

引用格式:张勇,孙雁斌,颜融,等.考虑极端天气的新型电力系统智能化调度方法[J].电力科学与技术学报,2025,40(1):163-172.

Citation: ZHANG Yong, SUN Yanbin, YAN Rong, et al. Intelligent dispatching of new power system with extreme climate present[J]. Journal of Electric Power Science and Technology, 2025, 40(1): 163-172.

考虑极端天气的新型电力系统智能化调度方法

张勇¹, 孙雁斌¹, 颜融¹, 肖亮¹, 范展滔¹,
方必武¹, 黎立丰², 杨再敏², 蒙文川²

(1. 中国南方电网有限责任公司电力调度控制中心, 广东广州 510530; 2. 南方电网能源发展研究院有限责任公司, 广东广州 510530)

摘要: 随着以新能源为基础的新型电力系统建设的不断推进, 近年来风电、光伏等新能源大规模密集接入系统, 这虽然为实现“双碳”目标奠定了坚实的基础, 但同时也导致极端天气下新型电力系统调度运行面临的挑战不断增大, 其中最易出现的问题是风电爬坡事件概率大幅提升, 不仅会造成系统频率的大幅频繁波动, 还会影响电力电量平衡, 严重威胁系统安全稳定运行。为此, 在统计分析风电爬坡事件的基础上, 提出基于深度自回归 (deep auto-regressive, DeepAR) 模型的风电爬坡事件的预测方法。首先, 结合风机功率与风速之间的关系, 分析极端天气下风电爬坡事件对电网调度运行的影响, 再建立风电爬坡事件物理模型, 分析发生风电爬坡事件时的风电功率统计特征; 然后, 结合深度自回归模型对风电爬坡事件进行功率预测, 分析极端天气下的风电出力曲线; 最后, 结合风电场实测数据验证所提方法的有效性。验证表明: 采用所提方法可提前精准定位极端天气环境下风电爬坡事件出现概率, 预期将极大改善未来新型电力系统调度运行面临的不确定性。

关键词: 新型电力系统; 风力发电; 极端天气; 风电爬坡; 深度自回归模型

DOI: 10.19781/j.issn.1673-9140.2025.01.017 中图分类号: TM73 文章编号: 1673-9140(2025)01-0163-10

Intelligent dispatching of new power system considering extreme climates

ZHANG Yong¹, SUN Yanbin¹, YAN Rong¹, XIAO Liang¹, FAN Zhantao¹,
FANG Biwu¹, LI Lifeng², YANG Zaimin², MENG Wenchuan²

(1. Power Dispatching Control Center of China Southern Power Grid Co., Ltd., Guangzhou 510530, China;

2. Energy Research Institute of China Southern Power Grid Co., Ltd., Guangzhou 510530, China)

Abstract: With the continuous development of new power systems based on new energy, large-scale and intensive wind power, photovoltaic, and other new energy access to the system has laid a solid foundation for the realization of the “carbon peaking and carbon neutrality” goals, but at the same time, it also leads to the increasing challenges faced by the dispatching operation of new power systems under extreme climates, and the most prominent problem is that the probability of wind power ramp events has increased significantly. Wind power ramp events will not only cause great fluctuations in the frequency of the system but also affect the balance of electric power and energy, threatening the safe and stable operation of the system. Through the statistical analysis of wind power ramp events, a predictive method of wind power ramp events based on a deep auto-regressive (DeepAR) model is proposed. Firstly, combined with the relationship between wind power and wind speed, the impact of wind power ramp events on power grid dispatching operations under extreme climates is analyzed. Secondly, a physical model of wind power ramp events is established to analyze the statistical characteristics of wind power when wind power ramp events occur. Then, the DeepAR model is used to perform the power prediction of wind power ramp events, and the wind power output curve under extreme

收稿日期: 2023-03-17; 修回日期: 2024-06-21

基金项目: 南方电网公司管理创新项目 (000000KK52210094)

通信作者: 蒙文川 (1976—), 男, 博士, 高级工程师, 主要从事电网新能源发展规划研究; E-mail: mengwe@csg.cn.

climates is analyzed. Finally, combined with the measured data of the wind power field, the effectiveness of the proposed method is verified. The verification shows that the proposed method can accurately predict the occurrence probability of wind power ramp events under extreme climates in advance, which is expected to greatly improve the uncertainty faced by the dispatching operation of new power systems in the future.

Key words: new power system; wind power generation; extreme climate; wind power ramp; deep autoregressive model

风能是一种清洁、无污染的可再生能源,其蕴含的能量巨大,受到世界各国的重视^[1-2]。随着中国经济快速发展和对能源的需求与日俱增,风力发电已发展为中国实现“双碳”目标的重要途径。随着风电装机占比的不断提升,风电的随机性、波动性及间歇性对大电网的安全稳定运行带来了巨大挑战^[1-5]。特别是在强对流、台风以及长时间大范围雨雪冰冻灾害等极端天气条件下,容易发生短时间内风电功率出现大幅变化的风电快速爬坡和风机大面积凝冻失备等事件,可能引发突出的电力电量平衡困难等问题,极大影响了电网安全运行^[6-10]。

极端天气导致短时间尺度上风电出力大幅波动,对新型电力系统智能化调度的影响尤为明显,如强对流等极端天气将显著改变风电场附近平均风速,进而引发风电爬坡事件^[7]。根据风电功率的变化方向可分为上、下爬坡事件,两者均会造成系统有功功率短时内严重不平衡,对大电网频率稳定造成严重威胁,极端情形下甚至会引发大面积停电等事故。目前,国内外针对此类爬坡事件的预测展开了一定的研究,文献[11]通过数据挖掘算法直接预测风电的爬坡率,但预测误差受预测步长的影响较大,无法对不同地区风电功率进行统一预测;文献[12]研究不同尺度风电爬坡事件的爬坡幅度、爬坡率和爬坡时间的概率分布,在短时间内预测效果较好,但随着时间的增长预测效果有所下降;文献[13]利用原子稀疏分解对非平稳信号的强跟踪和预测能力,结合线性回归方法修正预测结果,但分解的原子分量稀疏性较差,容易影响预测结果。综上,现有方法难以准确预测未来较长时间周期的风电爬坡事件。

