

基于自适应时序表征和多级注意力的超短期风电功率预测

张越,臧海祥,程礼临,刘璟璇,卫志农,孙国强

(河海大学 能源与电气学院,江苏 南京 211100)

摘要:针对风电功率数据包含的多尺度时间信息难以描述、现有方法未充分考虑气象因素对于风电功率动态耦合的影响而导致的预测性能下降等问题,提出了一种基于自适应时序表征和多级注意力的超短期风电功率预测方法。采用时序嵌入层对风电功率序列进行表征以获取其周期、非周期模式,并引入自注意力捕捉高维风电功率序列的自相关性;利用交叉注意力重构风电功率与气象因素,形成包含两者耦合关系的多维特征序列;利用一维卷积神经网络沿时间、特征方向分别挖掘多维特征序列的时间相关性和空间相关性,进而利用长短期记忆网络提取相应的时序特征,并将所得时序特征经全局注意力去噪和门控机制融合后输入全连接层,分别进行点预测和区间预测。实验结果表明,所提方法能够获得准确的点预测值和可靠的预测区间。

关键词:风电功率;超短期预测;多级注意力;深度学习;时空相关性;点预测;区间预测

中图分类号:TM614

文献标志码:A

DOI:10.16081/j.epae.202306018

0 引言

风力发电被认为是推进能源转型和可持续发展的重要方式之一^[1],然而受气象因素影响,风电功率具有较强的波动性和随机性,这给电力系统的功率平衡、规划调度带来了较大的挑战。对超短期风电功率进行准确的点预测和区间预测,能够确保电力系统的经济调度和安全运行。

传统的风电功率预测方法包括物理方法和统计方法^[2]。近年来,以机器学习和深度学习为主体的人工智能方法已被广泛应用于风电功率预测^[3]。支持向量回归^[4]、随机森林^[5]等机器学习方法应用于小样本数据集能取得良好的预测精度,然而随着风电相关数据的大规模增加,机器学习方法难以挖掘其中的复杂非线性关系,在很多预测场景中性能明显下降。相较而言,深度学习方法能从海量数据中学习关键特征^[6],提高预测表现。以卷积神经网络(convolutional neural network, CNN)、长短期记忆(long short-term memory, LSTM)网络为基础的深度学习模型在风电功率预测中表现出优异的性能。文献[7]利用CNN提升了模型对风电功率数据的特征提取能力;文献[8]利用改进的LSTM网络进行风电功率预测;文献[9]基于双向长短期记忆(bi-directional long short-term memory, Bi-LSTM)网络,提出了一种深度级联残差模型,获得了可靠的点预测、区间预测结果。

随着研究的不断深入,在深度学习模型中引入

注意力机制,往往能够进一步提升模型的预测表现。文献[10]在LSTM网络的基础上引入特征空间和时序双重注意力机制;文献[11]构建了基于注意力机制的时序卷积网络(temporal convolutional network, TCN)用于风电功率的超短期点预测和区间预测;文献[12]引入自注意力机制改进了TCN结构;文献[13]结合一维卷积神经网络(one-dimensional CNN, 1D-CNN)、堆叠Bi-LSTM网络和注意力机制,实现了高精度的风电功率预测。

高效的数据处理方法也常与深度学习模型相结合用于风电功率预测,如变分模态分解方法^[14]、奇异谱分解方法^[15]、改进的自适应噪声完备集合经验模态分解方法^[16]。这些方法通过分解风电功率序列,获取时间的相关特征,从而提升预测精度。然而,上述处理方法需要人为提取风电功率序列中的时间信息,其过程往往与模型实际的预测环节相分离,这会增加模型性能对数据处理的依赖性。为了进一步提升模型的预测表现,现有方法通常将历史气象特征也作为模型的输入,然而不同时刻的气象特征对风电功率的实际影响是不同的,直接将历史气象特征作为模型的输入,容易忽略其与风电功率之间的动态耦合关系,导致模型的预测性能下降。针对上述研究的不足,本文提出了一种基于自适应时序表征和多级注意力的超短期风电功率预测方法,主要创新点如下:

1)采用时序嵌入层Time2Vec对风电功率序列进行表征,将时间序列预处理过程集成到深度学习模型中,有效提取了风电功率的多尺度时间信息,提升了时间序列处理的自适应性;

2)引入多级注意力提升模型的预测表现,包括利用自注意力充分捕捉风电功率序列的自相关性,利用交叉注意力深度挖掘风电功率与气象因素之间

收稿日期:2023-02-28;修回日期:2023-05-10

在线出版日期:2023-06-30

基金项目:国家自然科学基金资助项目(52077062)

Project supported by the National Natural Science Foundation of China(52077062)

的耦合关系,利用全局注意力有效过滤LSTM网络隐藏层单元状态中的噪声;

3)构建了兼顾多维特征序列内在时空依赖关系的时序特征提取模块,即时空卷积神经网络-长短期记忆(spatiotemporal convolutional neural network-long short-term memory,STCNN-LSTM)网络,在充分考虑多维特征序列时间相关性和空间相关性的基础上,提取了更高层次的时序特征。

1 本文方法的基本原理

本文结合自适应时序表征方法Time2Vec、自注意力、交叉注意力、1D-CNN、LSTM网络和全局注意力建立了超短期风电功率预测模型,该模型以历史风电功率序列和影响风功率变化的多元气象序列作为输入,进行超短期风电功率的点预测和区间预测。所建模型的基本结构如图1所示。图中: Q 、 K 、 V 分别为查询矩阵、键矩阵、值矩阵。




图1 所建模型的基本结构

Fig.1 Basic structure of established model

针对风电功率波动性、突变性显著的特点,首先利用Time2Vec得到原始风电功率序列的时序表征向量,将其与原始序列拼接后,输入全连接层中,得到能够反映其多尺度时间特性的高维风电功率序列。

其次,考虑不同时间步风电功率值之间的影响,利用位置编码和多头自注意力重构所得高维风电功率序列,充分捕捉其自相关性。

然后,考虑风电功率与气象因素之间的耦合关系,利用交叉注意力重构风电功率序列与多元气象序列,得到包含两者耦合关系的多维特征序列。为了避免原始风电功率数据信息的丢失,本文在利用多头自注意力、交叉注意力对风电功率的相关数据进行重构时均引入了残差连接,以保留风电功率的原始特征信息。

在此基础上,利用1D-CNN沿时间和特征方向分别获取多维特征序列的时间相关性和空间相关性,进而利用LSTM网络充分提取两者的时序特征,将所得时序特征经全局注意力去噪和门控机制融合后,输入全连接层,分别进行点预测和区间预测。

