

含光储充的低压配电网净负荷区间预测方法

崔威^{1†}, 王俊龙¹, 王艺峰¹, 王冰², 陈磊², 董斌³

(1. 国网河北省电力有限公司, 河北 石家庄 050000; 2. 国网河北省电力有限公司衡水供电分公司, 河北 衡水 053000; 3. 河南许继仪表有限公司, 河南 许昌 461000)

摘要: 准确的净负荷预测是有源低压配电网优化调度的依据。随着光伏渗透率的提高和储能、电动汽车充电站的普及, 低压配电网净负荷的波动性和不确定性增大, 常规确定性点负荷预测不能满足台区调度的需要。针对小数据集下净负荷不确定性预测问题, 提出一种基于宽度学习的含光储充台区的净负荷区间预测方法。首先, 通过变分模态分解算法将非平稳的净负荷数据分解为一系列相对平稳的模态分量, 从而降低数据的复杂性; 然后, 这些模态分量通过适用于小规模数据集的宽度学习系统算法实现点预测; 最后, 在点预测的基础上建立一种区间优化模型, 将点预测模型转换为区间预测模型。仿真实验表明, 所提算法能够实现较精确的净负荷区间预测; 与其他算法相比, 在相同的置信区间要求下预测的区间更窄。

关键词: 净负荷; 区间预测; 低压配电网; 宽度学习系统; 变分模态分解

中图分类号: TM715

文献标识码: A

Interval Prediction for Net Load in Low-Voltage Distribution Areas with Integrated Photovoltaic, Energy Storage, and Charging Station

CUI Wei^{1†}, WANG Junlong¹, WANG Yifeng¹, WANG Bing², CHEN Lei², DONG Bin³

(1. State Grid Hebei Electric Power Co., Ltd., Shijiazhuang, Hebei 050000, China;

2. Hengshui Power Supply Branch of State Grid Hebei Power Co., Ltd., Hengshui, Hebei 053000, China;

3. Xuji Metering Co., Ltd., Xuchang, Henan 461000, China)

Abstract: Accurate net load prediction serves as the foundation for optimal scheduling in active low-voltage distribution networks. With the increasing penetration of photovoltaic (PV) systems and the widespread adoption of energy storage and electric vehicle charging stations, the volatility and uncertainty of net load in low-voltage distribution networks have significantly increased. Traditional deterministic point load forecasting methods are insufficient to meet the scheduling needs of feeder-level management. To address the issue of net load uncertainty prediction in the context of small datasets, this study proposes an interval forecasting method for net load in feeder areas with integrated PV, storage, and charging systems, based on broad learning. First, the variational mode decomposition (VMD) algorithm is employed to decompose the non-stationary net load data into a series of relatively stationary modal components, thereby reducing data complexity. Subsequently, these modal components are subjected to point forecasting using the broad learning system (BLS) algorithm, which is well-suited for small-scale datasets. Finally, an interval optimization model is constructed based on the point forecasting results, transforming the point forecasting model into an interval forecasting model. Simulation experiments demonstrate that the proposed method achieves accurate interval forecasting of net load. Compared to other algorithms, the proposed method produces narrower prediction intervals under the same confidence level requirements.

收稿日期: 2023-06-20

基金项目: 国网河北省电力有限公司科技项目(5204HS230008); 国家电网有限公司科技资助项目(5400-202313567A-3-2-ZN)

作者简介: 崔威(1986—), 男, 河北保定人, 硕士, 高级工程师, 研究方向: 电力市场营销及其数据智能化处理。

† 通信联系人, E-mail: wangbinghbsg@126.com

Key words: net load; interval prediction; low-voltage distribution substation; broad learning system; variational mode decomposition

