

引用格式:蔡昌春,范靖浩,李源佳,等.基于 TPA-MBLSTM 模型的超短期风电功率预测[J].电力科学与技术学报,2024,39(1):47-56.

Citation: CAI Changchun, FAN Jinghao, LI Yuanjia, et al. Ultra-short-term wind power prediction based on TPA-MBLSTM model[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 47-56.

基于 TPA-MBLSTM 模型的超短期风电功率预测

蔡昌春^{1,3}, 范靖浩^{2,3}, 李源佳^{2,3}, 何瑶瑶^{2,3}

(1. 河海大学人工智能与自动化学院, 江苏 常州 213022; 2. 河海大学信息科学与工程学院, 江苏 常州 213022;
3. 河海大学江苏省输配电装备技术重点实验室, 江苏 常州 213022;)

摘要: 风速变化的间歇性和波动性给风功率的精准预测带来极大挑战, 充分挖掘风电功率与风速等关键因素的内在规律是提高风电功率预测精度的有效途径。提出一种结合时间模式注意力(time pattern attention, TPA)机制的多层堆叠双向长短期记忆网络的超短期风电功率预测方法。首先, 利用基于密度的含噪声空间聚类方法(density based spatial clustering with noise, DBSCAN)和线性回归算法进行风功率数据集的异常值检测, 利用 k 最近邻(k-nearest neighbor, KNN)插值法重构异常点数据; 其次, 综合考虑风电功率与各气象特征的内在关联性, 在 MBLSTM 网络中引入 TPA 机制合理分配时间步长权重, 捕捉风电功率时间序列潜在逻辑规律; 最后, 利用实验仿真数据进行分析验证本文方法的有效性, 该方法能够充分挖掘风功率与风速影响因素的关系, 从而提高其预测精度。

关键词: 风电功率预测; 时间模式注意力机制; 多层堆叠双向长短期记忆网络; 异常数据检测; 基于密度的含噪声空间聚类方法; 线性回归

DOI: 10.19781/j.issn.1673-9140.2024.01.004 中图分类号: TM614 文章编号: 1673-9140(2024)01-0047-10

Ultra-short-term wind power prediction based on TPA-MBLSTM model

CAI Changchun^{1,3}, FAN Jinghao^{2,3}, LI Yuanjia^{2,3}, HE Yaoyao^{2,3}

(1. College of Artificial Intelligence and Automation, Hohai University, Changzhou 213022; 2. College of Information Sciences and Engineering, Hohai University, Changzhou 213022, China; 3. Jiangsu Key Laboratory of Power Transmission & Distribution Equipment Technology, Hohai University, Changzhou 213022, China;)

Abstract: The intermittency and volatility of wind speed changes pose great challenges to the accurate prediction of wind power. Fully exploring the inherent laws of key factors such as wind power and wind speed is an effective way to improve the accuracy of wind power prediction. A method for ultra-short-term wind power prediction is proposed, which incorporates a temporal pattern attention (TPA) mechanism into a multi-layer stacked bidirectional long short-term memory network. Firstly, outlier detection for the wind power dataset is performed using a density-based noisy spatial clustering method (DBSCAN) and a linear regression algorithm, followed by data reconstruction of outlier points using k-nearest neighbor (KNN) interpolation. Next, the intrinsic correlations between wind power and various meteorological features are comprehensively considered, and the TPA mechanism is introduced into the MBLSTM network to properly allocate time step weights, capturing the underlying logical patterns of the wind power time series. Finally, the effectiveness of the proposed method is verified through experimental simulation data analysis. Results show that this method can fully explore the relationship between wind power and wind speed influencing factors, thereby improving its prediction accuracy.

Key words: wind power prediction; TPA mechanism; MBLSTM; anomaly data detection; DBSCAN; linear regression

加快能源消费从传统化石燃料向绿色清洁能源转变, 构建以风电、光伏等可再生能源发电系统
的新型电力系统是实现中国“30·60”目标的关键。风力发电技术的发展也为缓解全球能源危机和温

收稿日期: 2023-04-05; 修回日期: 2023-07-16

基金项目: 国家自然科学基金(51607057); 常州市应用基础研究计划(CJ20220245)

通信作者: 蔡昌春(1981—), 男, 博士, 副教授, 主要从事分布式发电及微电网建模、新能源功率预测等方面的研究; E-mail: fload_cai@163.com

