

基于数字孪生的区域气象关联风电预测模型

代佳琨¹, 向月¹, 刘俊勇¹, 张新²

(1. 四川大学电气工程学院, 四川 成都 610025; 2. 谢菲尔德大学自动控制与系统工程系, 英国 谢菲尔德 S10 2TN)

摘要:新型电力系统建设下,风电清洁能源得到大力开发。由于风电的发电功率与风速、风向、气温等气象因素强关联,具有波动性,且新建的风电场缺乏历史气象和发电数据,难以被精确预测。因此,文中提出了一种基于数字孪生的区域气象关联风电预测方法。首先,将风电场系统物理实体与数据驱动模型相结合,实现了数据同步和实时更新;然后,通过灰色关联分析方法筛选出对风电场发电功率影响作用较大的多元气象因素,使用XGB算法对优选后的气象关联数据集进行训练,结合天气预报对风电场发电功率进行预测;最后,利用有历史数据风电场的训练模型对无历史数据新建风电场进行预测。算例对四川某区域风电场数据进行了分析和预测,验证了所提方法的有效性 with 合理性,能够获得比传统预测方法更准确的预测结果。

关键词:风电场;发电功率预测;数字孪生;气象因素;关联分析

中图分类号:TM 614 **文献标志码:**A **文章编号:**1003-6954(2023)02-0032-07

DOI:10.16527/j.issn.1003-6954.20230206

Regional Meteorology Correlated Wind Power Prediction Based on Digital Twin

DAI Jiakun¹, XIANG Yue¹, LIU Junyong¹, ZHANG Xin²

(1. College of Electrical Engineering, Sichuan University, Chengdu 610025, Sichuan, China; 2. Department of Automatic Control and Systems Engineering, The University of Sheffield, Sheffield S10 2TN, England)

Abstract: With the construction of new power system, clean energy has a great development. Because the wind power has strong correlation with meteorological factors such as wind speed, wind direction and temperature, it has the strong volatility. And there lacks historical data of weather and power generation in the newly-built wind farms, so it is difficult to accurately predict the wind power. Therefore, a regional wind power prediction method correlated with meteorology based on digital twin is proposed. Firstly, the physical entity of wind farm system is combined with the data-driven model to realize data synchronization and real-time update. Then, the multivariate meteorological factors that have a great impact on generation power of wind farm are screened out by the gray correlation analysis method, and the optimized wind power meteorological data set is trained by extreme gradient boosting (XGB) algorithm and the future generation power of wind farm is predicted in combination with the weather forecast. Finally, the training model of wind farms with historical data is used to predict the newly-built wind farms without historical data. Cases are given to analyze and predict the wind farm data of a certain region in Sichuan province, which verifies the effectiveness and rationality of the proposed method and can obtain more accurate prediction results than the traditional prediction methods.

Key words: wind farm; generation power prediction; digital twin; meteorological factors; correlation analysis

0 引言

随着清洁能源发电建设需求的不断增长,清洁

能源有望进入大规模发展的新阶段。如何对清洁能源发电功率进行精确预测,是保证电力系统经济调度和安全运行的重要基础。其中,如何建立一个更

高预测精度的模型,是亟待解决的问题。

精确的风电场发电功率预测是风电有效利用的前提。短期风电功率预测高度依赖风速预测,风速预测是导致预测误差的主要原因^[1-2]。为了获得更准确的短期风电功率预测结果,文献[3]提出了一种风速校正方法,以改进基于天气因素和预报风电功率预测模型获得的风速预测结果。然而,新建风电场的历史风速数据可能不足以训练性能良好的预测模型。文献[4]基于邻近风电场信息,利用卷积神经网络算法进行了短期风速预测。在所提出的方法中,卷积神经网络用于将风速变化的内在特征迁移到新建的风电场。文献[5]提出了一种短期光伏功率预测方法,应用了变分模态分解算法和双重注意力机制长短期记忆人工神经网络,可以为功率预测提供更高的准确性。文献[6]提出了一种基于多源风速融合的短期风功率预测方法。文献[7]提出了一种基于蒙特卡洛的风速校正方法,以减少因为气象因素的误差而造成的预测精度下降。上述文献基于风电场历史数据进行预测,但没有将出力预测与气象因素关联分析相结合。由于缺乏新建风电场历史数据,风电功率预测的精度仍不能令人满意。为此,文献[8]提出了一种基于能源气象关联的风电基地发展潜力评估方法。文献[9]提出了一种光伏和风力发电的联合预测方法,对风能和光伏输出功率之间的关系进行建模,可以在不同的天气条件下都有良好的预测精度。文献[10-12]基于天气数据对出力预测进行了分析,并分析了重要参数及其与风电功率输出的关联。