随着全球能源结构转型和可持续发展战略的推进,含有可再生能源和分布式发电资源的新型电力系统正逐渐成为能源领域的研究热点^[1]。在众多的可再生能源中,光伏能源因其清洁、低碳的特性备受青睐。与此同时,电动汽车作为新能源汽车的代表,也在逐步替代传统燃油车辆,成为推动交通领域绿色转型的重要力量^[2]。在这样的背景下,光伏能源、储能和电动汽车在低压配电网中的比例不断提高,对其运行和管理提出了新的挑战,其中净负荷预测的重要性日益凸显^[3]。

集成光伏—储能—充电设施的低压台区净负荷预测,即将光伏、储能和电动汽车充电站等因素考虑在内的负荷预测,是有源低压台区优化调度的基础,是确保台区稳定经济运行的关键技术之一^[4]。随着可再生能源的大规模接入和电力市场的发展,含光储充的净负荷变得更加复杂和不确定。为了描述含光储充的净负荷的不确定性,通常采用概率预测(Probability Prediction, PP)和区间预测(Interval Prediction, IP)的方法^[5]。概率预测方法通过估计未来负荷水平的概率分布,为每个可能的负荷值提供一个概率值。这种方法可以量化预测的不确定性,并且可以用来计算不同负荷水平的超过概率或发生频率,但往往需要大量的数据进行计算,并且计算耗时较长^[6]。区间预测方法则提供了一个负荷值的预期范围,通常以置信区间的形式表示^[7]。相比于概率预测,区间预测计算的数据量较少,计算复杂度较低,但预测表现受区间优化的影响^[8]。

考虑到光伏和电动汽车的波动性导致电力系统低压台区净负荷的非平稳性增加,通过采用信号分解技术简化净负荷数据的复杂度。现有的研究中,通常采用的信号分解技术包括小波变换(Wavelet Transform, WT)、经验模态分解(Empirical Mode Decomposition, EMD)、变分模态分解(Variational Mode Decomposition, VMD)等^[9]。在预测模型方面,随着人工智能技术的发展,基于机器学习的预测方法开始在净负荷预测中得到广泛应用。这些方法包括支持向量机(Support Vec-

tor Machine, SVM)、极限学习机(Extreme Learning Machine, ELM)、卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)等^[10]。除了上述的几种模型,宽度学习系统(Broad Learning System, BLS)适用于小规模数据集,并且具有计算效率高的优点,在时间序列预测方面也有很多研究和应用^[11]。文献[12]提出一种基于鲁棒稀疏 BLS 的预测方法,通过正则法提升了 BLS 的鲁棒性。文献[13]提出一种基于多模态动态潜变量 BLS 的负荷多步预测方法,动态潜变量建模提升了 BLS 的预测精度。文献[14]通过结构化流形学习提取混沌时间序列数据特征用于 BLS 的特征映射环节,从而提升了 BLS 的预测性能。

本文考虑到含光伏和充电桩的低压台区净负荷的波动性和不确定性,建立了一种基于宽度学习的区间预测(Broad Learning System-based Interval Prediction, BLS-IP)方法。BLS-IP 首先通过变分模态分解算法作为信号分解模型解决净负荷的非平稳性问题,简化净负荷数据的复杂度。然后, BLS-IP 通过 BLS 作为预测模型实现精准确定性点预测。接着,建立一种区间构造方法,并优化区间的上下界,使得在置信水平下的预测区间尽可能窄。最后,通过实际案例进行仿真实验,实验结果验证了所提方法的有效性。

1 净负荷的点预测模型

1.1 信号分解

考虑到光伏、储能和汽车充电站对净负荷造成的非平稳性,本文采用 VMD 算法对净负荷数据进行分解,以解决净负荷的非平稳性问题。假设一段长度为 n 的净负荷表示为: $X(t) = \{x_1, x_2, \dots, x_n\}$, 其中 $t = 1, 2, \dots, N$, 则通过 VMD 分解为 K 个模态后,数据 X 与分解的模态分量 IMF 的关系表示为:

$$X(t) = \sum_{i=1}^K \text{IMF}_i(t) + \text{res} \quad (1)$$

其中 t 表示采样时刻; res 表示噪声。

为了求解上述模态分量, VMD 通过构造以下目标函数进行求解:

$$\begin{cases} \min_{\{IMF_i\}_{\{w_i\}}} \left\{ \sum_K \left\| d_t \left[(\delta(t) + \frac{j}{\pi t}) \otimes \right. \right. \right. \\ \left. \left. \left. IMF_i(t) \right] e^{-jw_i t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_K IMF_i(t) = X(t) \end{cases} \quad (2)$$