针对以上问题,本文首先分析强对流天气下的风电场出力变化及其对高比例新能源接入新型电力系统调度运行的影响,在此基础上进一步对急剧变化风速下产生的风电爬坡场景进行深入探究,分析风电爬坡时风电出力的统计特性及相关物理特征。本文利用深度自回归神经网络和风速预测数据,结合风电爬坡场景下风电出力变化特征指纹,预测并判断未来一周内是否可能出现风电爬坡事

件,为调度运行确定运行方式提供决策支撑。

1 新型电力系统调度运行的挑战

新型电力系统的电源构成有显著变化,需要深入分析其带来的巨大挑战。与传统电力系统相比,新型电力系统的特征是,以风电、光伏为代表的新能源在电源结构中占据主导地位,并逐渐在发电层面占据主导地位^[6]。由于新能源发电具有强随机性、波动性和间歇性,受天气条件影响极大,因此,新型电力系统运行调度难度不断增大。

影响中国南方区域新型电力系统的恶劣天气主要包括强对流天气、台风和寒潮等^[7-8]。强对流天气是对流风暴所引起并由空气的强烈垂直运动导致的极端天气现象,它一般属于中小尺度天气系统,具有典型的“短时、高强度”特征。台风则属于大中尺度天气系统,主要是沿海地区的大风暴雨等天气,也可认为是一种较大范围的强对流天气;在强对流天气过程中,空气的剧烈对流运动通常伴随地面性大风、强雷电活动及短时强降雨等极端天气,对电网的主要影响模式是大量输电线路跳闸。寒潮是高纬度寒冷空气在特定的条件下加强加速向中低纬度地区迅速蔓延的天气现象,伴有沿途地区的大范围降温;寒潮对电力系统的影响多表现为输电线路和风机叶片覆冰及冻结。此外,强对流天气、台风及寒潮侵入地区普遍出现大风,部分风电场可能会出现功率满发甚至风力过大导致切出停机等现象。

风电接入改变了电网原有的潮流分布、系统惯量及电力电量平衡方法,不仅对电网稳定特性(包括频率、动态、暂态和电压稳定等)带来了巨大变革,同时也增加了气象等外界条件对电力系统产生大扰动的可能性^[14]。

选取广西某地区风速、风电出力数据,如图1所示,可见在一定的风速范围内,风机发电量与风速呈正相关性。但在恶劣气象条件下,急剧变化的风速可能会使风机出现爬坡现象,当风速超过阈值时甚至会发生风机切出事件,短时内发电出力的剧烈波动对电力系统的电力电量平衡提出了严峻挑战,这是新型电力系统调度运行的关键问题。

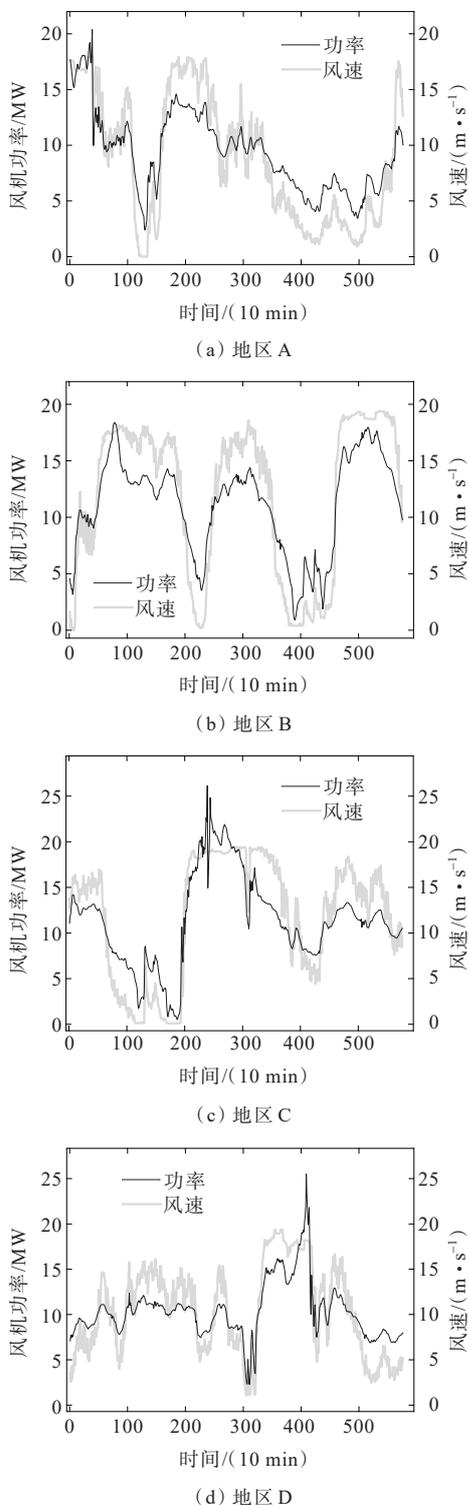


图 1 地区 A、B、C、D 风电功率与风速曲线
Figure 1 Wind power and wind speed curves in regions A, B, C and D

2 风电爬坡

2.1 风电爬坡模型

风电爬坡指的是风电出力在短时间内大规模变化的事件^[15-24],在强对流等极端天气过程中,风电场风电爬坡事件多发^[25-27]。风电爬坡通常具有爬坡

率、爬坡幅值、开始时间和持续时间等 4 个重要特征,如图 2 所示,其中, ΔP_1 、 ΔP_2 为爬坡幅值, Δt_1 、 Δt_2 为持续时间, t_1 、 t_2 为开始时间,爬坡率可表示为 $\Delta P_1 / \Delta t_1$ 、 $\Delta P_2 / \Delta t_2$ 。

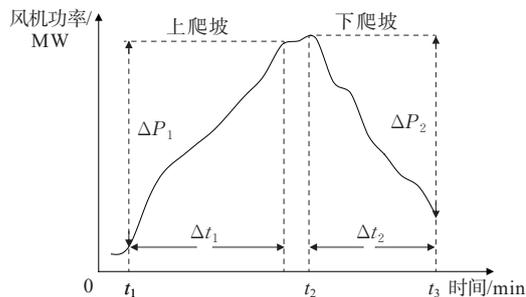


图 2 风电爬坡示意

Figure 2 Wind power ramp

根据风电爬坡概念可作出不同定义。当时间间隔为 Δt 、2 个时间断面风电功率的差值绝对值超过阈值时,文献[16]认为发生风电爬坡事件,即满足:

$$|P_{t+\Delta t} - P_t| > \lambda_{\text{threshold}} \quad (1)$$

式中, P_t 、 $P_{t+\Delta t}$ 分别表示 t 、 $t + \Delta t$ 时刻的功率; $\lambda_{\text{threshold}}$ 为给定阈值。