上述方法基于风电-气象的历史数据集,考虑了多种环境参数(风速、气压、温度和湿度)的影响,但模型不能适应由于运行时间、运行环境变化的风电场出力状态变化,缺少灵活性和实时性。因此,预测模型需要与风电场的物理实体相结合,在精度变低时,通过自主学习不断进行修正或进行故障识别,从而实现与物理实体的同步。数字孪生技术近年来在电力系统方面也有应用。文献[13]提出了一种基于长短期记忆神经网络(long short-term memory, LSTM)的光伏发电功率预测方法,并利用迁移学习建立了数字孪生模型,不仅可以得到精确的预测结果,还节省了模型训练时间。文献[14]运用数字孪生技术建立了虚拟空间对物理电网的映射和交互,提出了基于数字孪生的配电网运行画像构建方法。

文献[15]基于数字孪生的概念、架构和特征,提出了数字孪生虚拟电厂系统:通过引入数字孪生系统,将风电场物理实体与数据驱动的预测模型结合,基于历史数据和实时数据进行自主学习,能够实现精确的功率预测。

基于对上述文献的分析,下面提出一种基于数字孪生的区域气象关联风电预测模型,并且通过气象因素关联将此数字孪生模型应用到相似的新建风电场。所提方法相较于其他预测方法有更高的预测精度,节约了训练模型时间。

1 风电功率预测的数字孪生框架

数字孪生由现实物理空间、虚拟数字空间以及两者间数据传输链构成^[16]。所提出的风电出力预测数字孪生系统(wind farm digital twin, WF-DT)以风电发电功率预测为研究对象,其框架如图 1 所示。其中现实物理实体主要是风电场系统,包括风电场气象传感器与风机等物理实体。虚拟数字空间主要是由数据驱动的风电场发电功率预测模型。基于数字孪生的风电发电功率预测方法主要包含以下部分:

1) 现实空间物理模型:主要包括风电场气象(风速、气温、气压、湿度等)与运行状态(发电功率等)感知。

2) 虚拟空间数字模型:基于历史数据形成风电-气象关联分析数据集,选取关联度高的几个气象因素,利用极度梯度提升树(extreme gradient boosting, XGB)算法进行风电发电功率的实时预测。

3) 数据传输链:包括数据存储、数据传输模块。

4) 实时监测系统:包括误差检测及故障分析功能。当平均误差偏高时,自动调整模型并进行故障分析,得出偏差较大的数据项(如风速、湿度等),并向现实物理空间进行反馈,使风电场系统进行调整。

基于数字孪生的区域气象关联风电预测系统工作原理及能量信息流动示意如图 2 所示,其工作原理如下:一方面,采用各种传感器对风电场所处环境的多元气象数据进行采集,进行归一化处理后,作为灰色关联分析、XGB 预测模型的输入量进行测试,得到初步预测结果;另一方面,将采集到的实时气象数据上传到数据储存库进行数据更新,并通过对比分析,搜索最接近的气象数据,得到当时该气象条件