其中 $\delta(t)$ 表示单位脉冲函数; j 是虚数单位; π 表示圆的周长与直径之比的常数; $\otimes$ 表示卷积; e 表示自然对数的底数; w_i 表示 IMF_i 的中心频率; ∂ 表示偏导; $\| \cdot \|_2^2$ 表示 L2 范数。

上述目标函数可以通过拉格朗日乘子法进行求解, 从而将原始净负荷数据 X 分解为 K 个模态分量 $IMF = \{IMF^1, \dots, IMF^K\}$ 。

1.2 点预测

为了建立考虑多频率尺度特征的点预测模型, 首先, 净负荷数据 X 通过 VMD 分解, 得到 K 个模态分量 $\{IMF^1, \dots, IMF^K\}$ 。这些模态分量代表了净负荷数据在不同频率尺度上的特征, 有助于捕捉数据的多层次动态行为。然后, X 作为 IMF^0 与 VMD 分解后得到的 K 个模态分量组合成新的多模态数据 $Z = [IMF^0, IMF^1, \dots, IMF^K]$ 。这种组合方式能够在保留原始净负荷数据全局特征的基础上, 引入不同频率尺度的局部特征, 从而为点预测模型提供更丰富的输入信息。

点预测的任务是在时刻 η , 通过长度为 h 个历史时刻的数据, 预测未来第 θ 时刻的数据。点预测任务的数学表达式为:

$$X_{\eta+\theta} = f_{\text{pre}}(Z_{\eta}, Z_{\eta-1}, \dots, Z_{\eta-h+1}) \quad (3)$$

其中 f_{pre} 表示预测模型。

考虑到深层神经网络结构复杂, 所需调节的参数较多, 并且超参数调整过程极为耗时, 往往难以达到所需的预测精度。此外, 本文的适用场景为小规模数据集, 因此, 本文选择 BLS 作为预测模型。预测模型的输入构造为 $P = \{p_1, p_2, \dots, p_m\}$, 其中 $p_i = [Z_i, Z_{i+1}, \dots, Z_{i+h-1}]$, $m = \eta - h + 1$, 其模型架构可参照图 1 所示, 其主要步骤如下。

Step1: 输入数据映射到特征节点。假设存在 n_{win} 组特征节点, 输入数据映射到第 j 组特征节点的数学表达式为:

$$F_j = \varphi(PW_j^{\text{fea}} + \chi_j), \quad j = 1, 2, \dots, n_{\text{win}} \quad (4)$$

其中 F_j 表示第 j 组特征节点的输出; φ 表示激活函数; W_j^{fea} 表示由输入节点映射到第 j 组的特征节点的权重矩阵; χ_j 表示第 j 组映射过程的偏重。

Step2: 特征节点映射到增强节点。假设存在 n_{enhan} 个增强节点, 则特征节点映射到增强节点的数学表达式为:

$$\begin{aligned} H_{\text{enhan}} &= \xi(FW_{\text{enhan}} + \chi_{\text{enhan}}), \\ h &= 1, 2, \dots, n_{\text{enhan}} \end{aligned} \quad (5)$$

其中 H_{enhan} 表示增强节点的输出; ξ 表示激活函数; W_{enhan} 表示所有特征节点映射到增强节点的权重矩阵; $\chi_{\text{enhan}j}$ 表示此映射过程的偏重。