2 风电功率相关数据重构

2.1 基于Time2Vec的风电功率序列表征

作为一种新型时间序列表征方法,Time2Vec能够嵌入不同的深度学习模型中^[17]。对于给定的时间标量 τ ,经Time2Vec处理后可得到其高阶特征表示 $t_{2v}(\tau)$,具体可表示为:

$$t_{2v}(\tau)[i] = \begin{cases} \omega_0\tau + \varphi_0 & i=0 \\ \sin(\omega_i\tau + \varphi_i) & 1 \leq i \leq k \end{cases} \quad (1)$$

式中: $t_{2v}(\tau)[i]$ 为 $t_{2v}(\tau)$ 的第 i 个分量, $i=0$ 时为线性分量, $1 \leq i \leq k$ 时为周期性分量, k 为周期性分量的数量; ω_i 、 φ_i 分别为第 i 个周期性分量对应正弦函数的角频率、相位,均为可更新的参数, $\sin(\omega_i\tau + \varphi_i)$ 用于捕捉时间的周期性模式; ω_0 、 φ_0 分别为线性分量的角频率、相位,用于捕捉时间的非周期性模式。

本文利用Time2Vec对原始风电功率序列进行表征,示意图见附录A图A1,具体过程可表示为:

$$Y_{\text{concat}} = C_{\text{concat}}(Y, \text{Time2vec}(Y)) \quad (2)$$

式中: $Y \in \mathbb{R}^T$ 为给定时间窗口长度 T 内的风电功率序列; $Y_{\text{concat}} \in \mathbb{R}^{T \times (k+2)}$ 为Time2Vec分量Time2vec(Y)与原始风电功率序列拼接所得结果; $C_{\text{concat}}(\cdot, \cdot)$ 为拼接函数。

2.2 基于多头自注意力的风电功率序列重构

自注意力机制^[18]通过构建序列不同位置元素之间的联系和影响,得到原始序列新的表现形式。给定一个输入序列 $Z \in \mathbb{R}^{l \times d}$,其中 l 为序列长度, d 为变量维数。在自注意力机制中,该输入序列首先被转变为查询矩阵 Q 、键矩阵 K 、值矩阵 V ,如式(3)所示。

$$Q = ZW_Q, K = ZW_K, V = ZW_V \quad (3)$$

式中: $W_Q \in \mathbb{R}^{d \times d_k}$ 、 $W_K \in \mathbb{R}^{d \times d_k}$ 、 $W_V \in \mathbb{R}^{d \times d_v}$ 为参数矩阵, d_k 、 d_v 为变换维度; $Q \in \mathbb{R}^{l \times d_k}$ 、 $K \in \mathbb{R}^{l \times d_k}$ 、 $V \in \mathbb{R}^{l \times d_v}$ 分别为基于原始输入序列得到的查询矩阵、键矩阵、值矩阵。基于上述变量可计算得到自注意力机制的输出 A 为:

$$A = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4)$$

式中: $\text{Softmax}(\cdot)$ 为归一化指数激活函数。

$\text{Softmax}\left(QK^T/\sqrt{d_k}\right) \in \mathbf{R}^{l \times l}$ 构建了序列不同位置查询矩阵与键矩阵之间的相关性,在此基础上将值矩阵与权重矩阵相乘,即可得到输出 $A \in \mathbf{R}^{l \times d}$ 。

多头自注意力机制是在自注意力机制的基础上发展形成的,其计算方式与自注意力机制相同,区别在于多头自注意力基于输入序列进行多个自注意力的并行计算。多头自注意力机制的计算过程可表示为:

$$O = [A^{(1)} A^{(2)} \cdots A^{(m)}] W_o \quad (5)$$

式中: $A^{(1)}, A^{(2)}, \dots, A^{(m)}$ 为各头自注意力的计算结果; O 为多头自注意力机制的输出; m 为多头自注意力机制的“头数”; W_o 为参数矩阵。

多头注意力机制的结构示意图见附录A图A2,本文利用其充分捕捉功率数据的自相关性,进而对风电功率序列进行重构,具体步骤如下。

首先,在2.1节的基础上,将 Y_{concat} 映射至 d 维空间,得到 $Y_{\text{enc}} \in \mathbf{R}^{T \times d}$; 由于多头自注意力在计算时并没有考虑数据的位置信息,因此采用位置编码将位置信息添加到序列中,保留风电功率序列的时序特性用于后续的建模。位置编码的计算方式为:

$$\begin{cases} E_{p_{\text{pos}}, 2i} = \sin(p_{\text{pos}}/10\,000^{2i/d}) \\ E_{p_{\text{pos}}, 2i+1} = \cos(p_{\text{pos}}/10\,000^{2i/d}) \end{cases} \quad (6)$$

式中: p_{pos} 为序列索引; i 为维度索引; $E_{p_{\text{pos}}, 2i}, E_{p_{\text{pos}}, 2i+1}$ 为位置编码的计算结果。将上述映射到 d 维空间的序列与位置编码结果相加,即可得到带有位置信息的高维风电功率序列 $Y_{\text{new}} \in \mathbf{R}^{T \times d}$ 。

然后,按照式(3)—(5)对高维风电功率序列进行重构,具体过程如下:

$$\begin{cases} Q_y = Y_{\text{new}} W_{Q_y}, K_y = Y_{\text{new}} W_{K_y}, V_y = Y_{\text{new}} W_{V_y} \\ A_y = \text{Softmax}\left(Q_y K_y^T / \sqrt{d_k}\right) V_y \\ O_y = [A_y^{(1)} A_y^{(2)} \cdots A_y^{(m)}] W_{O_y} \end{cases} \quad (7)$$

式中: $W_{Q_y}, W_{K_y}, W_{V_y}, W_{O_y}$ 为参数矩阵; Q_y, K_y, V_y 分别为基于高维风电功率序列 Y_{new} 所得查询矩阵、键矩阵、值矩阵; A_y 为自注意力机制的输出; $A_y^{(1)}, A_y^{(2)}, \dots, A_y^{(m)}$ 为各头自注意力的计算结果; $O_y \in \mathbf{R}^{T \times d_y}$ 为经多头自注意力重构后的新型风电功率序列, d_y 为新型风电功率序列的维度。

2.3 基于交叉注意力的风电功率与气象因素重构

风速、温度、湿度等气象参数是影响风电功率的重要因素,因此需要考虑风电功率与多元气象变量之间的联系。本文利用交叉注意力重构风电功率序列和多元气象序列,以更好地捕捉气象因素对风电功率的动态影响。利用交叉注意力对两者进行重构时,基于2.2节所得新型风电功率序列变换得到查询