由于式(1)中对风电爬坡的定义并没有对时间区间作出规定,因此,文献[16]进一步规定,在时间间隔 Δt 范围内,若风电功率最大值与最小值的差值超过阈值,则认为发生风电爬坡事件,即满足:

$$\max(P[t, t + \Delta t]) - \min(P[t, t + \Delta t]) > \lambda_{\text{threshold}} \quad (2)$$

上述定义虽然考虑了区间内风电功率,但忽略了风电爬坡的变化率,因而本文采用文献[17]所定义的风电爬坡概念,即在一定时间间隔下,起始和结束时刻风电功率的差值绝对值与时间间隔的比值大于给定阈值,认为此时出现风电爬坡事件,即

$$|P_{t+\Delta t} - P_t| / \Delta t > \lambda_{\text{threshold}} \quad (3)$$

2.2 风电爬坡统计特性分析

风电功率曲线与风速密切相关^[18],风电功率与风速的关系如图 3 所示,当风速处于 $V_1 < V < V_2$ 时,功率大致呈现指数增长的规律,此段时间的功率变化率较大,容易出现上爬坡事件;当风速过大以至于超过规定阈值时,风机会出现切出停机现象,如风速大于 V_4 时风机功率会骤降为零。风机切机主要是风力过大时引起的切出停机现象,出现此类现象的条件较苛刻,绝大部分地区难以出现风机大面积同时切出停机现象,因此,本文主要考虑风速 $V_1 < V < V_2$ 时的风电爬坡事件。

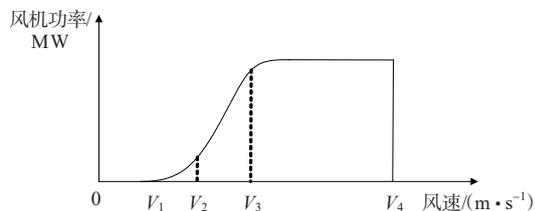


图3 风机功率与风速关系

Figure 3 Relationship between wind power and wind speed

选取南方某地区风电功率数据进行分析,风速与风电出力采样间隔为10 min。根据本文的风电爬坡定义,基于风电出力识别爬坡事件。假设风电场装机容量为20 MW,且最小爬坡时间 Δt 为1 h,对于向上爬坡,当功率变化超过总装机容量的20%时,则认为存在风电上爬坡事件;对于下爬坡,当功率变化超过总装机容量的15%时,则认为存在风电向下爬坡事件^[1]。因此,规定上爬坡率大于4 MW/h或下爬坡率大于3 MW/h的现象为风电爬坡事件。原始功率曲线如图4所示;爬坡事件识别结果如图5所示。图5中将未发生爬坡事件对应时间点的爬坡率置零,将已发生爬坡事件对应时间点的爬坡率保留。

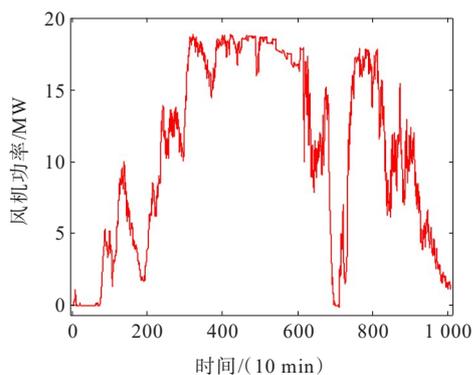


图4 风电出力曲线

Figure 4 Wind power output curve

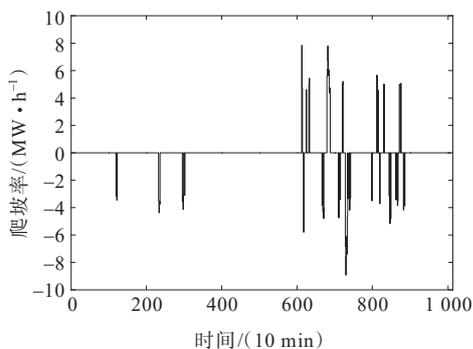


图5 风电出力爬坡率

Figure 5 Ramp rate of wind power output

每个爬坡事件的持续时间不同,且对应爬坡率也有很大区别。尽管在一周内发生爬坡事件的次数较少,但爬坡事件会使风电出力出现波动,影响电网保供。为进一步分析风电功率的变化情况,对上述数据进行一阶差分统计分析,差分前、后统计状况如表1所示。

表1 差分前、后统计状况

Table 1 Statistical values before and after difference

统计值	原始序列		差分序列	
	风机出力/ MW	风速/ ($\text{m} \cdot \text{s}^{-1}$)	风机出力/ MW	风速/ ($\text{m} \cdot \text{s}^{-1}$)
平均值	10.823 7	10.429 9	0.001 7	0.000 6
标准差	6.519 6	3.998 9	0.909 3	0.434 6
最大值	18.890 0	20.375 0	4.430 0	3.890 0
最小值	0.000 0	1.261 0	-5.380 0	-8.497 0

由表1可见,在装机容量为20 MW的情况下,风机功率最大可达18.890 0 MW,最小为0,平均在10.82 MW附近;通过对风机功率原始数据进行一阶差分统计分析发现,差分后序列平均值为0.001 7,标准差为0.909 3,风机功率数据的总体趋势变化相对平稳。对于较平稳风电功率序列,常规的预测方法容易将风电爬坡事件识别为正常出力事件,进而造成系统内有功功率不平衡,给电网的调度运行带来困难。

3 基于深度自回归模型的风电出力预测

为适应电力系统中风电装机占比快速攀升的形势,近年来基于数值天气预报的风电出力预测准确率得到显著提升,但在强对流等极端场景下的预测水平仍有较大的提升空间。本文结合给定区域内恶劣天气演变历史以及强对流气候持续情况,研究强对流天气下风电爬坡现象,以一定时段的历史风速数据和未来预测风速数据作为协变量,利用深度自回归(deep auto-regressive, DeepAR)模型预测风电出力的概率分布,并有效判断风电爬坡。

深度神经网络在时间序列预测领域已经得到广泛的应用。Flunkert和Gasthaus等人于2019年提出了深度自回归模型^[28],该模型有别于传统的时间序列预测算法,它以时间序列上每个时间断面的数值作为预测目标,根据因变量和协变量的历史数据,计算序列在每个时间点上的概率分布^[28-32];该方