Step3: 特征节点和增强节点映射到输出节点。

$$X_{\eta+\theta} = [F \mid H_{\text{enhan}}] W_{\text{output}} \quad (6)$$

其中 W_{output} 表示特征节点和增强节点映射到输出节点 $X_{\eta+\theta}$ 的权重矩阵。

2 净负荷的区间预测模型

2.1 区间预测原理

区间预测技术涉及在没有明确上限或下限的情况下估计不确定量的界限, 也称为下上限估计。然而, 区间预测缺少训练标签, 因此在区间预测时需要构造合理的预测区间。假设预测的真实值是 Y , 则区间构造方法为:

$$\begin{cases} Y^u = Y + w_u \\ Y^l = Y - w_l \end{cases} \quad (7)$$

其中 Y^u 和 Y^l 表示预测的上边界和下边界。 w_u 和 w_l 表示重构区间的宽度。

区间预测与区间构造相互响应。理想状况下, 预测的区间会收敛于构造的区间。本文采用 BLS 作为预测模型, 在 BLS 模型中, 仅需要在上一环节的 Step3 进行伪逆运算, 因此可以在精确的点预测的基础上实现区间预测的增量优化调整。本文所提的区间预测的模型如图 1 所示。

2.2 所提区间优化方法

区间构造的目的是为区间预测提供有监督学习方式的标签。区间构造的估计边界值 $[Y^l, Y^u]$ 应该尽可能地包含真实的预测值 Y , 同时最小化重构区间的宽度。因此, 区间构造的优化目标函数设置为:

$$f_{\text{cost}} = (Y_i^u - U_i)^2 + (Y_i^l - L_i)^2 \quad (8)$$

其中 L_i 和 U_i 分别为预测模型的第 i 个下界输出和上界输出。




图 1 基于 BLS 的区间预测框架

在区间构造的条件下,采用预测区间覆盖率 (PI Coverage Probability, PICP) 和预测区间平均宽度 (PI Normalized Root-mean-square Width, PINRW) 对预测区间进行评价,从而达到预测的区间收敛于构造的区间的目的。PICP 和 PINRW 的定义如下:

$$PICP = \frac{1}{n} \sum_{i=1}^n C_i, \quad (9)$$

$$C_i = \begin{cases} 1, & y_i \in [L_i, U_i] \\ 0, & y_i \notin [L_i, U_i] \end{cases}$$

$$PINRW = \frac{1}{R} \sqrt{\frac{1}{n} \sum_{i=1}^n (U_i - L_i)^2} \quad (10)$$

PICP 和 PINRW 都是区间预测的重要评价指标,但是这两个指标都不能充分反映预测区间的合理性。在实际过程中,PICP 和 PINRW 存在矛盾。当 PICP 较高时可能导致 PINRW 较大,而当减小 PINRW 时又将导致 PICP 减小。因此,用覆盖宽度准则 (Coverage Width Criterion, CWC) 来衡量这两个指标。根据定义,CWC 是由 PICP 和 PINRW 决定的两个术语的乘积,其中 PICP 越高, PINRW 越小,产生的 CWC 越小,表明预测区间具有更好的合理性。CWC 的数学表达如下所示:

$$CWC = \frac{1 + \eta_2 \cdot PINRW}{1 + \gamma(PICP) e^{-\eta_1 (PICP - \mu)}} \quad (11)$$

$$\gamma(PICP) = \begin{cases} 0, & PICP \geq \mu \\ 1, & PICP < \mu \end{cases} \quad (12)$$

其中 η_1 是对 PICP 的惩罚因子, η_2 用于线性增加 PINRW 的影响, μ 用于预测 PINC 的值, $\gamma(PICP)$ 是一个阶梯函数,当 PICP 小于 μ 时, PICP 的惩罚将被执行。