对应的风电场发电输出功率实际值和预测值,然后进行误差补偿得到最终的数字孪生体预测值。

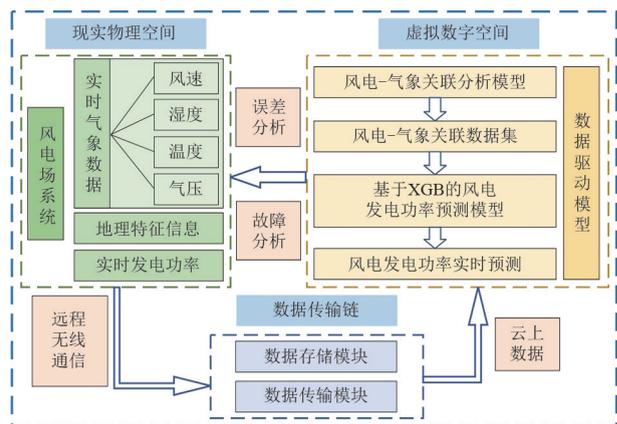


图1 气象关联风电预测数字孪生框架

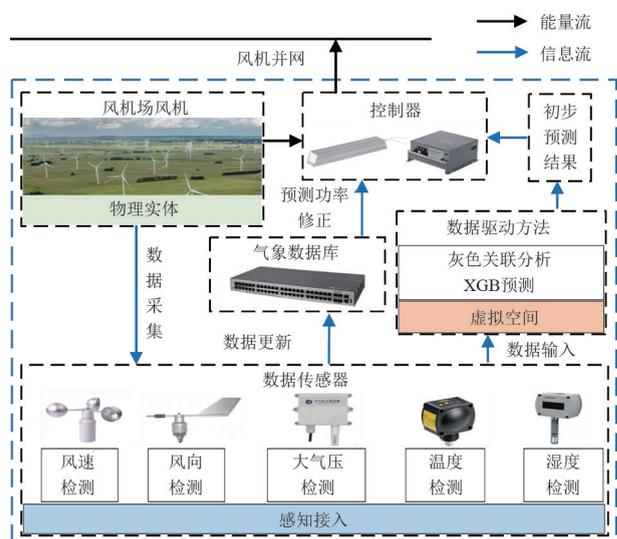


图2 预测系统工作原理及能量信息流动

2 风电-气象关联分析

气象因素对风电场发电功率的作用机理和影响程度各不相同^[17],定量分析气象因素作用程度的大小,进而准确识别、优化选取核心气象影响因素是选取模型输入变量的基本前提。这里使用灰色关联分析方法研究气象因素与风电场发电功率之间的关联特征。其基本原理是对数据序列动态变化曲线进行相似度的量化比较,进而分析各气象因素间关联程度的强弱^[18]。从风电场系统的物理实体获得数据后,数据驱动模块先采用灰色关联分析法对单个气象因素进行分析,获取不同时期下各气象要素与风电发电功率之间的关联度。

将风电场历史数据按照丰水期、枯水期和平水期划分,把风电场发电功率与气象因素的序列看成

是一个灰色关系统。分别计算多元气象因素与新能源发电功率的灰色关联度,得出在不同时期气象因素对新能源发电功率作用程度由强到弱的排序情况,从而确定影响新能源发电功率的核心气象因素。首先,定义风电场发电功率为参考序列、气象因素为比较序列,量化两者之间的变化大小,如式(1)所示。

$$\Delta_i(k) = |x'_i(k) - x'_i(k)| \quad (i = 1, \dots, m; k = 1, 2, \dots, n) \quad (1)$$

式中: $\Delta_i(k)$ 为差序列, $\Delta_i(k) = \{\Delta_i(1), \Delta_i(2), \dots, \Delta_i(k)\}$; m 和 n 分别为序列数量与序列长度; $x'_i(k)$ 为第 i 个序列中第 k 个数据的值。

筛选每个差序列中的最小值 $\min_i \min_k \Delta_i(k)$ 及最大值 $\max_i \max_k \Delta_i(k)$,定义两者之间的关联系数为 $\gamma_{oi}(k)$ ^[19]。

$$\gamma_{oi}(k) = \frac{\min_i \min_k \Delta_i(k) + \zeta \max_i \max_k \Delta_i(k)}{\Delta_i(k) + \xi \max_i \max_k \Delta_i(k)} \quad (i = 0, 1, \dots, m; k = 1, 2, \dots, n) \quad (2)$$

式中, ξ 为分辨系数,取值范围为(0,1)。

灰色关联度 γ_{oi} 为

$$\gamma_{oi} = \frac{1}{n} \sum_{k=1}^n \gamma_{oi}(k) \quad (3)$$

式中, n 为序列的长度。

γ_{oi} 受风电场发电功率、气象因素、序列长度和分辨系数的影响,取值范围为(0,1)。 γ_{oi} 表示各气象因素与风电场发电功率的关联程度,其值越大,发电功率与气象因素的变化趋势越相似,即气象因素对风电场发电功率的影响作用更大。