矩阵,基于原始多元气象序列变换得到键矩阵和查询矩阵,具体过程如下:

$$\begin{cases} Q_{xy} = O_y W_{Q_{xy}}, K_{xy} = X W_{K_{xy}}, V_{xy} = X W_{V_{xy}} \\ A_{xy} = \text{Softmax}\left(Q_{xy} K_{xy}^T / \sqrt{d_k}\right) V_{xy} \\ O_{xy} = [A_{xy}^{(1)} A_{xy}^{(2)} \cdots A_{xy}^{(m)}] W_{O_{xy}} \end{cases} \quad (8)$$

式中: $X \in \mathbf{R}^{T \times n}$ 为影响风电功率变化的多元气象序列, n 为气象变量的数量; $W_{Q_{xy}}, W_{K_{xy}}, W_{V_{xy}}, W_{O_{xy}}$ 为参数矩阵; Q_{xy}, K_{xy}, V_{xy} 分别为相应的查询矩阵、键矩阵、值矩阵; A_{xy} 为交叉注意力机制的输出; $A_{xy}^{(1)}, A_{xy}^{(2)}, \dots, A_{xy}^{(m)}$ 为各头交叉注意力的计算结果; $O_{xy} \in \mathbf{R}^{T \times d_{xy}}$ 为最终得到的多维特征序列(d_{xy} 为该序列的维度),该序列充分考虑了风电功率与气象因素之间的耦合关系,是对风电功率和气象因素进行有效重构后的高级特征表示。

3 超短期风电功率预测模型

3.1 基于STCNN-LSTM网络的时序特征提取

当1D-CNN和LSTM网络应用于时间序列预测时,能够有效捕获时间序列的高级特征和重要信息^[19]。本文充分利用1D-CNN和LSTM网络在时序建模中的优势,构建了STCNN-LSTM网络,以提取2.3节中 $O_{xy} \in \mathbf{R}^{T \times d_{xy}}$ 的时序特征,具体过程如图2所示。




图2 STCNN-LSTM网络时序特征提取过程

Fig.2 Temporal feature extraction process of STCNN-LSTM network

首先,利用1D-CNN构建时间卷积模块和空间卷积模块,对 O_{xy} 进行初步特征提取。时间卷积模块使用卷积核数量为 d_{xy} 的1D-CNN沿时间维度对 O_{xy} 进行卷积运算,所采取的填充方式为“causal”,具体计算方式为:

$$l_{\text{tem}} = \text{Relu}(O_{xy} * W_{\text{tem}} + b_{\text{tem}}) \quad (9)$$

式中: $W_{\text{tem}}, b_{\text{tem}}$ 分别为卷积运算的权重、偏置; $\text{Relu}(\cdot)$ 为激活函数; $l_{\text{tem}} \in \mathbf{R}^{T \times d_{xy}}$ 为输出结果; “*” 为卷积运算。时间卷积模块可以有效地学习多维特征序列在时间维度上的依赖关系,然而其在捕获多元序列空间依

赖关系方面的能力有所欠缺,空间卷积模块则是针对这一不足而设计的。空间卷积模块使用卷积核数量为 T 的1D-CNN沿特征维度对 O_{xy} 进行卷积运算,所采取的填充方式为“same”,具体计算方式为:

$$l_{spa} = \text{Relu}(O_{xy} * W_{spa} + b_{spa}) \quad (10)$$

式中: W_{spa} 、 b_{spa} 分别为卷积运算的权重、偏置; l_{spa} 为空间卷积模块的输出,其充分学习了多维特征序列之间的空间依赖关系。

基于上述时间卷积模块和空间卷积模块所得结果,利用LSTM网络进一步提取其时序特征,具体可表示为:

$$\begin{cases} H_{tem} = \text{LSTM}(l_{tem}) = [h_1^{tem} \cdots h_t^{tem} \cdots h_T^{tem}] \\ H_{spa} = \text{LSTM}(l_{spa}) = [h_1^{spa} \cdots h_t^{spa} \cdots h_T^{spa}] \end{cases} \quad (11)$$

式中: $\text{LSTM}(\cdot)$ 表示LSTM网络; $H_{tem} \in \mathbb{R}^{T \times U}$ 为基于 l_{tem} 的网络输出, U 为LSTM网络的隐藏层单元数量; $H_{spa} \in \mathbb{R}^{T \times U}$ 为基于 l_{spa} 的网络输出; $h_t^{tem} \in \mathbb{R}^U$ 、 $h_t^{spa} \in \mathbb{R}^U$ ($t=1, 2, \dots, T$)为在时间步 t 对应隐藏层单元的状态。

为了提升模型的预测表现,本文引入注意力机制进一步变换所得时序特征。现有研究针对LSTM网络输出建立的注意力机制往往为不同时间步对应的隐藏层状态向量分配一个注意力权重系数^[10,13],这种方式不能过滤掉每个时间步隐藏层状态中的噪声^[20]。因此,本文设计了一种全局注意力,兼顾了时间步和隐藏层单元状态2个角度,为LSTM网络的输出分配一个注意力权重矩阵,具体的变换过程如下:

$$E = \text{Relu}(\tilde{V}(\tanh(\tilde{W}H))) \quad (12)$$

$$\begin{cases} \beta_{t,u} = \frac{e^{e_{t,u}}}{\sum_{t'=1}^T \sum_{u'=1}^U e^{e_{t',u'}}} \\ \beta_t = [\beta_{t,1} \cdots \beta_{t,u} \cdots \beta_{t,U}] \in \mathbb{R}^U \end{cases} \quad (13)$$

$$c_o = \sum_{t=1}^T \beta_t \odot h_t \quad (14)$$

式中: $E \in \mathbb{R}^{T \times U}$; $c_o \in \mathbb{R}^U$ 为最终的输出; $\tilde{V}$ 、 $\tilde{W}$ 为参数矩阵; $\tanh(\cdot)$ 为激活函数; $e_{t,u}$ ($t=1, 2, \dots, T$; $u=1, 2, \dots, U$)为变换所得矩阵 E 的元素; $\beta_{t,u}$ 为全局注意力权重矩阵的元素;“ $\odot$ ”为哈达玛积; h_t 为在时间步 t 隐藏层单元的状态。