室效应提供了有效的解决方案,但是风力发电系统具有很强的间歇性和波动性^[1-2],其大规模并网给电网规划和稳定运行带来新的挑战。精准的风电功率预测对于提高风能发电系统的利用率,改善电力系统运行的安全性和可靠性具有重要作用,能够更好地与其他发电设备协同工作,减少二氧化碳排放^[3]。

风电功率超短期预测主要是对未来 10 min 至 4 h 内的风电功率进行预测。目前风电功率超短期预测方法主要有物理方法和统计方法^[4]。物理方法主要包括 3 个关键过程:降尺度模型、风力转换模型和模型输出统计^[5],其建模过程复杂,计算成本和难度较高。统计方法主要分析历史风电数据的统计分布特征,实际风电功率与历史风电功率呈非线性关系,建立气象预报数据进行预测,主要方法有卡尔曼滤波模型、ARMA 模型、人工神经网络模型^[6-9]。

随着技术的发展,人工智能、深度学习等技术也广泛应用于风电功率预测领域^[10-14]。文献[15]采用小波降噪方法对原始数据进行降噪和重构,并结合混沌分析和长短期记忆网络对风电功率进行预测。文献[16]首先利用 Pearson 距离分析法筛选出与风电功率相关程度高的变量进而降低数据复杂度,然后利用长短记忆网络(long short-term memory, LSTM)网络对多变量时间序列进行动态时间建模,较人工神经网络(artificial neural network, ANN)和支持向量机(support vector machines, SVM)等常规机器学习算法具有更高的预测精度。文献[17]引入卷积神经网络(convolutional neural network, CNN)来压缩门控循环单元(gate recurrent unit, GRU)隐藏状态以减少模型输出量,克服训练过程中的梯度爆炸和消失问题。上述预测方法局限于按正序数据序列对数据进行处理,忽视了反向数据信息流变换规律的影响,造成在输入时间序列数据较长时易丢失序列信息。文献[18]利用注意力模型优化长短期记忆网络的特征向量从而优化 LSTM 网络的权重以提升预测精度。文献[19]在 LSTM 神经网络预测过程中引入双重注意力机制(DA-LSTM),自适应挖掘功率与相关输入特征参数及时序之间的关联。文献[20]提出了时间模式注意力机制,使用时间序列频域信息提取数据中潜在的时序特征。

由于电网调控和设备故障造成电网运行数据不完整或者不充分,异常数据的存在造成风电功率预测效果不佳^[21-23]。文献[24]中采用孤立森林算法对风电数据集进行异常检测,方法简单但存在很多

正常值被误认定为异常的情况。文献[25]运用 K-means 算法识别风机数据中的异常值,但 K-means 算法聚类簇个数以及簇中心值的选取对结果有较大影响。

针对上述问题,本文提出一种基于时间模式注意力机制的多层堆叠双向长短期记忆网络的超短期风电功率预测方法。首先,利用基于密度的含噪声空间聚类方法(density based spatial clustering with noise, DBSCAN)和线性回归算法组合进行数据集的异常值检测,将来自数据采集系统的数据进行异常检测,并通过 k 最邻近(k-nearest neighbor, KNN)插值法对异常数据重构;其次,为进一步加强长短期记忆神经网络在时间序列信号特征提取能力,挖掘天气影响因素间的解耦关系从而提高神经网络预测精度及泛化能力,本文引入时间模式注意力机制,通过对不同时间步权重的合理分配,捕捉风电功率时间序列潜在在逻辑规律,提升预测精度。最后通过实验证明本文提出方法的有效性和准确性。

1 风电功率数据异常值检测与处理

1.1 数据分析

现有研究表明,风速和功率近似为三次方的关系,由于实际数据集中存在大量异常值,使风速功率特性呈离散状。准确识别并消除异常数据可以有效提高风电功率预测精度和可信度。功率数据的异常值分 3 种类型^[22],如图 1 所示。

类型 1 该异常的特征是没有输出功率,风速大于切入风速。

类型 2 这些异常随机分布在特征空间中,主要是由于传感器故障或信号处理中的噪声引起的。

类型 3 这些异常的特征是稳定和持续的正功率输出,功率低于涡轮机的额定功率。




图 1 异常值类型

Figure 1 Outlier types

1.2 数据异常检测

DBSCAN为一种经典的密度聚类方法,相比于K-means等只能用于凸样本集检测的方法相比,DBSCAN的泛用性更广,无需手动确认聚类的数量,可以聚类任意形状的数据,能够有效地进行噪声和离群点筛选。