在区间构造的条件下,预测区间与构造区间的拟合误差表示为:

$$\begin{cases} e_u = \frac{\sum_{i=1}^n (Y_i^u - U_i)}{n} \\ e_l = \frac{\sum_{i=1}^n (Y_i^l - L_i)}{n} \end{cases} \quad (13)$$

其中 e_l 和 e_u 分别为下界和上界的平均拟合误差。

为了优化构造的区间,区间估计的宽度应该在每次训练结束后更新为平均拟合误差 e_l 和 e_u 的 α 倍,其计算过程如下:

$$\begin{cases} \Delta w_u = k_1 \cdot (w_u - e_u \cdot \alpha) \\ \Delta w_l = k_1 \cdot (w_l - e_l \cdot \alpha) \end{cases} \quad (14)$$

$$\begin{cases} w_u \leftarrow w_u - \Delta w_u \\ w_l \leftarrow w_l - \Delta w_l \end{cases} \quad (15)$$

其中 k_1 表示区间宽度的调节更新速度。PICP 为了满足预先设置的预测区间名义置信度 (PI Nominal Confidence, PINC),假设 α 为使 PICP 在训练过程中满足 PINC 的系数;因此,可以利用这两个指标的差值来优化每次训练后的 α ,这也是保证 PICP 合格的一个有力约束。调整过程描述如下:

$$\begin{cases} \Delta \alpha = k_2 \cdot (PICP - PINC_{\text{train}}) \\ \alpha \leftarrow \alpha - \Delta \alpha \end{cases} \quad (16)$$

其中 $PINC_{\text{train}}$ 是预先分配给训练的 PINC, k_2 表示调整 α 的更新速度。

3 应用及验证

本文选取加州大学圣地亚哥分校提供的公开数据集,以验证所提出模型的有效性^[15]。该数据集采集自 Trade Street Warehouse 的一栋建筑,其数据采集频率为每 15 分钟一次。本文专注于分析所选建筑与主电网之间的净负荷数据,该数据通过从总负荷中扣除光伏发电、电池储能以及电动汽车

充电站的输出得到。

3.1 点预测结果

在本文中,鉴于包含光伏、储能和电动汽车充电站的净负荷数据表现出显著的动态波动性,且在短时间尺度内数据特征具有相似性,而在长时间尺度内则表现出较大的差异性,我们决定选取一个月内的规模数据作为模型训练的样本集,并开展提前 24 步的预测工作,即对接下来 6 小时内的净负荷数值进行预测。鉴于本文所处理的数据集规模较小,深度学习算法可能并不适宜。因此,本文选取了 BLS、Elman 神经网络、反向传播神经网络(Back Propagation Neural Network, BPNN)和 KELM 作为对比模型。在这些模型中,每一层神经元的节点数量通过网格搜索法在 20 至 100 的范围内进行优化选择,同时选用径向基函数(Radial Basis Function, RBF)作为核函数,并设置迭代次数为 200,以确保模型的收敛性和预测效果。

本文采用均方根误差(Root Mean Square Error, RMSE),平均绝对误差(Mean Absolute Error, MAE)和对称平均绝对百分比误差(Symmetric Mean Absolute Percentage Error, SMAPE)进行点预测的评价,它们的定义如下所示。在所有公式中, b_i 表示真实值, b_i^+ 表示预测值, n_b 表示 b 的长度。

1)RMSE 定义为:

$$RMSE = \sqrt{\frac{1}{n_b} \sum_{i=1}^{n_b} (b_i - b_i^+)^2}$$

(17)

其中 RMSE 测量预测值与实际观测值之间的误差。RMSE 值越小,表示预测模型的精度越高。

2)MAE 定义如下:

$$MAE = \frac{1}{n_b} \sum_{i=1}^{n_b} |b_i - b_i^+|$$

(18)

其中 MAE 对异常值不太敏感。MAE 越小,表示预测准确性越高。

3)SMAPE 定义如下:

$$SMAPE = \frac{1}{n_b} \sum_{i=1}^{n_b} \frac{|b_i - b_i^+|}{(|b_i| + |b_i^+|)/2}$$