利用全局注意力对所得 H_{tem} 、 H_{spa} 进行变换,可得 $c_{o,tem} \in \mathbb{R}^U$ 、 $c_{o,spa} \in \mathbb{R}^U$,进而引入门控机制,融合所得时序特征,可得时序特征融合结果 o 为:

$$o = \mu c_{o,tem} + (1-\mu) c_{o,spa} \quad (15)$$

式中: μ 为门控系数,其取值范围为 $[0, 1]$ 。

3.2 基于多级注意力和STCNN-LSTM网络的超短期风电功率点预测

基于多级注意力和STCNN-LSTM(multi-level attention STCNN-LSTM, MASTCNN-LSTM)网络的超

短期风电功率点预测的流程图如附录A图A3所示。其中:数据预处理阶段对异常值和缺失值进行清洗,并在此基础上划分训练集和测试集;风电功率相关数据重构阶段充分挖掘了风电功率的多尺度特性、气象因素对风电功率的动态影响,并形成了包含两者耦合关系的多维特征序列;STCNN-LSTM网络实现了对上述多维特征序列深层时序特征的有效提取,进而将其输入全连接层中,得到最终的风电功率点预测值。模型训练时采用均方误差(mean squared error, MSE)作为损失函数,其表达式为:

$$\gamma_{MSE} = \frac{1}{N_s} \sum_{i=1}^{N_s} (\hat{y}_i - y_i)^2 \quad (16)$$

式中: γ_{MSE} 为MSE值; y_i 为第 i 个样本的实测值; $\hat{y}_i$ 为第 i 个样本的预测值; N_s 为训练集样本总数。在训练过程中不断更新模型参数,使得MSE尽可能小;当训练达到设定次数后,可基于测试集验证模型的实际预测效果。该模型的点预测过程可描述为:

$$\hat{y}_{T+\lambda} = f_p(Y, X) \quad (17)$$

式中: $f_p(\cdot)$ 为MASTCNN-LSTM网络的非线性映射函数; $\hat{y}_{T+\lambda}$ 为预测步长为 λ 时的风电功率预测值。

本文选取均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)、相关系数(correlation coefficient, CORR)、决定系数(coefficient of determination, CoD)作为点预测的评价指标,其计算公式分别为:

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (18)$$

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (19)$$

$$c_{CORR} = \frac{\left| \sum_{i=1}^N (\hat{y}_i - \hat{y}_a)(y_i - y_a) \right|}{\sqrt{\left[\sum_{i=1}^N (\hat{y}_i - \hat{y}_a)^2 \right] \left[\sum_{i=1}^N (y_i - y_a)^2 \right]}} \quad (20)$$

$$c_{CoD} = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (y_i - y_a)^2} \quad (21)$$

式中: e_{RMSE} 、 e_{MAE} 、 c_{CORR} 、 c_{CoD} 分别为RMSE、MAE、CORR、CoD值; y_a 、 $\hat{y}_a$ 分别为测试集样本的实际均值、预测均值; N 为测试集样本总数。评价模型时,所得RMSE、MAE值越小, CORR、CoD值越大,则模型的点预测精度越高,预测效果越好。

3.3 基于分位数回归和MASTCNN-LSTM网络的超短期风电功率区间预测

风电功率区间预测通过预测实际功率值的上下界,得到给定置信度下的预测区间^[21]。本节在3.2节中点预测模型的基础上引入分位数回归(quantile

regression, QR), 构建基于 QR 和 MASTCNN-LSTM (QR-MASTCNN-LSTM) 网络的深度神经网络进行超短期风电功率区间预测。QR 被用于研究自变量与因变量条件分位数之间的关系, 并得到因变量的条件概率分布。在 QR 神经网络中, QR 用于揭示历史输入对风电功率条件分布的影响规律, 从而得到不同分位数水平下的风电功率预测值。

基于 QR-MASTCNN-LSTM 网络的超短期风电功率区间预测流程图如附录 A 图 A4 所示, 其同样包括数据预处理、风电数据重构、STCNN-LSTM 网络时序特征提取等过程。点预测模型在训练时使用 MSE 作为目标损失函数, 不能得到不同条件分位数对应的风电功率值, 因此所提区间预测模型在模型训练阶段选取分位数损失 (quantile loss, QL) 作为目标损失函数, 其数学表达式为:

$$\gamma_{\text{QL}} = \begin{cases} \frac{1}{N} \sum_{j=1}^Q \sum_{i=1}^{N_i} (1 - q_j) (\hat{y}_i^{q_j} - y_i) & \hat{y}_i^{q_j} \geq y_i \\ \frac{1}{N} \sum_{j=1}^Q \sum_{i=1}^{N_i} q_j (y_i - \hat{y}_i^{q_j}) & \hat{y}_i^{q_j} < y_i \end{cases} \quad (22)$$

式中: γ_{QL} 为 QL 值; q_j 为第 j 个分位数; $\hat{y}_i^{q_j}$ 为在分位数水平 q_j 下进行预测的第 i 个样本预测值; Q 为分位数的数量。训练阶段同样是在设定的训练周期内不断更新模型参数, 以获得尽可能小的 QL。

在进行区间预测时, 对于显著性水平为 α 的情形, 实际风电功率值落在预测区间内的理论概率被称为预测区间名义置信度 (prediction interval nominal confidence, PINC), 其表达式为:

$$c_{\text{PINC}} = (1 - \alpha) \times 100 \% \quad (23)$$

式中: c_{PINC} 为 PINC。

此时, 对于第 i 个样本的实测值, 其所形成的预测区间 I_i^α 为:

$$\begin{cases} I_i^\alpha = U_i^\alpha - L_i^\alpha & \alpha \in (0, 0.5) \\ U_i^\alpha = \hat{y}_i^{1-\alpha/2}, L_i^\alpha = \hat{y}_i^{\alpha/2} \end{cases} \quad (24)$$

式中: U_i^α 、 L_i^α 分别为显著性水平 α 下第 i 个样本预测区间的上、下界; $\hat{y}_i^{\alpha/2}$ 、 $\hat{y}_i^{1-\alpha/2}$ 分别为分位数水平 $\alpha/2$ 、 $1-\alpha/2$ 对应的第 i 个样本的预测值。当 $\alpha=0.1$ 时, PINC 为 90%, $\hat{y}_i^{0.95}$ 、 $\hat{y}_i^{0.05}$ 分别为 y_i 的上、下界, 中间区域形成对应的预测区间; 当 α 取不同的值时, 可以形成不同置信度下的预测区间, 能够提供不同程度的预测信息。因而, 显著性水平为 α 时的区间预测过程可进一步描述为:

$$U_{T+\lambda}^\alpha, L_{T+\lambda}^\alpha = \hat{y}_{T+\lambda}^{1-\alpha/2}, \hat{y}_{T+\lambda}^{\alpha/2} = f_i(\mathbf{Y}, \mathbf{X}) \quad (25)$$

式中: $f_i(\cdot)$ 为 QR-MASTCNN-LSTM 的非线性映射函数; $U_{T+\lambda}^\alpha$ 、 $L_{T+\lambda}^\alpha$ 分别为显著性水平 α 下预测步长为 λ 时预测区间的上、下界。