归一化灰色关联度,如式(4)所示。

$$\gamma_i = \gamma_{oi} / \sum_{i=1}^m \gamma_{oi} \quad (4)$$

式中, γ_i 为第 i 个比较序列的因子权重系数,表示各个气象因素对风电场发电功率变化的作用大小。以 γ_i 的大小排序,筛选出影响作用大的气象因素,即核心气象因素。

3 数据驱动的风电场发电功率预测

风电场发电功率精确预测是应对风电出力随机性、波动性与间歇性的重要手段。但其中日前预测对历史数据的连续性和完整度要求较高,且预测的输入变量维度较高,这会使模型结构趋于复杂,也使基于多变天气条件的预测精度不高。同时,部分风

电场也缺乏历史数据。为此,采用数字孪生系统更进一步地将风电场物理实体特点与预测的数字模型结合,将上述关联规则作为输入变量识别优化的依据,提取出关键气象因素,并基于此构建风电出力预测模型的输入集。考虑到数据样本量不足,选用 XGB 算法对新能源出力进行 24 h 的日前预测,并与多种算法的预测结果进行对比,验证根据关联分析结果筛选输入变量的有效性。此外,通过构建无历史出力数据情况下的拟合模型以确定新建电站的出力状况,实现无历史出力数据的新建风电场发电功率预测。

由于实际中历史数据较为混乱且数量少,采用 XGB 算法能够在数据量较少的情况下进行较好的拟合,取得较高的预测精度^[20]。基于数字孪生的风电场发电功率预测 XGB 算法的模型^[21]为

$$\hat{y} = \sum_p f_p(x_k), \quad f_p^R \in F \quad (5)$$

式中: \hat{y} 为风电场发电功率预测值; F 为 XGB 算法的回归树模型集合; $f_p(\cdot)$ 为函数空间 F 中的第 p 个函数; x_k 为 k 个输入数据,即优选关联度较高的气象因素的值。

每一次迭代不影响模型,即原来的模型保持不变,将一个新函数 $\Omega(\cdot)$ 添加到模型里。一个函数对应一棵树,新生成的树拟合上次预测的残差、目标函数及迭代过程如式(5)一式(8)所示。

$$X_{\text{obj}} = \sum_{k=1}^n l(x_k, \hat{y}) + \sum_p \Omega(f_p) \quad (6)$$

$$\Omega(f_p) = \gamma T + \lambda \frac{1}{2} \sum_{j=1}^T \omega_j^2 \quad (7)$$

$$\begin{cases} \hat{y}^{(0)} = 0 \\ \hat{y}^{(1)} = f_1(x_k) = \hat{y}^{(0)} + f_1(x_k) \\ \hat{y}^{(s)} = \hat{y}^{(s-1)} + f_p(x_k) \end{cases} \quad (8)$$

式中: $\sum_{k=1}^n l(x_k, \hat{y})$ 为预测与真实数据累计误差, $l(\cdot)$ 为误差计算函数; $\hat{y}^{(s)}$ 为预测值的 s 次迭代值; $\sum_p \Omega(f_p)$ 为正则化项; T 为叶子结点的总数; ω_j 为第 j 个叶子节点的分数; γ 为系数,作用是控制叶子节点数量; λ 为系数,作用是将叶子节点的分数控制在合理范围。XGB 中正则化方程将根据误差变化调整预测函数,降低阶数,防止预测的过拟合。模型通过不断迭代进一步缩小目标函数。每次迭代对目标函数的影响如式(9)所示^[22]。

$$\tau^{(s)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(s-1)} + f_s(X_i)) + \Omega(f_s) \quad (9)$$

最后,选取平均绝对百分比误差作为模型预测性能的主要评价指标。

$$\Delta y_i = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (10)$$

式中, Δy_i 为风电场系统 t 时刻实际发电功率 y_i 和模型产生的发电功率预测值 \hat{y}_i 之间的误差。若 Δy_i 超过设置的阈值 ω ,说明误差较大,此时系统自动分析引起误差的原因。原因有两种:1)由风电场系统物理空间中的传感器故障产生的,数字系统通过排除法找到导致误差的传感器数据类型;2)WF-DT 系统中的预测模型已不再能反映当前物理实体的真实特性,就需要对预测模型的结构或参数进行更新。