法能够很方便地将相关的物理约束纳入模型考虑。特定场景下概率预测比单个时间断面期望值预测更有意义,这既能反映随机性更贴近物理规律的本质,大幅提升预测精度,也能评估预测的不确定性和相关预测可靠性。

本文定义第 i 个时间序列在 t 时刻的值为 $z_{i,t}$,以 t_0 作为预测开始时刻, $[1, t_0 - 1]$ 为观测区间,假设取值均为已知; $[t_0, T]$ 为预测区间,取值未知; $x_{i,1:T}$ 为各时间断面的协变量,取值同样已知。因此,采用自回归循环神经网络 (recurrent neural network, RNN) 架构的 DeepAR 模型可预测时间序列 $z_{i,t_0:T}$ 的概率分布,即

$$P(z_{i,t_0:T} | z_{i,1:t_0-1}, x_{i,1:T}) \quad (4)$$

假定式(4)可以写成如下似然形式:

$$Q_{\theta}(z_{i,t_0:T} | z_{i,1:t_0-1}, x_{i,1:T}) = \prod_{t=t_0}^T Q_{\theta}(z_{i,t} | z_{i,1:t-1}, x_{i,1:T}) = \prod_{t=t_0}^T \ell(z_{i,t} | \theta(h_{i,t}, \theta)) \quad (5)$$

其中,

$$h_{i,t} = h(h_{i,t-1}, Z_{i,t-1}, X_{i,t}, \theta) \quad (6)$$

式(5)、(6)中,似然函数 $\ell(z_{i,t} | \theta(h_{i,t}, \theta))$ 为一个固定分布,其中的参数由神经网络的输出 $h_{i,t}$ 和函数 $\theta(h_{i,t}, \theta)$ 估计给出; $h_{i,t}$ 为 t 时刻时步自回归 RNN 的状态输出; $h(\cdot)$ 表示神经网络函数,其不指定具体网络结构,可以是 RNN、长短期记忆网络 (long short-term memory, LSTM), 也可以是门控循环单元结构 (gated recurrent unit, GRU); θ 为给定神经网络的超参数。

DeepAR 模型结构如图 6 所示,分为训练和预测部分。在模型训练过程中,每个时步均输入上一时步的隐藏状态 $h_{i,t-1}$ 和观测值 $z_{i,t-1}$,并同步将当前时刻的已知协变量 $x_{i,t}$ 作为输入量。经过神经网络的学习,可以计算优化当前时步的隐藏状态 $h_{i,t}$,进而通过似然函数 $\ell(z_{i,t} | \theta(h_{i,t}, \theta))$ 进行仿射,返回当前时步的概率预测分布,其中 $\theta(\cdot)$ 的具体形式取决于似然函数的选择。最后,通过最大化对数似然函数训练整个网络的参数,优化得到较优的自回归 RNN 函数 $h(\cdot)$ 和映射神经网络 $\theta(\cdot)$ 中的参数,其中 L 为似然函数值。

$$L = - \sum_{i=1}^N \sum_{t=t_0}^T \log \ell(z_{i,t} | \theta(h_{i,t})) \quad (7)$$

当模型训练完成后,即可导入时间序列区间为 $[1, t_0 - 1]$ 的观测数据,得到 h_{i,t_0-1} ,并在区间为

$[t_0, T]$ 时对每一时步依次进行计算,得到概率分布模型 (如高斯分布模型 $\ell(\cdot | \theta_{i,t})$), 进而借助该概率模型随机采样得到一个预测值 $\tilde{z}_{i,t} \sim \ell(\cdot | \theta_{i,t})$, 这个采样值将作为下一个时步的输入。如此不断重复该过程,能够得到 $[t_0, T]$ 时刻的序列预测值。值得一提的是,概率分布预测本质上是预测该时步上数值的概率分布,并且通过设定参数,描述该数值可能的区间,在当前时步上输出一个概率并采样得到数值后,该数值将会作为下一个时步的输入。该数值是随机采样得到的,每次存在一定的差异,这大大增强了模型鲁棒性。

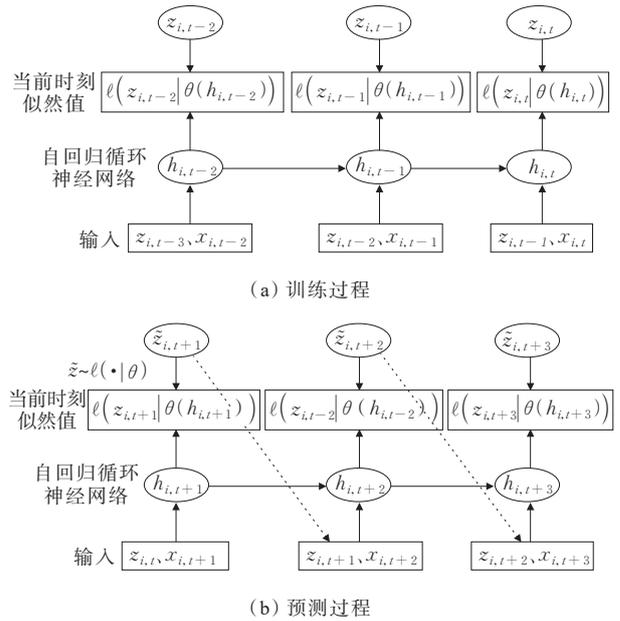


图 6 DeepAR 网络架构示意

Figure 6 DeepAR network architecture

模型中似然函数 $\ell(z_{i,t} | \theta(h_{i,t}, \theta))$ 的选择需要与数据的统计属性相匹配。常用的似然函数形式有高斯、伯努利、beta 以及负二项式分布等。考虑风电爬坡的数值型数据特征,本文采用高斯分布作为似然函数模型对风电爬坡场景下的风电出力进行预测。似然函数模型参数包括数学期望和标准差,即 $\theta = (\mu, \sigma)$, 选择 softplus 作为其激活函数来保证 σ 为正数,其表达式如下:

$$\ell_G(Z | \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(Z - \mu)^2}{2\sigma^2}\right] \quad (8)$$

$$\mu(h_{i,t}) = \mathbf{w}_\mu^\top h_{i,t} + \mathbf{b}_\mu \quad (9)$$

$$\sigma(h_{i,t}) = \log\left[1 + \exp(\mathbf{w}_\sigma^\top h_{i,t} + \mathbf{b}_\sigma)\right] \quad (10)$$