在模型评价阶段, 选用平均覆盖误差 (average

coverage error, ACE)、预测区间归一化平均宽度 (prediction interval normalized average width, PINAW)、温克勒得分 (Winkler score, WS) 作为区间预测的评价指标, 其计算公式分别为:

$$\begin{cases} e_{\text{ACE}} = \frac{1}{N} \sum_{i=1}^N h_i \times 100 \% - c_{\text{PINC}} \\ h_i = \begin{cases} 1 & L_i \leq y_i \leq U_i \\ 0 & y_i < L_i, y_i > U_i \end{cases} \end{cases} \quad (26)$$

$$w_{\text{PINAW}} = \frac{N^{-1}}{\max\{y\} - \min\{y\}} \sum_{i=1}^N (U_i - L_i) \quad (27)$$

$$s_{\text{WS}} = \begin{cases} \frac{1}{N} \sum_{i=1}^N [-2\alpha\theta_i - 4(L_i - y_i)] & y_i < L_i \\ \frac{1}{N} \sum_{i=1}^N (-2\alpha\theta_i) & L_i \leq y_i \leq U_i \\ \frac{1}{N} \sum_{i=1}^N [-2\alpha\theta_i - 4(y_i - U_i)] & y_i > U_i \end{cases} \quad (28)$$

式中: e_{ACE} 、 w_{PINAW} 、 s_{WS} 分别为 ACE、PINAW、WS; U_i 、 L_i 分别为第 i 个样本预测区间的上、下界; h_i 为判断第 i 个样本的实测值是否落在预测区间内的状态变量, 若落在预测区间内, 则 $h_i=1$, 否则 $h_i=0$; $\theta_i=U_i-L_i$; $\max\{y\}$ 、 $\min\{y\}$ 分别为实测值的最大值、最小值。当评价模型时, ACE 值在 0 附近表示预测区间的覆盖可靠性较高, PINAW 用于衡量测量预测区间的宽度, WS 则用于衡量预测区间的锐度, 当满足一定的可靠性要求时, PINAW 值越小, WS 越接近 0, 模型的区间预测性能越好。

4 算例分析

4.1 算例概况

本文首先进行点预测和区间预测, 分别验证所提方法进行超短期风电功率预测的准确性和可靠性; 在此基础上, 设置消融实验以分析所提模型中的重要组成部分对模型预测效果的提升作用; 为了探究气象因素对模型预测性能的实际影响以及所提方法在极端天气情况下的有效性, 还对比分析了考虑与不考虑气象因素时所提模型的预测表现; 最后, 对所提模型的运行时间进行了讨论, 以验证其在超短期风电功率预测中的可行性。

本文所用数据源自江苏某容量为 49.5 MW 的风电场, 具体为 2017 年 1 月 1 日至 2017 年 12 月 31 日的风电功率、气象数据, 气象因素包括风速、风向、温度、气压、湿度; 数据采样间隔为 15 min, 共计采样 35 040 个样本, 并划分前 30 000 个样本作为训练集, 后 5 040 个样本作为测试集。所用滑动窗口长度为 48, 即将目标预测时刻之前 12 h 的风电功率、气象数据作为模型输入; 实验中的预测步长为 1, 即进行提前 15 min (超短期范畴) 的风电功率预测。

本文所有深度学习模型均基于 Tensorflow 这一

深度学习框架进行构建,当各模型进行训练时,选取Adam作为优化器,验证集比例为0.1,批量大小为512,总训练迭代次数为80次。为了确保实验结果的准确性和客观性,实际算例测试时各模型均运行5次,用所得结果的均值来评估模型的预测表现。

4.2 点预测结果分析

为了充分验证本文所提模型在进行点预测时的有效性,选取6个模型进行对比分析,分别为TCN、LSTM网络、Bi-LSTM网络、双重注意力LSTM(dual-stage attention LSTM, DALSTM)网络^[10]、自注意力时序卷积网络-LSTM(self-attention temporal convolutional network-LSTM, SATCN-LSTM)网络^[12]以及基于Time2Vec、注意力的卷积Bi-LSTM(Time2Vec attention based convolutional Bi-LSTM, TACBi-LSTM)网络^[13]。不同模型的点预测结果如表1所示。

表1 不同模型的点预测结果

Table 1 Point forecasting results of different models

模型	e_{RMSE} / MW	e_{MAE} / MW	c_{CORR}	c_{CoD}
TCN	2.530	1.552	0.9642	0.9286
LSTM网络	2.482	1.672	0.9678	0.9312
Bi-LSTM网络	2.492	1.644	0.9667	0.9307
DALSTM网络	2.405	1.532	0.9684	0.9354
SATCN-LSTM网络	2.317	1.424	0.9708	0.9401
TACBi-LSTM网络	2.316	1.360	0.9707	0.9402
MASTCNN-LSTM网络	2.233	1.197	0.9720	0.9443

由表1知,MASTCNN-LSTM网络的点预测精度最高,其RMSE、MAE分别为2.233、1.197 MW, CORR、CoD分别为0.9720、0.9443。相比于基础的深度学习模型,本文所提模型的预测精度显著提升, RMSE下降了10.04%~11.74%, MAE下降了22.88%~22.44%;相比于文献[10, 12-13]中高效的风电功率预测模型,本文所提模型仍能获得更小的预测误差,其RMSE下降了3.56%~7.16%, MAE下降了12.02%~21.68%,体现了所提模型在进行超短期风电功率点预测方面的优越性。

不同模型的预测误差分布曲线如图3所示。由图可以看出,本文所提模型在测试集上的预测误差在0值附近分布最为集中,其分布曲线相比于其他模型的分布曲线也更窄,这表明本文所提模型在测试集上的总体误差更小,预测效果更好。

不同时段各模型的点预测曲线和实际风电功率曲线的拟合情况见附录B图B1。由图可以看出,受风速等因素的影响,风电功率具有较强的波动性。对比可知,MASTCNN-LSTM网络的综合拟合效果最优,具体表现在:对于风电功率波动较大的情形,如图B1(a)和图B1(c)出现的“爬坡”现象,相比于其他模型,本文所提模型的预测值曲线都与实际值曲线更为贴合;对于风电波动较小的情形,如图B1(b)中




图3 不同模型的预测误差分布曲线

Fig.3 Forecasting error distribution curves of different models

起始、中间时段以及图B1(c)中最后时段出现的“小幅振荡”现象,本文所提模型的预测值曲线仍与实际值曲线最为接近。

4.3 区间预测结果分析

相比于点预测,区间预测通常能提供更多有助于电力系统风险分析的信息^[22]。本文所测试的区间预测模型均基于4.2节中的点预测模型,利用QL函数进行训练,构建相应的QR神经网络。算例测试验证了PINC为90%、85%、80%时各模型的区间预测表现,具体结果如附录B表B1所示。由表可知:当PINC为90%、85%时,QR-MASTCNN-LSTM网络的ACE绝对值、PINAW、WS绝对值均最小,这表明本文所提模型生成的预测区间更窄,具有更高的可靠性;当PINC为80%时,QR-MASTCNN-LSTM网络的ACE为2.5321,表明其区间覆盖率高于给定的置信水平,但其PINAW值最小,且WS值均优于其他模型,这表明该模型提供了可靠的预测区间,且宽度相对较窄。综上可知,本文所提模型在3种置信水平下生成的预测区间具有较高的可靠性,且基于不同评估指标体现了最高的区间预测精度。

