上的在线预测结果

Table 3: Online prediction results using the DLinear model on Dataset B under different thresholds

Dataset B									
δ	1h			3h			6h		
	MAE	RMSE	PA	MAE	RMSE	PA	MAE	RMSE	PA
0	0.06745	0.10108	1	0.10408	0.14949	1	0.13871	0.19053	1
0.1	0.0674	0.10107	0.8844	0.10428	0.14942	0.8916	0.13902	0.19035	0.8877
0.2	0.06742	0.10112	0.7283	0.10438	0.14946	0.7236	0.13908	0.1903	0.7368
0.3	0.06738	0.10114	0.583	0.10474	0.14948	0.5947	0.13927	0.19031	0.5699
0.4	0.06727	0.10122	0.4695	0.10488	0.14961	0.4602	0.13936	0.19038	0.4709
0.5	0.06719	0.1013	0.3631	0.10508	0.14972	0.3495	0.13961	0.19044	0.3726
0.6	0.06717	0.10142	0.2877	0.10509	0.14974	0.3084	0.13951	0.19059	0.3132
0.7	0.0672	0.10141	0.2512	0.10503	0.14982	0.2444	0.13967	0.19068	0.2606
0.8	0.06714	0.10151	0.2169	0.10517	0.14986	0.2125	0.13975	0.19079	0.2172
0.9	0.06721	0.10166	0.1727	0.10541	0.15	0.1645	0.13975	0.19081	0.1783
1	0.06732	0.10169	0.1416	0.10554	0.1501	0.1302	0.13977	0.19081	0.1577

三、结论

本文针对风电功率时间序列随机性强、非平稳性显著及分布随时间变化等特点,提出了一种基于 Wasserstein 距离的触发式在线预测框架。该方法通过离线训练构建初始模型,并利用 Wasserstein 距离检测数据分布变化,在发生显著漂移时触发模型更新。在两个真实风电数据集上的实验结果表明,所提出方法在

不同预测步长和多种主流模型下均优于传统离线预测模式,尤其在中长期预测任务中表现更为突出。此外,该框架具有良好的模型无关性和通用性,在避免信息泄露的前提下,可利用新到数据实现模型动态优化。尽管本文方法取得了较好效果,但在没有考虑数据出现异常值情况,未来可结合异常检测策略,进一步提高模型在复杂运行环境中的鲁棒性与适用性。

参考文献

- [1] 史彭珍,魏霞,张春梅,等.基于 VMD-BOA-LSSVM-AdaBoost 的短期风电功率预测[J].太阳能学报,2024,45(1):226-233.
- [2] 夏卫平,邓艾东,薛原,等.基于 VMD 和多时间尺度分类预测的风电单机短期功率预测研究[J].太阳能学报,2025,46(12):554-563.
- [3] 赵洪山,杨铎,刘欣雨,等.基于动态深度学习的风电功率在线预测方法[J].太阳能学报,2025,46(9):171-180.
- [4] 李翠萍,张冰,李军徽,等.NWP 辅助复合神经网络预测误差修正的风储系统日前上报策略[J].太阳能学报,2024,45(10):86-96.
- [5] 杨明,李梦林,王勃,等.面向新型电力系统的数值天气预报技术及应用综述[J].电力系统自动化,2025,49(17):1-20.
- [6] 陈勇.考虑气象相似性与数值天气预报修正的海上风功率预测研究[J].电力设备管理,2025(12):150-152.
- [7] 刘吉雄,邹瑞,许思为.基于 ARIMA 的风电发电量预测[J].现代信息科技,2025,9(4):157-161,166.
- [8] 高志远,郝译,张超,等.电力市场中新能源发电概率预测的实施研究和应用展望[J/OL].电网技术,2026:1-13[2026-02-03].
- [9] 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(9):3455-3464.
- [10] 林铮,刘可真,沈斌,等.考虑海上风电多机组时空特性的超短期功率预测模型[J].电力系统自动化,2022,46(23):59-66.
- [11] MEI Y, CHE J, SUN Q, et al. An overview of short-term wind power forecasting: Multi-scale decomposition and multi-model deep learning fusion[J]. Energy Strategy Reviews, 2026, 63: 102021.
- [12] 王继恒,胡阳,宋子秋,等.基于多模态混合深度学习的大型风电机组入流风场预测[J/OL].系统仿真学报,2026:1-14[2026-02-03].
- [13] 范竞敏,贺广林,王新刚,等.基于 VMD-TCN-GRU-AM 的超短期风电预测[J].太阳能学报,2025,46(6):538-547.
- [14] 乔宽龙,董存,车建峰,等.时空特性下基于图卷积神经网络的风电集群功率短期预测方法[J].太阳能学报,2024,45(5):95-103.
- [15] 徐武,范鑫豪,沈智方,等.多尺度特征提取的 Transformer 短期风电功率预测[J].太阳能学报,2025,46(2):640-648.
- [16] ZENG A, CHEN M, ZHANG L, et al. Are transformers effective for time series forecasting?[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2023, 37(9): 11121-11128.
- [17] ZHANG T, ZHANG Y, CAO W, et al. Less is more: fast multivariate time series forecasting with light sampling-oriented MLP structures[EB/OL]. arXiv:2207.01186, 2022[2026-02-03].
- [18] WANG R, WU J, CHENG X, et al. Adaptive expert fusion model for online wind power prediction[J]. Neural Networks, 2025, 184: 107022.
- [19] SHEN J, QU Y, ZHANG W, et al. Wasserstein distance guided representation learning for domain adaptation[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2018, 32(1).
- [20] XIANG Q, ZI L, CONG X, et al. Concept drift adaptation methods under the deep learning framework: a literature review[J]. Applied Sciences, 2023, 13(11): 6515.
- [21] CHEN Y, XU J. Solar and wind power data from the Chinese state grid renewable energy generation forecasting competition[J]. Scientific Data, 2022, 9(1): 577.
- [22] HONG T, PINSON P, FAN S, et al. Probabilistic energy forecasting: global energy forecasting competition 2014 and beyond[J]. International Journal of Forecasting, 2016, 32(3): 896-913.
- [23] DEY R, SALEM F M. Gate-variants of gated recurrent unit (GRU) neural networks[C]//2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS). 2017: 1597-1600.
- [24] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: a search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10): 2222-2232.
- [25] HEWAGE P, BEHERA A, TROVATI M, et al. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station[J]. Soft Computing, 2020, 24(21): 16453-16482.
- [26] LIU Y, HU T, ZHANG H, et al. iTransformer: inverted transformers are effective for time series forecasting[EB/OL]. arXiv:2310.06625, 2023[2026-02-03].
- [27] PIAO X, CHEN Z, MURAYAMA T, et al. Fredformer: frequency debiased transformer for time series forecasting[C]//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2024: 2400-2410.
- [28] ZHANG Y, YAN J. Crossformer: transformer utilizing cross-dimension dependency for multivariate time series forecasting[C]//The Eleventh International Conference on Learning Representations. 2023.