其中,参数 \mathbf{w}_μ^\top 、 \mathbf{b}_μ 、 \mathbf{w}_σ^\top 、 \mathbf{b}_σ 均由自回归循环神经网络训练优化所得。

DeepAR最后能够产生一个可选时间跨度的多步预测结果,其中单时步的预测结果为概率分布,默认输出置信度为50%和90%的概率分布区间,置信度可以在1%~99%之间任意选择。通过给出各个时步的概率分布,既可以综合区间预测结果给出一个时步点预测结果,也可以使用某置信度条件下的概率分布区间来进行预测。

4 考虑风电爬坡的电网智能调度

4.1 预测效果评价指标

为了评价DeepAR模型的预测结果,选取均方根误差(root-mean-square error, RMSE)、均方误差(mean square error, MSE)、平均绝对百分比误差(mean absolute percentage error, MAPE)等作为该模型评价指标,同时也作为其他时序预测模型性能的对标指标。表达式分别如下:

$$e_{\text{RMSE}} = \sqrt{\frac{1}{h} \sum_{i=1}^h [Y(i) - \hat{Y}(i)]^2} \quad (11)$$

$$e_{\text{MSE}} = \frac{1}{h} \sum_{i=1}^h [Y(i) - \hat{Y}(i)]^2 \quad (12)$$

$$e_{\text{MAPE}} = \frac{1}{h} \sum_{i=1}^h \left| \frac{Y(i) - \hat{Y}(i)}{Y(i)} \right| \quad (13)$$

式(11)~(13)中, $\hat{Y}(i)$ 为模型的预测值; $Y(i)$ 为实际观测值; h 为预测区间长度。

同时采用加权分位数损失评估DeepAR模型的预测分布准确度,对于 $[0, 1]$ 内的分位数,加权分位数损失表达式为

$$w_{\text{QL}}[\tau] = 2 \sum_{i,t} Q_{i,t}^{(\tau)} / \sum_{i,t} |y_{i,t}| \quad (14)$$

$$\text{with } Q_{i,t}^{(\tau)} = \begin{cases} (1-\tau) |q_{i,t}^{(\tau)} - y_{i,t}|, & \text{if } q_{i,t}^{(\tau)} > y_{i,t} \\ \tau |q_{i,t}^{(\tau)} - y_{i,t}|, & \text{otherwise} \end{cases}$$

式中, τ 为指定的分位数; $q_{i,t}^{(\tau)}$ 表示分位数为 τ 时的模型预测值。

4.2 风电爬坡特征提取

风电爬坡场景受极端天气影响,依据风速变化随机性发生,DeepAR采用RNN模型为基础的seq2seq架构,能够根据历史风速和风电出力数据实现多步取值的概率分布预测。风电爬坡定义为2个时刻之间风电出力的大比例突变,对其差分数据进行训练或可提取关于风电爬坡的独有特征,由此需对历史风电出力数据进行预处理。

首先对风电出力数据进行间隔为1h的差分,

得到每小时时刻相对于前1h风电出力的变化量 ΔP ,将其作为训练数据,注入训练模型,同一风电场位置下的风速变化数据作为协变量同时参与训练。考虑风速是影响风电出力变化的主要因素之一,某时刻的风速将会对下一时间段的风电出力产生影响,对风速数据同样进行小时间隔的差分处理,同一时刻得到风速和风电出力的小时变化量。风速及风电出力差分结果如图7所示。

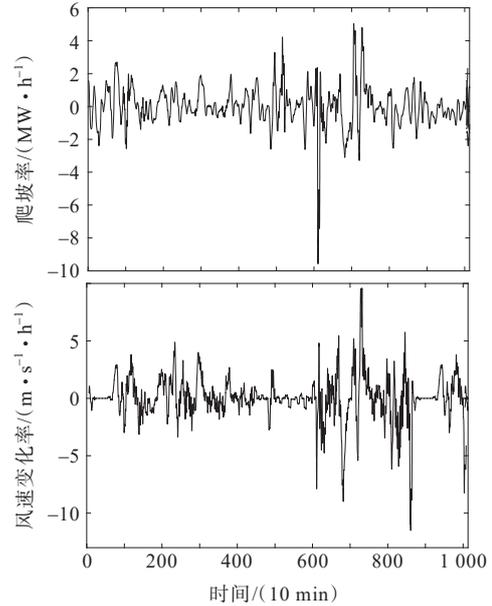


图7 风速及风电出力差分曲线

Figure 7 Differential curves of wind speed and wind power output

由图7可知,风电出力变化同风速变化存在一定的时延,这是由风机发电的物理特性所致。根据风力发电功率和风速的差分曲线,当风速变化率在 $[-5, 5]$ 内小幅度波动时,其均值近似为0,相同时段内风电出力变化率同样波动幅度较为温和;而当风速变化率波动较强时,风电出力变化率也同样出现异常幅度,在多个时间点出现了上、下爬坡事件。

4.3 预测结果

为验证所提DeepAR(diff_power&speed)方法的有效性,选取南方区域某地1月—6月的某风机发电出力数据及同一时期的实测风速数据作为数据集。数据采样间隔为10min,并以5月10日零点为分界点,零点之前数据作为训练集,以5月10、14日当天作为预测区间,每个预测区间长度为144。由实测数据可知这两日均发生了较为明显的风电爬坡事件,其中5月10日晚发生了显著的上、下爬坡事件,5月14日早晨发生了显著的下爬坡事件,如图8所示。

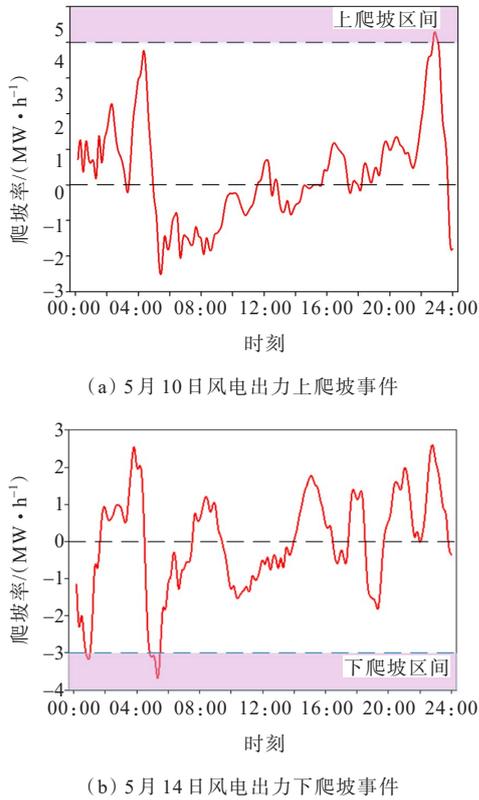


图 8 含爬坡事件的风电出力差分曲线
Figure 8 Differential curves of wind power output with ramp event