为了更为直观地比较不同模型的区间预测效果,选取QR-SATCN-LSTM网络、QR-TACBi-LSTM网络、QR-MASTCNN-LSTM网络模型在不同时段3种置信度下产生的预测区间进行可视化分析,可视化结果如附录B图B2所示。由图可知,3种模型所产生的预测区间均能较好地覆盖实际的风电功率值,以表征风电功率预测的不确定性。相比于其他2种区间预测模型,QR-MASTCNN-LSTM网络生成的预测区间更为紧凑,其区间包络线也能较好地描述风电功率的波动特征,区间预测效果最好。

4.4 消融实验结果分析

为了验证本文所提方法中重要组件对其预测性能的实际影响,本节针对点预测和区间预测分别进行消融实验,所用实验数据和相应的参数设置均与前文保持一致,所得结果见表2和附录B表B2。表

中:情形A—D分别删除了Time2Vec、多头自注意力、交叉注意力、全局注意力组件;情形E为本文所提点预测方法,集成了上述4个组件。

表2 消融实验的点预测结果

Table 2 Point forecasting results of ablation experiment

情形	删除组件	e_{RMSE} / MW	e_{MAE} / MW	c_{CORR}	c_{CoD}
A	Time2Vec	2.253	1.226	0.9714	0.9433
B	多头自注意力	2.300	1.391	0.9708	0.9410
C	交叉注意力	2.242	1.214	0.9717	0.9439
D	全局注意力	2.243	1.233	0.9717	0.9439
E	—	2.233	1.197	0.9720	0.9443

由表2可知:相较于情形A,情形E利用Time2Vec组件对风电功率序列进行表征学习,其MAE降低了2.38%;相较于情形B,情形E的MAE降低了13.96%;相较于情形C,情形E引入交叉注意力组件进一步提高了点预测精度;相较于情形D,情形E引入全局注意力组件同样提升了模型的点预测表现。

由表B2可知,情形A和情形B在不同的置信度约束下得到的预测区间宽度比情形E更宽,就WS指标而言,情形E进行区间预测时的综合性能也优于情形A和情形B,可见Time2Vec、自注意力组件能够充分挖掘风电功率序列自身的多尺度特性,使得预测区间能更好地描述风电功率的波动特征;情形C在90%、80%置信度约束下取得最优的预测区间宽度,相较而言,情形E在3种置信度约束下的WS绝对值都更小,这表明交叉注意力组件能够有效提升区间预测的锐度;情形D在90%、85%置信度约束下取得较好的区间预测效果,但在80%置信度约束下的预测效果有所下降,尤其是区间覆盖率下降显著。综上可知,情形E的稳定性更好。

综上所述,本文所提方法中的4个重要组件在进行实际的超短期风电功率预测时,能够充分发挥自身的效能,不同程度地提升模型进行点预测和区间预测的综合性能。

4.5 气象因素对风电功率预测的影响分析

为了探究进行超短期风电功率预测时考虑气象因素的必要性,本节对比分析了考虑、不考虑气象因素时所提模型的预测效果,对应的点预测和区间预测结果如附录B表B3所示。由表可知,考虑气象因素时,模型的点预测和区间预测效果均更好。特别的是,当进行区间预测时,若不考虑气象因素,则模型的区间覆盖率远低于给定的置信水平,这是因为气象因素对风电功率的变化有重要的影响,将其作为输入更有利于模型描述风电功率的不确定性。

极端天气情况下考虑、不考虑气象因素时本文所提模型的风电功率预测表现如图4所示。受极端天气影响,风电功率呈现剧烈的波动,幅值变化范围较大。对比可知,考虑气象因素时所得点预测曲线

的拟合效果更好,所得预测区间同样能够较好地覆盖实际的风电功率值,上述结果再次验证了进行超短期风电功率预测时考虑气象因素的必要性,也说明了所提方法应用于极端天气情况下风电功率预测的可行性。




图4 极端天气情况下本文所提模型的风电功率预测表现
Fig.4 Wind power forecasting performance of proposed model under extreme weather condition

图4 极端天气情况下本文所提模型的风电功率预测表现
Fig.4 Wind power forecasting performance of proposed model under extreme weather condition

风电功率相关数据重构的具体表现如附录B图B3所示,该重构过程首先基于输入样本,利用Time2Vec以向量嵌入的形式提供时间表示。由图B3可知:自注意力使得模型在实际预测时更关注邻近时刻(第47、48个时间步)的风电功率;而对于不同时刻的气象特征,其对预测的影响各异,交叉注意力使得模型着重关注特定时刻的气象特征,以动态捕捉不同时刻对应气象因素对风电功率的影响,并形成包含两者耦合关系的多维特征序列。

4.6 不同模型的运行时间对比分析

本文进一步分析了不同模型的运行时间,不同点预测模型的训练用时和测试用时如表3所示。由表可知,MASTCNN-LSTM网络、TACBi-LSTM网络的训练用时和测试用时均更长,这是因为两者的模型结构更深。在增加一定计算成本的基础上,本文所提模型的预测精度提升明显,且其在测试集上的计算时间仅为12.0 s,远小于目标预测步长(15 min),因而本文所提模型在进行实际的超短期风电功率预测时能够快速高效地得到相应的预测结果。

表3 不同点预测模型的运行时间

Table 3 Running time of different point forecasting models

模型	训练用时 / h	测试用时 / s
TCN	0.58	2.0
LSTM网络	0.11	1.7
Bi-LSTM网络	0.16	1.7
DALSTM网络	0.31	3.0
SATCN-LSTM网络	0.49	3.8
TACBi-LSTM网络	1.60	8.2
MASTCNN-LSTM网络	3.40	12.0

5 结论

本文提出了一种基于自适应时序表征和多级注意力的风电功率预测方法,对超短期风电功率进行点预测和区间预测。该方法对风电功率的相关数据进行重构,并利用STCNN-LSTM网络有效提取了兼顾多元时间序列内在时空相关性的高阶时序特征,同时引入多级注意力机制,提升了模型的预测表现。基于算例测试结果,可得到如下结论:

1)所提模型能够获得准确的点预测结果,进行提前15 min的风电功率预测时,其测试RMSE、MAE分别为2.233、1.197 MW,CORR和CoD分别为0.9720、0.9443,相比于其他深度学习模型,本文所提模型的RMSE、MAE分别下降了3.56%~11.74%、12.02%~28.44%,预测精度显著提升;

2)所提模型能够获得可靠的区间预测结果,在置信度为90%、85%、80%的情形下,其产生的预测区间均具有较高的可靠性,且PINAW、WS指标均优于其他区间预测模型,能够准确描述预测的不确定性;

3)本文所用的自适应时序表征方法Time2Vec以及基于自注意力、交叉注意力、全局注意力所构建的多级注意力机制,均能够发挥自身的效能,有效提升模型进行点预测和区间预测的性能。

未来,如何构建多源多维数据驱动的深度学习方法来提升风电功率预测的准确性和可靠性,是值得思考和探索的;此外,不同天气状况、不同时间尺度的风电功率预测研究 also 具有重要的现实意义。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 肖白,邢世亨,王茂春,等. 基于改进KDE法和GA-SVM的多风电场聚合后输出功率长期波动特性预测方法[J]. 电力自动化设备,2022,42(2):77-84.
XIAO Bai, XING Shiheng, WANG Maochun, et al. Prediction method of output power long-term fluctuation characteristic for multiple wind farms after aggregation based on improved KDE method and GA-SVM[J]. Electric Power Automation Equipment, 2022, 42(2): 77-84.
- [2] 孙荣富,张涛,和青,等. 风电功率预测关键技术及应用综述[J]. 高电压技术,2021,47(4):1129-1143.
SUN Rongfu, ZHANG Tao, HE Qing, et al. Review on key technologies and applications in wind power forecasting[J]. High Voltage Engineering, 2021, 47(4): 1129-1143.
- [3] 崔杨,王议坚,黄彦浩,等. 基于多元注意力框架与引导式监督学习的闭环风电功率超短期预测策略[J]. 中国电机工程学报,2023,43(4):1334-1347.
CUI Yang, WANG Yijian, HUANG Yanhao, et al. Closed-loop wind power ultra-short-term forecasting strategy based on multi-attention framework and guided supervised learning[J]. Proceedings of the CSEE, 2023, 43(4): 1334-1347.
- [4] DHIMAN H S, DEB D, GUERRERO J M. Hybrid machine intelligent SVR variants for wind forecasting and ramp events [J]. Renewable and Sustainable Energy Reviews, 2019, 108: 369-379.
- [5] YE Lin, LI Yilin, PEI Ming, et al. A novel integrated method for short-term wind power forecasting based on fluctuation clustering and history matching[J]. Applied Energy, 2022, 327: 120131.
- [6] 杨京渝,罗隆福,阳同光,等. 基于气象特征挖掘和改进深度学习模型的风电功率短期预测[J]. 电力自动化设备,2023,43(3):110-116.
YANG Jingyu, LUO Longfu, YANG Tongguang, et al. Wind power short-term forecasting based on meteorological feature exploring and improved deep learning model[J]. Electric Power Automation Equipment, 2023, 43(3): 110-116.
- [7] 牛哲文,余泽远,李波,等. 基于深度门控循环单元神经网络的短期风电功率预测模型[J]. 电力自动化设备,2018,38(5):36-42.
NIU Zhewen, YU Zeyuan, LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 36-42.
- [8] EWEES A A, AL-QANESS M A A, ABUALIGAH L, et al. HBO-LSTM: optimized long short term memory with heap-based optimizer for wind power forecasting[J]. Energy Conversion and Management, 2022, 268: 116022.
- [9] KO M S, LEE K, KIM J K, et al. Deep concatenated residual network with bidirectional LSTM for one-hour-ahead wind power forecasting[J]. IEEE Transactions on Sustainable Energy, 2020, 12(2): 1321-1335.
- [10] 苏向敬,周汶鑫,李超杰,等. 基于双重注意力LSTM神经网络的可解释海上风电出力预测[J]. 电力系统自动化,2022,46(7):141-151.
SU Xiangjing, ZHOU Wenxin, LI Chaojie, et al. Interpretable offshore wind power output forecasting based on long short-term memory neural network with dual-stage attention[J]. Automation of Electric Power Systems, 2022, 46(7): 141-151.
- [11] LIANG Junkai, TANG Wenyuan. Ultra-short-term spatiotemporal forecasting of renewable resources: an attention temporal convolutional network-based approach[J]. IEEE Transactions on Smart Grid, 2022, 13(5): 3798-3812.
- [12] XIANG Ling, LIU Jianing, YANG Xin, et al. Ultra-short term wind power prediction applying a novel model named SATCN-LSTM[J]. Energy Conversion and Management, 2022, 252: 115036.
- [13] MA Zhengjing, MEI Gang. A hybrid attention-based deep learning approach for wind power prediction[J]. Applied Energy, 2022, 323: 119608.
- [14] LU Peng, YE Lin, PEI Ming, et al. Short-term wind power forecasting based on meteorological feature extraction and optimization strategy[J]. Renewable Energy, 2022, 184: 642-661.
- [15] SHAO Zhen, HAN Jun, ZHAO Wei, et al. Hybrid model for short-term wind power forecasting based on singular spectrum analysis and a temporal convolutional attention network with an adaptive receptive field[J]. Energy Conversion and Management, 2022, 269: 116138.
- [16] 肖白,张博,王辛玮,等. 基于组合模态分解和深度学习的短期风电功率区间预测[J/OL]. 电力系统自动化. (2023-02-07) [2023-02-28]. <http://kns.cnki.net/kcms/detail/32.1180.TP.20230207.1211.003.html>.
- [17] KAZEMI S M, GOEL R, EGHBALI S, et al. Time2Vec: learning a vector representation of time[EB/OL]. [2023-02-28]. <https://arxiv.org/abs/1907.05321>.
- [18] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is

- all you need[EB/OL]. [2023-02-28]. <https://arxiv.org/abs/1706.03762>.
- [19] 臧海祥,许瑞琦,刘璟璇,等. 基于多维融合特征和卷积神经网络的多任务用户短期负荷预测[J/OL]. 电力系统自动化. (2022-11-30)[2023-02-28]. <http://kns.cnki.net/kcms/detail/32.1180.TP.20221130.0922.003.html>.
- [20] GENG Xiulin, HE Xiaoyu, XU Lingyu, et al. Attention-based gating optimization network for multivariate time series prediction[J]. Applied Soft Computing, 2022, 126: 109275.
- [21] 黎静华, 黄玉金, 黄乾. 基于改进混沌时间序列的风电功率区间预测方法[J]. 电力自动化设备, 2019, 39(5): 53-60, 68. LI Jinghua, HUANG Yujin, HUANG Qian. Interval prediction method of wind power based on improved chaotic time series [J]. Electric Power Automation Equipment, 2019, 39(5): 53-60, 68.
- [22] 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.