(19)

其中 SMAPE 有助于评估预测模型中正错误和负错误的一致性和平衡性。SMAPE 越小,表示预测准确性越高。

表 1 展示了不同预测模型在进行净负荷提前 24 步点预测时的评价结果。从评价结果可以看

出,BLS 模型在 RMSE、MAE 和 SMAPE 等评价指标上的表现优于其他模型,具有最小的误差值,表明其预测精度最高。这一结果主要归功于 BLS 模型采用岭回归伪逆算法来确定网络权重,这种方法能够有效降低模型过拟合的风险,并增强模型对新数据的泛化能力。通过这种方式,BLS 模型在处理净负荷预测问题时展现出了较高的预测精度。

表 1 点预测模型结果

方法	RMSE	MAE	SMAPE
BLS	3.8022	2.7742	0.2686
Elman	4.6187	3.4978	0.3457
BP	4.7453	3.6225	0.3502
KELM	4.7696	3.7553	0.3739

图 2 展示了利用不同预测模型进行净负荷提前 24 步点预测的结果。通过对比分析图 2 中的预测曲线与真实负荷曲线,可以发现 BLS 模型所预测的净负荷曲线与真实负荷曲线之间的拟合度最佳。例如,在第 384 至第 576 个采样点的区间内,原始负荷曲线的波形性相较于之前有所减弱。在这一区间,唯有 BLS 模型的预测曲线能够准确地反映出真实负荷的波动特征,而其他模型的预测结果则未能精确捕捉到这一变化,这可能是由于这些模型存在过拟合的问题。因此,BLS 模型在预测净负荷方面表现出了较高的准确性。

3.2 区间预测结果

在上一节所讨论的点预测结果分析中,BLS 模型展现出了最高的预测精度。基于此,本节将在 BLS 点预测成果的基础上,运用本文提出的区间预测方法来实现对未来负荷的区间预测。为了进行比较分析,所采用的对比方法通过统计学手段来确定预测区间的上界和下界,同时,两种预测方法的 PINC 均设定为 90%,以确保预测结果的可靠性和一致性。通过这种对比,旨在进一步验证所提出区间预测方法的有效性和适用性。

依据式(9)至式(11)对两种区间预测方法进行评估,所得结果列于表 2 中。从表 2 的数据分析可见,本文所提出的区间预测方法在 PICP、PINRW 以及 CWC 等评价指标上均优于传统的统计学方法。这一结果表明,本文所提出的区间预测方法在实际应用中更为合理,能够提供更为准确且具有实

用价值的净负荷预测区间。




图 2 提前 24 步的点预测的对比结果

表 2 区间预测评价结果

方法	PICP	PINRW	CWC
BLS-PI	0.9002	0.0297	1.1782
统计学	0.8998	0.0662	2.6582

图 3 展示了区间预测方法的对比结果。通过细致观察图中的数据,可以发现本文提出的区间预测方法所形成的预测区间相较于传统统计方法而言,上下界之间的距离更为紧凑,即区间宽度更窄。这一现象表明,与统计学方法相比,本文所采用的区间预测技术能够以更高的精度界定未来净负荷的可能变化范围,从而为电力系统的调度和管理提供更为精确的参考依据。

本文提出的区间预测方法的训练过程如图 4 所示。在本文所设定的 90% 置信区间下,区间构造的 PICP 在训练进行到第 100 轮时,逐渐稳定并

接近预设的目标置信水平 PINC,同时 α 值也趋于稳定。这一现象表明,区间预测的边界值已经通过优化过程达到了预期的统计特性。因此,可以得出结论,本文所提出的区间预测方法是基于统计计算结果的有效预测手段。