TFT (temporal fusion transformers) 模型是一种基于注意力机制的多步时间序列预测模型,本质上也是一个 seq2seq 的模型结构,采用分位数回归,对于时序数据的多步预测任务同样具有很好的效果和解释性,并且也能够通过结合先验已知协变量提取时序特征来优化模型预测效果,其输出结果为各时步上变量点预测值。

由于 TFT 模型预测结果的数值特性,对于所选数据集,以 DeepAR 上侧 50 分位数为点预测值,考虑风速以及风电爬坡特性的影响,选取仅用风机发电出力数据进行训练的 DeepAR(power)模型、以风机发电出力为目标预测序列;风速为协变量进行训练的 DeepAR(power&speed)模型、以风机发电出力差分值为目标预测序列;风速差分值为协变量进行训练的 DeepAR(diff power&speed)模型、以风机发电出力差分值为目标预测序列;风速差分值为协变量进行训练的 TFT(diff power&speed)模型这 4 种模型作为对照。

将所用训练数据分为 20 个 batch 进行训练,模型的整个训练过程共迭代 50 次,以达到较好的拟合状态,同时优化模型的性能和速度。根据上述指标对 5 月 10、14 日的预测结果进行综合评价,结果如

表 2 所示,在对所用数据差分处理前,单风电出力数据参与模型训练并不能达到很高的拟合效果, RMSE 为 1.939 0,50 分位数下的加权分位数损失值为 0.350 5。

表 2 模型预测性能评估

Table 2 Model prediction performance evaluation

模型	e_{RMSE}	e_{MSE}	e_{MAPE}	$w_{QL}[50]$
DeepAR(power)	1.939 0	3.759 8	3.240 1	0.350 5
DeepAR (power&speed)	7.212 2	52.015 7	11.422 0	1.740 8
DeepAR (diff_power&speed)	0.253 5	0.064 3	0.348 0	0.177 5
TFT (diff_power&speed)	0.617 8	0.381 7	0.978 6	0.385 3

由表 3 数据可知,模型虽有一定的预测能力,但并不能有效预测未来一天时间内的风电出力变化;结合风速作为协变量之后的预测效果反而有所退步,各项指标均显著增大。考虑风电出力受多项因素影响,单纯的风速并不能刻画其变化特征,反而会影响模型提取风电爬坡特征的能力。对所用数据进行差分处理后再进行模型训练,可以看到,模型预测能力的各项性能指标均有了显著减小,模型预测能力显著增强,并且较之单风电出力数据训练的模型预测能力更强。RMSE 低至 0.253 5,50 分位数下的加权分位数损失值为 0.177 5,远低于其他模型预测的结果。与之相比,TFT 时序预测模型同样采用差分处理后的风速和风电出力数据,但其模型预测效果并不理想,虽远超 2 个非差分数据训练的 DeepAR 模型,但显然不及差分数据训练的 DeepAR 模型。这也得益于 DeepAR 模型的概率分布预测特性,更大程度上能够捕获风电爬坡特征。

各模型风电出力点预测值与真实观测值曲线如图 9 所示,其中 DeepAR (power) 与 DeepAR (power&speed)模型采用未差分数据进行训练和预测,与未差分的功率真实观测值进行对比;DeepAR (diff_power& speed)和 TFT (diff_power & speed)模型采用差分数据进行训练和预测,因而与差分的功率真实观测值进行对比。图 9 中未差分数据的 3 条曲线相去甚远,预测效果差强人意;而差分数据的 3 条曲线近似黏合,模型展现出良好的预测能力;TFT 模型虽具有一定的预测能力,但在一些波动性强的位置难以有效提取变化特征,较之 DeepAR 模型,预测精度并不理想,且对重要特征的捕捉能力较弱。

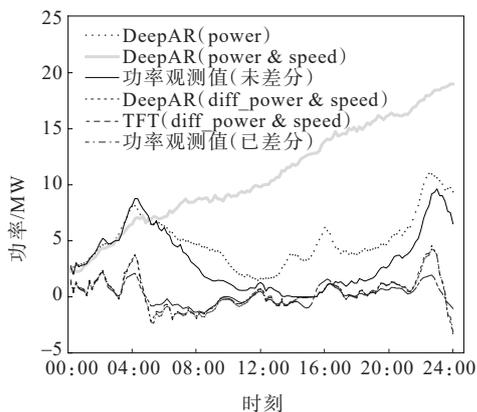


图9 风电出力点预测数据曲线

Figure 9 Wind power output point prediction data curve

另外,DeepAR模型预测的结果实际上是目标序列取值的概率分布,能够得到不同置信度条件下的预测值波动范围,能够更大范围地捕获波动特征。如图10所示,在5月10日DeepAR(diff_power&speed)预测结果中,实际上50分位数下的点预测结果同真实值之间仍有一定的偏差,但其95%置信区间却能够覆盖几乎所有的真实观测值所在位置。由此,电网调度者不但能根据50分位数时的点预测结果来判断是否存在风电爬坡事件,同时,也能够根据该时步的概率分布范围来衡量发生风电爬坡的可能性,提供更多的调度灵活性和可操作性。

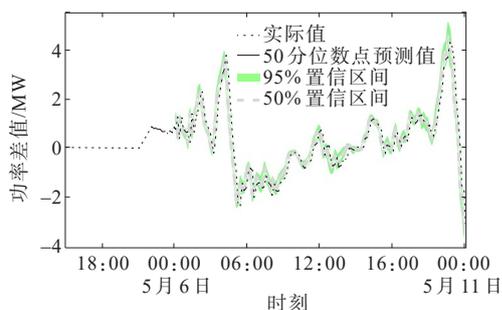


图10 5月10日风电出力差分数据预测曲线

Figure 10 Differential data prediction curve of wind power output on May 10

5 结语

本文针对极端天气下新型电力系统智能化调度方法展开了深入研究,着重针对极端天气下风力发电所存在的风电爬坡事件进行分析。为缓解风电爬坡事件对电网调度运行的影响,本文提出了基于DeepAR模型的风电爬坡事件预测方法,大大提升了风电爬坡事件预测准确性。