4 算 例

针对四川某区域风电场进行能源出力与气象因素的关联分析,并基于此进行出力预测;最后,对区域内站点进行预测并验证所提出的数字孪生系统的有效性。其中风电场 2019 年和 2020 年的出力特性如图 3 所示。

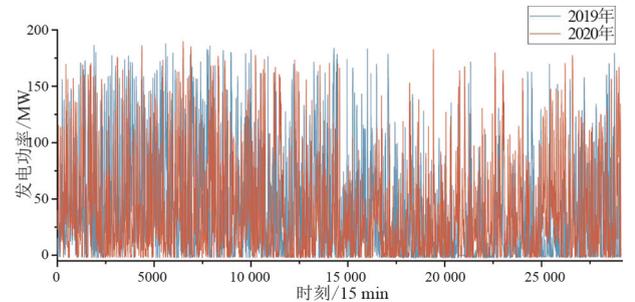


图 3 风电场 2019 和 2020 年的发电功率

4.1 风电场发电功率预测

系统在所存储的历史数据的基础上,首先对风电场进行发电功率与气象因素的关联分析。这里选取相关气象因素风速、风向、气温、湿度和气压,分别对丰水期、枯水期和平水期的关联度进行了分析,其结果如表 1 所示。

此风电场地处山谷,其海拔高度适中。风电场出力的核心影响因素为风速,次要关联影响因素为风向或气温,且影响因素具备一定的季节性。在丰水期,风电场风向关联度远大于气温关联度。而在枯水期及平水期,风向与气温关联度相差不大。值得注意的是,在枯水期,湿度也对风功率有明显影

响。相较而言,无论是丰水期、枯水期还是平水期,压强对风功率的影响都是最小的。

表 1 风电站核心气象要素关联度分析

丰水期		枯水期		平水期	
风速	0.827	风速	0.669	风速	0.783
风向	0.633	气温	0.661	风向	0.688
气温	0.517	风向	0.644	气温	0.644
湿度	0.458	湿度	0.627	湿度	0.616
气压	0.393	气压	0.600	压强	0.524

所举算例的数字孪生过程在于气象因素实时关联优选和 XGB 算法。为对比基于数字孪生系统中关联规则优化对预测性能的影响及 XGB 算法对其出力预测的有效性,分别构建传统的基于历史数据优选关联的 XGB 以及 LSTM、深度信念网络 (deep belief network, DBN) 等 3 种预测模型,进行 24 h 的风功率短期预测,结果如图 4 所示。

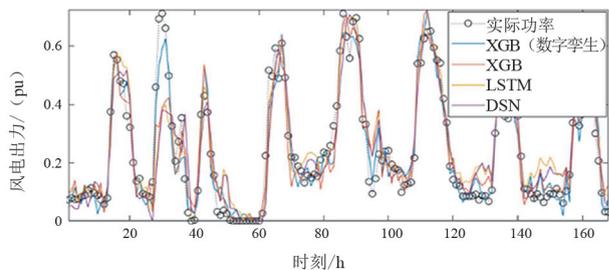
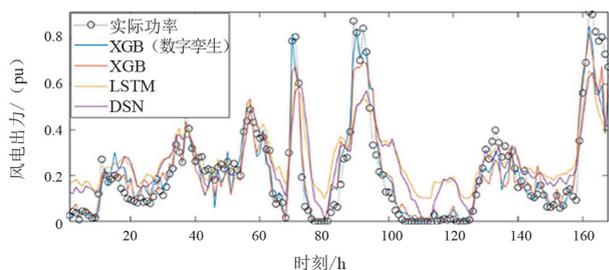


图 4 不同算法出力预测结果对比

由图 4 可知:在输出风功率较小、风功率变化较为平缓的情况下,有实时气象优选孪生过程的 XGB 预测模型精度高于传统的基于历史数据优选关联的 XGB 预测模型,并且均略高于 LSTM 和 DBN 预测模型;而在风电场发电功率陡增或陡降的极端风电出力情况下,如图 4(a)中时刻 70~71 和 96~97 内,所提出的数字孪生系统的拟合风功率大幅度波动的能力明显高于其他模型,原因就在于此孪生过程的实时性,能够实时优选高关联的气象因素,并且对预测过程进行校正。传统方法基于已有历史数据库,没有与实际风电场物理实体相结合,缺乏灵活性,遇极