假设样本集为 $D=(x_1, x_2, \dots, x_n)$,那么使用DBSCAN进行密度描述的定义如下:

邻域:以选定目标为中心,半径为 ϵ 的区域即为该目标的邻域;

核心对象:若选定目标对象邻域内的样本数量大于邻域密度阈值 P_{smin} ,则称该目标对象为核心对象;

密度直达:在样本集 D 中,若点 m 在核心对象 n 的 ϵ 邻域内部,则称点 m 从点 n 密度直达;

密度可达:在样本集 D 中,对于 x_i 和 x_j ,若存在序列点 P_1, P_2, \dots, P_n ,满足 $p_1 = x_i, p_i = x_j$,且 p_{i+1} 可由 p_i 密度直达,则称 x_j 从 x_i 密度可达;

密度相连:在样本集 D 中,若存在点 o 到点 m 和点 n 都密度可达,则称 m, n 密度相连;

DBSCAN聚类即为一个从密度可达关系延展出最大密度相连的集合,利用 P_{smin} 和 ϵ 这2个参数,可以将样本集分为核心点、边缘点和离群点3种。核心点是指在其邻域半径范围内样本点数量大于等于 P_{smin} 的数据点;边缘点是指在其邻域半径范围内样本点数量小于 P_{smin} 但位于其他核心点的邻域内的数据点,不满足以上2种情况的其他样本点为离群点。DBSCAN算法具体执行步骤如下:

1) 初始化参数,设定邻域半径 ϵ 和邻域密度阈值 P_{smin} ,将所有点初始化为未访问状态;

2) 随机选择一个未访问状态的数据点 P ,计算其邻域内样本点数;

3) 若数据点 P 是核心点,则将点 P 和其密度可达点形成一个新簇,递归计算当前簇中的数据点是否为核心点来扩展当前簇,直至没有新的核心点;

4) 若数据点 P 为边缘点,则将其归于邻域内核心点的簇,其他的点标记为离群点;

5) 重复步骤2)到步骤4),直至所有点被处理完,得到的离群点为异常值数据。

由于风速和功率近似为三次方关系,为了充分识别异常数据,本文采用线性回归算法对异常值进

行补充检测。首先,构建线性回归模型拟合功率和风速,然后将功率值输入到训练好的线性回归模型中以获得预测风速值,计算预测值与真实值的偏差,并设定阈值,当实际偏差超过设定阈值时,则判定该点数据异常。

1.3 异常数据重构

处理异常数据通常在数据量足够大时删除一些异常数据和缺失数据,但这种方法会破坏数据的完整性,使原始数据的时序连续性降低,影响后续建模的精度。通过对被删除的异常数据和缺失数据进行重构,能使数据保持完整性和时序连续性。KNN是通过选取邻近样本,利用样本值的均值、中位数进行异常数据的填充。具体过程如下。

首先,计算样本与目标点的距离 d_i 为

$$d_i = \sqrt{\sum_{i=1}^n (c_x - c_i)^2} \quad (1)$$

$$\omega_i = \frac{1}{d_i} \quad (2)$$

式中, c_x 为目标样本; c_i 为邻近样本; ω_i 为样本权重; d_i 为样本与目标点的距离; n 为邻近样本点个数。

通过计算不同样本之间的距离,可以获得距离矩阵 D ,然后计算权重矩阵,最后计算目标样本估计值为

$$g = \sum_{i=1}^n \omega_i \cdot x_i \quad (3)$$

式中, x_i 为临近样本相应位置上的数值; n 为邻近样本点个数。

2 TPA-MBLSTM 预测模型

2.1 多层双向LSTM模型

局限于单向记忆网络结构,LSTM神经网络只能存储并记忆过去与当前的信息,这可能导致预测结果出现误差累积的情况。LSTM可以被视作单个非线性单元,用于构建其他大型、复杂的深度神经网络。一般来说,双向LSTM神经网络(bidirectional long short-term memory, BiLSTM)能够同时利用过去时刻和未来时刻的信息,由正向和反向LSTM单元组成,从而增强训练记忆;而深层LSTM神经网络能够深度刻画数据特征,保证数据的准确性。

BiLSTM网络由正向LSTM和反向LSTM构成,分别用于获取输入序列过去时刻和未来时刻的时序信息进行正向和反向训练,同时将正反的隐

含层输出作为输出层的输入。在 t 时刻, BiLSTM 网络隐含层的输出值 h_t 由正向 LSTM 隐含层输出和反向 LSTM 隐含层输出组成, 双向 LSTM 神经网络的数学模型如下:

$$\begin{cases} \vec{h}_t = L_{\text{STM}}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = L_{\text{STM}}(x_t, \overleftarrow{h}_{t-1}) \\ h_t = [\vec{h}_t, \overleftarrow{h}_t] \end{cases} \quad (4)$$