1) 本文深入分析了极端天气下未来新型电力系统调度运行面临的挑战;

2) 对大规模风电场风电功率与风速关联性进行了总结,分析了极端天气下的风电爬坡事件对电网安全运行的影响;

3) 对风电爬坡事件进行了分析,总结风电功率与风速的关系,对风电功率数据以及其差分数据的统计特性进行了分析;

4) 结合DeepAR模型对风电爬坡事件进行预测,讨论并总结了结合先验已知风速数据为协变量以及数据差分预处理对于模型预测性能的提升效果,并结合风电站实测数据对所提方法进行了验证,通过与TFT模型的对比分析发现,所提方法能有效捕捉风电爬坡事件特性,并对未来一天时间内的风电出力变化进行预测,精准定位风电爬坡事件的出现。

对于本文提出的风电爬坡事件预测方法,虽为应对极端天气下未来新型电力系统调度运行面临的挑战有所裨益,但距离投入实际生产应用仍需进一步对模型的训练和预测速度进行评价和改进,今后的工作也将围绕这个部分进行深入的研究和拓展。

参考文献:

- [1] 张东英,代悦,张旭,等.风电爬坡事件研究综述及展望[J].电网技术,2018,42(6):1783-1792.
ZHANG Dongying, DAI Yue, ZHANG Xu, et al. Review and prospect of research on wind power ramp events[J]. Power System Technology, 2018, 42(6): 1783-1792.
- [2] HOLTINEN H, MEIBOM P, ORTHS A, et al. Impacts of large amounts of wind power on design and operation of power systems, results of IEA collaboration [J]. Wind Energy, 2011, 14(2): 179-192.
- [3] 谷兴凯,范高锋,王晓蓉,等.风电功率预测技术综述[J].电网技术,2007,31(增刊2):335-338.
GU Xingkai, FAN Gaofeng, WANG Xiaorong, et al. Summarization of wind power prediction technology[J]. Power System Technology, 2007, 31(sup 2): 335-338.
- [4] 宋家康,赵建勇,孙海霞,等.基于多目标协同训练的风电功率预测提升算法[J].电力工程技术,2023,42(6): 232-240.
SONG Jiakang, ZHAO Jianyong, SUN Haixia, et al. Wind power prediction and improvement algorithm based on multi-objective col-laborative training[J]. Electric Power Engineering Technology, 2023, 42(6): 232-240.
- [5] 郭燕玲,赵晶,周林,等.山东半岛风电爬坡事件的识别

- 与天气分析研究[J].气候与环境研究,2017,22(1):97-107.
- GUO Yanling, ZHAO Jing, ZHOU Lin, et al. A study on the identification and synoptic analysis of wind ramp events in shandong peninsula[J]. Climatic and Environmental Research, 2017, 22(1): 97-107.
- [6] 丁立, 乔颖, 鲁宗相, 等. 高比例风电对电力系统调频指标影响的定量分析[J]. 电力系统自动化, 2014, 38(14): 1-8.
- DING Li, QIAO Yin, LU Zongxiang, et al. Impact on frequency regulation of power system from wind power with high penetration[J]. Automation of Electric Power Systems, 2014, 38(14): 1-8.
- [7] 迟永宁, 刘燕华, 王伟胜, 等. 风电接入对电力系统的影响[J]. 电网技术, 2007, 31(3): 77-81.
- CHI Yongning, LIU Yanhua, WANG Weisheng, et al. Study on impact of wind power integration on power system[J]. Power System Technology, 2007, 31(3): 77-81.
- [8] 李媛媛, 邱跃丰, 马世英, 等. 风电机组接入对系统小干扰稳定性的影响研究[J]. 电网技术, 2012, 36(8): 50-55.
- LI Yuanyuan, QIU Yuefeng, MA Shiyong, et al. Impact of grid-connected wind turbine generators on small signal stability of power grid[J]. Power System Technology, 2012, 36(8): 50-55.
- [9] 刘洪波, 刘永发, 任阳, 等. 高风电渗透率下考虑系统风电备用容量的储能配置[J]. 发电技术, 2024, 45(2): 260-272.
- LIU Hongbo, LIU Yongfa, REN Yang, et al. Energy storage configuration considering the system wind power reserve capacity under high wind power permeability[J]. Power Generation Technology, 2024, 45(2): 260-272.
- [10] 戴建军, 王明明, 游云汉, 等. 基于时间敏感网络的风电主动支撑和运行控制网络技术研究[J]. 中国电力, 2023, 56(10): 53-61.
- DAI Jianjun, WANG Mingming, YOU Yunhan, et al. Research on active support and operation control network of wind turbine based on time-sensitive network[J]. Electric Power, 2023, 56(10): 53-61.
- [11] ZHENG H, KUSIAK A. Prediction of wind farm power ramp rates: a data-mining approach[J]. Journal of Solar Energy Engineering, 2009, 131(3): 376-385.
- [12] CUI M, ZHANG J, FLORITA A R, et al. An optimized swinging door algorithm for identifying wind ramping events[J]. IEEE Transactions on Sustainable Energy, 2015, 7(1): 150-162.
- [13] 崔明建, 孙元章, 柯德平. 基于原子稀疏分解和BP神经网络的风电功率爬坡事件预测[J]. 电力系统自动化, 2014, 38(12): 6-11+26.
- CUI Mingjian, SUN Yuanzhang, KE Deping. Wind power ramp events forecasting based on atomic sparse decomposition and BP neural networks[J]. Automation of Electric Power Systems, 2014, 38(12): 6-11+26.
- [14] 马欢, 李常刚, 刘玉田. 风电爬坡事件对系统运行充裕性的影响评估[J]. 电力系统自动化, 2017, 41(4): 41-47.
- MA Huan, LI Changgang, LIU Yutian. Assessing impact of wind power ramp events on operation adequacy of power systems[J]. Automation of Electric Power Systems, 2017, 41(4): 41-47.
- [15] 何川, 刘天琪, 胡晓通, 等. 基于超短期风电预测和混合储能的风电爬坡优化控制[J]. 电网技术, 2017, 41(3): 782-790.
- HE Chuan, LIU Tianqi, HU Xiaotong, et al. Optimal control of wind ramp based on very short-term wind forecast and hybrid ESS[J]. Power System Technology, 2017, 41(3): 782-790.
- [16] KAMATH C. Understanding wind ramp events through analysis of historical data[C]// IEEE Transmission and Distribution Conference and Exposition, New Orleans, LA, USA, 2010.
- [17] 茹瑶, 赵永宁, 叶林, 等. 超短期LSTM风电功率预测模型的混合专家模块化代理解释方法[J]. 电力建设, 2024, 45(11): 114-124.
- RU Yao, ZHAO Yongning, YE Lin, et al. Modular surrogate inter-pretation method based on decision tree mixture of experts for ultra-short-term LSTM wind power forecasting model[J]. Electric Power Construction, 2024, 45(11): 114-124.
- [18] 夏雪, 戚永志, 刘玉田. 风机爬坡功率的有限度控制策略[J]. 电力系统自动化, 2014, 38(20): 26-32.
- XIA Xue, QI Yongzhi, LIU Yutian. Finite control strategy for wind turbine ramping power[J]. Automation of Electric Power Systems, 2014, 38(20): 26-32.
- [19] 岳晓宇, 彭显刚, 林俐. 鲸鱼优化支持向量机的短期风电功率预测[J]. 电力系统及其自动化学报, 2020, 32(2): 146-150.
- YUE Xiaoyu, PENG Xiaogang, LIN Li. Short-term wind power forecasting based on whales optimization algorithm and support vector machine[J]. Proceedings of the CSU-EPSC, 2020, 32(2): 146-150.
- [20] 杨宏, 闫玉杰, 王瑜. Beta分布在风电预测误差模型中的适用性[J]. 电测与仪表, 2020, 57(11): 37-41.
- YANG Hong, YAN Yujie, WANG Yu. Applicability of beta distribution on wind power forecast error modeling[J]. Electrical Measurement & Instrumentation, 2020, 57(11): 37-41.
- [21] 张丁予, 解佗, 马易晨, 等. 基于爬坡特征识别的短期风电功率集成预测方法[J]. 电网与清洁能源, 2024, 40(8): 128-133.
- ZHANG Dingyu, XIE Tuo, MA Yichen, et al. Research on integrated short term wind power prediction methods based on climbing feature recognition[J]. Power System