端风电出力情况时预测效果不佳。

计算有无数字孪生系统的 XGB 模型以及优化选取输入变量后的 LSTM 和 DBN 在测试集上的风功率归一化平均绝对误差 (mean absolute error, MAE) 与预测精度 (基于均方根误差),如表 2 与表 3 所示。

表 2 风电预测误差

时期	MAE 预测误差			
	XGB (数字孪生)	XGB	LSTM	DBN
丰水期	0.058 2	0.063 6	0.132 3	0.115 1
枯水期	0.082 1	0.120 5	0.133 0	0.125 8

表 3 风电预测精度

时期	预测精度/%			
	XGB (数字孪生)	XGB	LSTM	DBN
丰水期	91.86	91.24	84.47	85.46
枯水期	85.66	87.49	87.22	87.01

结合对图 4 的分析结果,可以看出:基于数字孪生的统筹方法能够有效改善 XGB 的预测效果;实时气象关联优选后的气象因素筛选降低了风功率随机性和间歇性对预测模型最终结果的影响,对解决风功率快速、大幅度波动情况下预测模型精度不稳定的问题具有一定的适用性。

4.2 无历史数据相似电站预测

基于数字孪生构建无历史数据相似风电场发电功率拟合模型,通过与有历史数据的风电场数据进行对比以验证拟合模型的有效性。实际风功率与拟合结果的对比如图 5 所示。

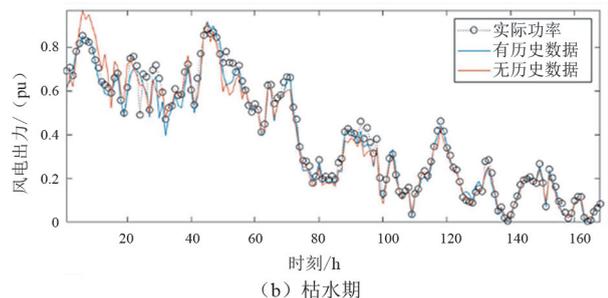
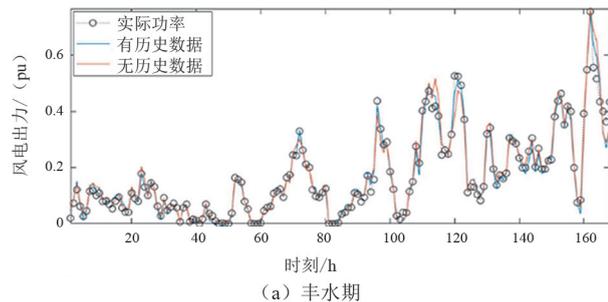


图 5 风电场发电功率拟合结果对比

由图 5 可知,在风功率较小且变化平稳的情况

下,无历史数据风电场拟合预测的整体精度较高,如图 5(a)中时刻 1~100 h 内,拟合结果与实际数据基本完全重合,可以很好地反映风电出力状况。当气象因素随天气条件变化较剧烈,风功率的起伏波动大、频率高时,拟合结果与实际数据的偏差较常规天气时有一定的增加,但依然能较好地跟随风功率的变化。如图 5(b)中时刻 155~162 h 内,拟合结果准确反映出实际风功率的陡降和陡增,且两者的极大值点和极小值点基本一致。

风电预测拟合的精度如表 4 所示,无历史数据但有气象数据预测误差值保持在较好的范围内。

表 4 有/无历史数据风电场预测拟合精度对比

时期	预测精度/%	
	有历史数据无气象数据	无历史数据有气象数据
丰水期	91.52	95.41
枯水期	91.47	92.41

5 结 论

上面提出了一个基于数字孪生的区域气象关联风电预测模型。通过灰色关联分析方法筛选出对风电场发电功率影响作用较大的多元气象因素;使用 XGB 算法对优选后的风电-气象数据集进行训练,对风电场发电功率进行预测;关联预测模型与风电场系统物理实体相结合,实现了数据同步和实时更新。此基于数字孪生的发电功率预测模型能够利用有历史数据风电场的训练模型对无历史数据的新建风电场进行预测。利用所提方法对四川某区域风电场数据进行了分析和发电功率预测,深度挖掘了区域风电场的风电-气象关联特征,为后续预测该风电场的发电功率和相似风电场发电功率提供了数据。基于实时关联优选后的 XGB 算法相较于其他算法具有更高的精度。而无历史出力数据情况下的拟合模型所得结果在大部分时间段内与实际数据保持一致,预测误差值保持在较好的范围内。