作者简介:

张 越(1999—),男,硕士研究生,研究方向为电力系统大数据分析、新能源发电预测技术(**E-mail**: 211306080051@hhu.edu.cn);

臧海祥(1986—),男,副教授,博士研究生导师,博士,通信作者,研究方向为电力系统规划与运行分析、新能源发电技术、人工智能在电力系统中的应用(**E-mail**: zanghaixiang@hhu.edu.cn);

程礼临(1995—),男,博士研究生,主要研究方向为电力系统大数据分析、新能源发电技术(**E-mail**: straw@hhu.edu.cn)。

(编辑 陆丹)

Ultra-short-term wind power forecasting based on adaptive time series representation and multi-level attention

ZHANG Yue, ZANG Haixiang, CHENG Lilin, LIU Jingxuan, WEI Zhinong, SUN Guoqiang

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: In view of the problems that the multi-scale time information in wind power data is difficult to describe and the existing methods fail to fully consider the dynamic coupling effects of meteorological factors on wind power, which lead to forecasting performance degradation, an ultra-short-term wind power forecasting method based on adaptive time series representation and multi-level attention is proposed. The wind power sequence is represented by the time embedding layers to obtain its periodic and non-periodic patterns, and then the self-attention is introduced to capture the autocorrelation of the high-dimensional wind power sequence. The wind power and meteorological factors are reconstructed by cross attention to form a multi-dimensional feature sequence containing the coupling relationships between them. One-dimensional convolutional neural networks are used to mine both temporal correlation and spatial correlation of the multi-dimensional feature sequences along the time direction and feature direction respectively. Then, the corresponding temporal features are extracted by the long short-term memory network, and the obtained temporal features are denoised by the global attention and integrated by the gating mechanism, which are then fed to a fully-connected layer to generate point forecasting result and interval forecasting result respectively. Experimental results show that the proposed method can obtain both accurate point forecasting results and reliable forecasting intervals.

Key words: wind power; ultra-short-term forecasting; multi-level attention; deep learning; spatiotemporal correlation; point forecasting; interval forecasting

附录 A




图 A1 基于 Time2Vec 的风电功率序列表示

Fig.A1 Illustration of Time2Vec for wind power series representation




图 A2 多头注意力机制结构示意图

Fig.A2 Structure diagram of multi-head attention mechanism




图 A3 基于 MASTCNN-LSTM 的超短期风电功率点预测流程图

Fig.A3 Flowchart of ultra-short-term wind power point forecasting based on MASTCNN-LSTM




图 A4 基于 QR-MASTCNN-LSTM 的超短期风电功率区间预测流程图

Fig.A4 Flowchart of ultra-short-term wind power interval forecasting based on QR-MASTCNN-LSTM

附录 B





图 B1 不同模型的点预测曲线

Fig.B1 Point forecasting curves of different models


表 B1 3 种置信度下不同模型的区间预测结果

Table B1 Interval forecasting results of different models under three confidence levels


模型	PINC 为 90%			PINC 为 85%			PINC 为 80%		
	e_{ACE}	w_{PINAW}	s_{WS}	e_{ACE}	w_{PINAW}	s_{WS}	e_{ACE}	w_{PINAW}	s_{WS}
QR-TCN	-1.0377	0.1289	-1.9795	-6.8149	0.1070	-2.7268	-9.7075	0.0905	-3.4123
QR-LSTM	-0.8173	0.1190	-1.7611	-2.4279	0.0900	-2.2290	-4.5393	0.0736	-2.6507
QR-Bi-LSTM	-1.3782	0.1142	-1.7924	0.6370	0.0933	-2.2960	2.0713	0.0800	-2.6769
QR-DALSTM	0.5849	0.1175	-1.7032	0.9575	0.0946	-2.1806	-0.0921	0.0742	-2.5186
QR-SATCN-LSTM	0.7252	0.1160	-1.6987	-3.3093	0.0892	-2.1392	-6.9231	0.0728	-2.5197
QR-TACBiLSTM	2.2877	0.1261	-1.7842	3.6819	0.1048	-2.2857	0.0681	0.0818	-2.6959
QR-MASTCNN-LSTM	-0.2764	0.1126	-1.6357	-0.3245	0.0808	-2.1216	2.5321	0.0718	-2.4048



(a) 时段 IV(PINC 为 90%)



(b) 时段 V(PINC 为 85%)



(c) 时段 VI(PINC 为 80%)

图 B2 3 种置信度下不同模型产生的预测区间

Fig.B2 Prediction intervals generated by different models under three confidence levels

表 B2 消融实验的区间预测结果

Table B2 Interval forecasting results of ablation experiment

情形	删除组件	PINC 为 90%			PINC 为 85%			PINC 为 80%		
		e_{ACE}	w_{PINAW}	s_{WS}	e_{ACE}	w_{PINAW}	s_{WS}	e_{ACE}	w_{PINAW}	s_{WS}
A	Time2Vec	-3.1010	0.1131	-1.7476	0.9375	0.0889	-2.1226	-0.8534	0.0731	-2.4964
B	多头自注意力	-1.9992	0.1134	-1.7426	-8.4976	0.0890	-2.2402	-4.5593	0.0771	-2.7020
C	交叉注意力	0.6651	0.1096	-1.6359	-2.4880	0.0817	-2.1450	-1.4744	0.0659	-2.5656
D	全局注意力	0.4046	0.1116	-1.6213	0.3966	0.0874	-2.0521	-7.4038	0.0733	-2.4718
E	—	-0.2764	0.1126	-1.6357	-0.3245	0.0808	-2.1216	2.5321	0.0718	-2.4048

表 B3 考虑、不考虑气象因素时所提模型的预测结果

Table B3 Forecasting results of proposed model with and without considering meteorological factors

是否考虑气象因素	点预测				区间预测								
	e_{RMSE} / MW	e_{MAE} / MW	c_{CORR}	c_{CoD}	PINC 为 90%			PINC 为 85%			PINC 为 80%		
					e_{ACE}	w_{PINAW}	s_{WS}	e_{ACE}	w_{PINAW}	s_{WS}	e_{ACE}	w_{PINAW}	s_{WS}
否	2.243	1.202	0.9717	0.9439	-21.8710	0.1022	-1.7545	-20.8774	0.0811	-2.2200	-20.0040	0.0678	-2.5786
是	2.233	1.197	0.972 0	0.944 3	-0.2764	0.1126	-1.6357	-0.3245	0.0808	-2.1216	2.5321	0.0718	-2.4048




图 B3 风电功率相关数据重构过程

Fig.B3 Reconstruction process of wind power related data