- and Clean Energy, 2024, 40(8): 128-133.
- [22] 张野,李凤婷,张高航,等.考虑风电爬坡备用需求的风电高渗透电力系统优化调度方法[J].电力系统保护与控制,2024,52(23):95-106.
ZHANG Ye, LI Fengting, ZHANG Gaohang, et al. Optimization and scheduling methods for wind power high-penetration power system-considering wind power ramping reserve requirements[J]. Power System Protection and Control, 2024, 52(23): 95-106.
- [23] 陈天阳,钱政,荆博,等.基于K-means++与ELM的短期风电功率预测模型研究[J].电测与仪表,2024,61(6):45-50.
CHEN Tianyang, QIAN Zheng, JING Bo, et al. Short-term wind power forecasting based on K-means++ and ELM [J]. Electrical Measurement & Instrumentation, 2024, 61 (6): 45-50.
- [24] 杨茂,董昊.基于数值天气预报风速和蒙特卡洛法的短期风电功率区间预测[J].电力系统自动化, 2021, 45 (5): 79-85.
YANG Mao, DONG Hao. Short-term wind power interval prediction based on wind speed of numerical weather prediction and monte carlo method[J]. Automation of Electric Power Systems, 2021, 45(5): 79-85.
- [25] 杨健,徐思卿,姜尚光,等.基于动态时间规整的风电功率爬坡滚动修正模型[J].电力系统自动化, 2021, 45 (16): 152-159.
YANG Jian, XU Siqin, JIANG Shangguang, et al. Rolling correction model of ramp for wind power based on dynamic time warping[J]. Automation of Electric Power Systems, 2021, 45(16): 152-159.
- [26] 李彬,彭曙蓉,彭君哲,等.基于深度学习分位数回归模型的风电功率概率密度预测[J].电力自动化设备,2018, 38(9):15-20.
LI Bin, PENG Shurong, PENG Junzhe, et al. Wind power probability density forecasting based on deep learning quantile regression model[J]. Electric Power Automation Equipment, 2018, 38(9): 15-20.
- [27] 施进炜,张程,原冬芸.基于数据修正的概率稀疏自注意短期风电功率预测[J].智慧电力,2023,51(10):54-61.
SHI Jinwei, ZHANG Cheng, YUAN Dongyun. Short-term wind power prediction based on data correction with probabilistic sparse self-attention[J]. Smart Power, 2023, 51(10): 54-61.
- [28] 何旭辉,段泉成,严磊.基于DeepAR的短期风速概率预测[J].铁道学报, 2023, 45(7): 152-160.
HE Xuhui, DUAN Quancheng, YAN Lei. Short-term wind speed probabilistic prediction model using DeepAR[J]. Journal of the China Railway Society, 2023, 45(7): 152-160.
- [29] 朱刚,李文,杜守国,等.基于深度学习模型DeepAR的时间序列预测及应用实例[J].电子商务,2020(7):83-86.
ZHU Gang, LI Wen, DU Shouguo, et al. Time series forecasting and application examples based on deep learning model DeepAR[J]. E-Business Journal, 2020(7): 83-86.
- [30] 史永胜,任嘉睿,李锦,等.基于DeepAR与特征选择的锂离子电池在线状态估计[J].电源学报, 2023, 21(2): 163-171.
SHI Yongsheng, REN Jiarui, LI Jin, et al. Online state estimation of lithium-ion batteries based on DeepAR and feature selection[J]. Journal of Power Supply, 2023, 21(2): 163-171.
- [31] 李天玉.基于sDTW-DeepAR的地面沉降预测研究[D].广州:广东工业大学,2022.
LI Tianyu. Research on ground subsidence prediction based on sDTW-DeepAR[D]. Guangzhou: Guangdong University of Technology, 2022.
- [32] 闫龙川,李妍,宋浒,等.基于Prophet-DeepAR模型的Web流量预测[J].广西师范大学学报(自然科学版), 2022, 40(3): 172-184.
YAN Longchuan, LI Yan, SON Hu, et al. Web traffic prediction based on Prophet-DeepAR model[J]. Journal of Guangxi Normal University (Natural Science Edition), 2022, 40(3): 172-184.