图 3 区间预测的对比结果




图 4 本文所提方法的区间预测训练过程

4 结 论

为了给包含光伏发电和电动汽车充电站在内的电力系统提供未来净负荷的精确数值预测,以便更好地制定储能设备和火力发电等资源的优化调度方案,提出了一种新颖的基于宽度学习的区间预测方法。通过实际应用所得到的结果,本文得出以下重要结论:

- 1) 在处理小规模数据集的情况下,BLS 模型展现出了卓越的泛化能力,其点预测的准确度在所有比较模型中表现最佳。

2) 通过对预测区间进行优化和重构,本文所提出的区间预测方法能够有效地缩减预测区间的宽度。这一改进对于提高在不确定性条件下进行优化调度的经济性具有重要意义。

在未来的研究工作中,本文计划专注于自适应局部区间预测的探索。具体而言,研究将致力于在保持整体预测置信区间要求不变的大前提下,针对不同的局部时刻采用差异化的置信区间设置。通过这种方式,旨在实现对预测区间宽度的优化,进一步提升预测模型的精确度和适用性。

参考文献

[1] 孔祥玉, 马玉莹, 艾芊, 等. 新型电力系统多元用户的用电特征建模与用电负荷预测综述[J]. 电力系统自动化, 2023, 47(13): 2—17.

[2] WAZIRALI R, YAGHOUBI E, ABUJAZAR M S S, et al. State-of-the-art review on energy and load forecasting in microgrids using artificial neural networks, machine learning, and deep learning techniques[J]. Electric Power Systems Research, 2023, 225: 109792.

[3] ZHANG Y F, WEN H L, WU Q W, et al. Optimal adaptive prediction intervals for electricity load forecasting in distribution systems via reinforcement learning[J]. IEEE Transactions on Smart Grid, 2023, 14(4): 3259—3270.

[4] GU Z W, SHEN Y T, WANG Z J, et al. Load forecasting model considering dynamic coupling relationships using structured dynamic-inner latent variables and broad learning system[J]. Engineering Applications of Artificial Intelligence, 2024, 133: 108180.

[5] WANG R H, LI C S, FU W L, et al. Deep learning method based on gated recurrent unit and variational mode decomposition for short-term wind power interval prediction [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(10): 3814—3827.

[6] 黎静华, 骆怡辰, 杨舒惠, 等. 可再生能源电力不确定性预测方法综述[J]. 高电压技术, 2021, 47(4): 1144—1157.

[7] 唐君毅, 丁碧薇, 杨琪. 考虑风电预测区间的电力系统灵活性评估方法[J]. 电气传动, 2023, 53(7): 49—55.

[8] 朱立轩, 万灿, 鞠平. 计及不确定性的电力系统区间分析研究综述[J]. 电力自动化设备, 2023, 43(7): 1—11.

[9] 吴向明, 宋楠, 李晓军, 等. 基于二次模态分解和卷积双向长短期记忆神经网络的高比例光伏配电网线损预测[J]. 电网技术, 2024: 1—11.

[10] 卢武, 郑人杰, 赵文彬, 等. 基于 EMD-GRU 的短期电力负荷预测方法[J]. 电气传动, 2022, 52(21): 74—80.

[11] CHEN C L P, LIU Z L. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 10—24.

[12] 康逸群, 刘厦, 雷兢. 基于鲁棒稀疏宽度学习系统的短期风电功率预测[J]. 太阳能学报, 2024, 45(5): 32—43.

[13] 夏蕾, 张世林, 李文美, 等. 基于宽度学习的新型电力系统负荷多步预测方法[J]. 供用电, 2024, 41(1): 100—108.

[14] HAN M, FENG S B, CHEN C L P, et al. Structured manifold broad learning system: a manifold perspective for large-scale chaotic time series analysis and prediction[J]. IEEE Transactions on Knowledge and Data Engineering, 2019, 31(9): 1809—1821.

[15] UCSD-microgrid-database. URL <https://github.com/sushilsilwal3/UCSD-Microgrid-Database/tree/master>.