参考文献

[1] GHADIMI Noradin, AKBARIMAJD Adel, SHAYEGHI Hossein, et al. Two stage forecast engine with feature selection technique and improved meta-heuristic algorithm for electricity load forecasting[J]. Energy, 2018, 161: 130-142.

[2] RODRIGUEZAB Fermin, FLEETWOODAB Alice, AINHOA

Galarza, et al. Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control [J]. Renewable Energy, 2018, 126: 855-864.

- [3] LI M L, YANG M, YU Y X, et al. A wind speed correction method based on modified hidden Markov model for enhancing wind power forecast [J]. IEEE Transactions on Industry Applications, 2022, 58(1): 656-666.
- [4] WANG Z J, ZHANG J, ZHANG Y, et al. Short-term wind speed forecasting based on information of neighboring wind farms [J]. IEEE Access, 2020, 8: 16760-16770.
- [5] 杨晶显, 张帅, 刘继春, 等. 基于 VMD 和双重注意力机制 LSTM 的短期光伏功率预测 [J]. 电力系统自动化, 2021, 45(3): 174-182.
- [6] AN J Q, YIN F, WU M, et al. Multisource wind speed fusion method for short-term wind power prediction [J]. IEEE Transactions on Industrial Informatics, 2021, 17(9): 5927-5937.
- [7] XIE Z Q, JI T Y, LI M S, et al. Quasi-Monte Carlo based probabilistic optimal power flow considering the correlation of wind speeds using copula function [J]. IEEE Transactions on Power Systems, 2018, 33(2): 2239-2247.
- [8] CHAO Huawei, WU Gang, LI Ting, et al. A development potential assessment method for clean energy stations [J]. Frontiers in Energy Research, 2022, 10: 1-14.
- [9] SANJARI M J, GOOIL H B, NAIR N C, et al. Power generation forecast of hybrid PV-wind system [J]. IEEE Transactions on Sustainable Energy, 2020, 11(2): 703-712.
- [10] 杨光. 光伏发电功率与气象影响因子关联关系的分析研究 [D]. 保定: 华北电力大学, 2014.
- [11] WU Y K, WU Y C, HONG J S, et al. Probabilistic forecast of wind power generation with data processing and numerical weather predictions [J]. IEEE Transactions on Industry Applications, 2021, 57(1): 36-45.
- [12] 刘宇凝, 王迎丽, 徐明文, 等. 基于数字孪生混合储能的风电功率波动平抑策略 [J]. 电网技术, 2021, 45(7): 2503-2514.
- [13] 史凯钰, 张东霞, 韩肖清, 等. 基于 LSTM 与迁移学习的光伏发电功率预测数字孪生模型 [J]. 电网技术, 2022, 46(4): 1363-1372.
- [14] 杜晓东, 曾四鸣, 刘科研, 等. 基于云模型的配电网运行画像数字孪生构建方法 [J]. 电力系统保护与控制, 2022, 50(10): 104-113.
- [15] 严兴煜, 高赐威, 陈涛, 等. 数字孪生虚拟电厂系统框架设计及其实践展望 [J]. 中国电机工程学报, 2023, 43(2): 604-619.

- [16] 王成山,董博,于浩,等.智慧城市综合能源系统数字孪生技术及应用[J].中国电机工程学报,2021,41(5):1597-1608.
- [17] SHI J, DING Z H, LEE W J, et al. Hybrid forecasting model for very-short term wind power forecasting based on grey relational analysis and wind speed distribution features [J]. IEEE Transactions on Smart Grid, 2014, 5(1):521-526.
- [18] WANG Yanliang, XIANG Yue. Photovoltaic-storage energy system management considering wireless data communication [J].Energy Reports, 2022,8:267-273.
- [19] WEI Xiangyu, XIANG Yue, LI Junlong. Wind power bidding coordinated with energy storage system operation in real-time electricity market: A maximum entropy deep reinforcement learning approach [J]. Energy Reports, 2022,8:770-775.
- [20] 陈振宇,刘金波,李晨,等.基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J].电网技术,2020,44(2):614-620.
- [21] YAO Xiaotong, FU Xiaoli, ZONG Chaofei. Short-term load forecasting method based on feature preference strategy and light GBM-XGboost [J]. IEEE Access, 2022,10:75257-75268.
- [22] 吴春华,董阿龙,李智华,等.基于图相似日和 PSO-XGBoost 的光伏功率预测[J].高电压技术,2022,48(8):3250-3259.

作者简介:

代佳琨(1999),男,硕士研究生,研究方向为新能源出力预测;

向月(1987),男,博士,副教授,研究方向为新型电力系统规划与运行;

刘俊勇(1962),男,博士,教授,研究方向为电力系统分析、调度与市场等;

张新(1983),男,博士,教授,研究方向为新能源电力系统规划与运行。

(收稿日期:2022-08-26)

(上接第 14 页)

- [26] 吴天宝,马小敏,唐军,等.基于时间序列迭代的输电线路覆冰厚度估计方法[J].四川电力技术,2022,45(5):20-25.
- [27] 熊昌全,何泽其,张宇宁,等.基于 Bi-LSTM 和支持向量机的风机叶片短期覆冰状态预测模型[J].四川电力技术,2021,44(3):88-94.
- [28] 周恩泽,胡思雨,张录军,等.电网山火灾害特征及风险预警技术[J].电力工程技术,2020,39(3):58-64.
- [29] 陈莹,王松岩,陈彬,等.台风环境下考虑地理高程信息的输电通道结构失效故障概率评估方法[J].电网技术,2018,42(7):2295-2302.
- [30] 刘天浩,朱元振,孙润稼,等.极端自然灾害下电力信息物理系统韧性增强策略[J].电力系统自动化,2021,45(3):40-48.
- [31] 马丽叶,王海锋,卢志刚,等.计及相关性影响的台风灾害下灵活性资源韧性规划[J].电力系统自动化,2022,46(7):60-68.
- [32] 薛禹胜.两网融合支撑下的停电防御框架(电力系统自动化公众号)[EB/OL].(2019-07-21)[2022-08-28].
<https://mp.weixin.qq.com/s/LWbyLwLWsltyXxGXIpFcQ>.
- [33] 陈彬,倪明,周霞,等.极端灾害下基于时空网格的配电网多源数据融合方法[J].中国电力,2019,52(11):77-84.
- [34] 张瑞曦,徐青山,程煜,等.极端灾害下考虑动态重构的微网形成策略[J].电力工程技术,2022,41(1):56-63.
- [35] 郁琛,李尚轩,谢云云,等.考虑交通网与配电网信息融合的台风后配电网抢修策略优化[J].电力系统自动化,2022,46(4):15-24.
- [36] 张璐,黄睿,王照琪,等.考虑恢复力与经济性均衡的配电网移动储能优化配置策略[J].电力系统自动化,2020,44(21):23-31.
- [37] 杨祺铭,李更丰,别朝红,等.台风灾害下基于 V2G 的城市配电网弹性提升策略[J].电力系统自动化,2022,46(12):130-139.
- [38] 姚卓磊,黄文焘,余墨多,等.智能配电网电力-通信灾害故障动态协调恢复方法[J].电力系统自动化,2022,46(19):87-94.
- [39] 薛禹胜,吴勇军,谢云云,等.复合自然灾害下的电力系统稳定性分析[J].电力系统自动化,2016,40(4):10-18.
- [40] LI Z, XUE Y, WANG H, et al. Decision support system for adaptive restoration control of transmission system [J]. Journal of Modern Power Systems and Clean Energy, 2021,9(4):870-885.

作者简介:

郁琛(1985),男,博士,高级工程师,研究方向为电力系统外部灾害防御;

常康(1983),男,博士研究生,高级工程师,研究方向为电力系统外部灾害防御;

刘韶峰(1977),男,硕士,高级工程师,研究方向为新能源并网控制及电力系统安全稳定控制。

(收稿日期:2022-08-30)