式中, x_t 为 t 时刻的输入; \vec{h}_{t-1} 为 $t-1$ 时刻正向 LSTM 隐含层输出; \overleftarrow{h}_{t-1} 为 $t-1$ 时刻反向 LSTM 隐含层输出。

多层堆叠双向 LSTM 神经网络 (multilayer bidirectional LSTM, MBLSTM) 是双向 LSTM 神经网络深度不断拓展的过程, 对神经网络的输入数据进行反复多次训练, 提高预测准确度。MBLSTM 结构如图 2 所示。

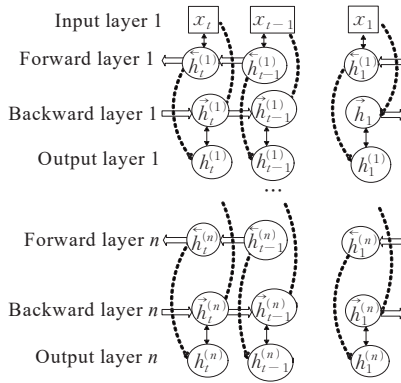


图 2 MBLSTM 网络结构
Figure 2 MBLSTM network structure

2.2 时间模式注意力机制

传统注意力机制注重选择与当前时间步骤相关的信息, 在处理只含单一时间序列数据时效果较好。然而, 在风电功率预测中, 数据包括风电功率时间序列和天气因素, 由于各时间步含有多个变量, 其影响因素多样且相互间存在复杂的非线性联系。传统注意力机制对多个时间步骤的信息进行平均, 难以有效捕捉某个时间步作为注意重点。时间模式注意力机制 (temporal pattern attention, TPA) 利用时间序列的频域信息提取数据中潜在的时序特征, 能够有效挖掘各变量与风电功率时间序列的内在联系, 其结构示意如图 3 所示。图 3 中显示了前一级神经网络隐含层输出的信息, 每个信息代表了前一级网络的时间状态, 然后通过多个卷积层过滤器提取特征。




图 3 时间模式注意力机制示意
Figure 3 Schematic diagram of attention mechanism in time mode

假设通过 MBLSTM 网络产生的隐藏层信息为 $H = \{h_{t-w}, h_{t-w+1}, \dots, h_{t-1}\}$, 其中 h_t 为 t 时刻的隐藏层信息, w 为用于选取一定长度的时间数据的时间滑动窗口的长度, T 为过滤器提取的权重最大长度, 一般情况下与窗口滑动长度相等。对原始隐藏层信息 H 进行卷积计算, 产生一个 $n \times k$ 维的矩阵 H^C :

$$H_{i,j}^C = \sum_{l=1}^{\omega} H_{i,(t-\omega+1+l)} \cdot C_{j,T-\omega+l} \quad (5)$$

式中, C_j 为过滤器; $H_{i,j}^C$ 为第 i 行向量通过 C_j 中第 j 个长度为过滤器提取的特征值; t 为时间; ω 为过滤器长度; T 为过滤器提取的权重最大长度, 通常取 ω 。

通过将隐藏层函数 h_t 与 H^C 计算得到权重 α_i , 该权重表示 $H_{i,j}^C$ 中每一行对隐含层函数 h_t 的影响强度, 即每个时间序列对于 h_t 的影响值。 W_a 为 $m \times k$ 的权重系数, 计算为

$$f(H_i^C, h_t) = (H_i^C)^T W_a h_t \quad (6)$$

$$\alpha_i = \text{sigmoid}(f(H_i^C, h_t)) \quad (7)$$

其中, H_i^C 为 H^C 中第 i 行的向量。

对 H_i^C 进行加权求和, v_t 表示 H_i^C 所有行对于 h_t 的综合影响, 也就是时间影响力, 即

$$v_t = \sum_{i=1}^n \alpha_i H_i^C \quad (8)$$

其中, n 为输入变量的特征数。

最后综合考虑时间影响力 v_t 的影响, 获得最终预测值 h'_t 表示为

$$h'_t = W_h h_t + W_v v_t \quad (9)$$

其中, W_v 、 W_h 分别为矩阵参数权重。

2.3 TPA-MBLSTM 预测模型

本文提出 TPA-MBLSTM 预测模型, 通过多层双向长短期记忆神经网络提取数据中的长短期时间序列特征, 并通过 TPA 机制提取重要信息, 提升预测性能, 基于 TPA-MBLSTM 模型的超短期风电功率预测的流程如图 4 所示。具体步骤如下:

1) 将原始数据进行预处理, 首先采用 Pearson

相关系数和显著性水平 P 值计算功率与影响因素的非线性相关性,实现对输入特征的筛选;

2) 利用 DBSCAN 和线性回归算法组合进行数据集的异常值检测并用 KNN 插值法进行填补,最后标准化样本数据,消除量纲对数据的影响;

3) 搭建 TPA-MBLSTM 预测模型,将处理好

的数据输入神经网络进行训练,通过调试获取最优的模型参数;

4) 使用训练完成的网络在测试集样本上进行预测,并利用均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)进行误差分析。

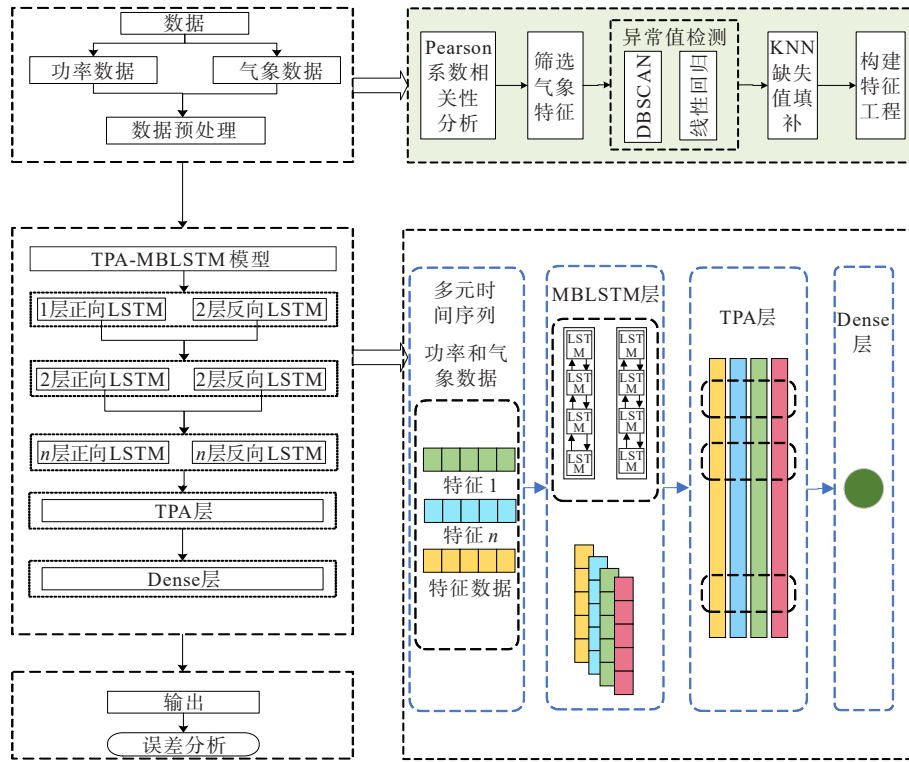


图 4 预测流程

Figure 4 Forecast flowchart

2.4 误差评价指标

本文选取回归分析中常用的评价指标:MAE、RMSE 评价预测模型的性能,其定义分别为

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (10)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (11)$$

式中, y_i 为第 i 个样本点真实值; y'_i 为第 i 个样本点预测值; n 为数据点个数。

3 算例分析

3.1 数据说明

为验证所提预测模型的准确性,本文采用的数据集来源于荷兰的某风力发电场。该数据记录了风力发电场 2018—2019 年的运行数据,采样频率为

10 min/次,每天 144 个点。并包含了空气密度、温度、风速、风向、湿度、大气压强等气象数据。

选取了空气密度、温度、风速、风向、湿度、大气压强 6 个指标进行 Pearson 系数和显著性水平 P 值的计算,结果如表 1 所示。并绘制相关性热图,结果如图 5 所示。

表 1 气象因素与风电功率相关性系数

Table 1 Correlation coefficients between meteorological factors and wind power

气象参数	Pearson 系数	P 值
风速	0.70	0.00
风向	0.17	2.23 e-240
空气密度	0.08	4.6 e-279
温度	-0.22	0.00
湿度	-0.21	0.00
大气压强	-0.06	2.34 e-40

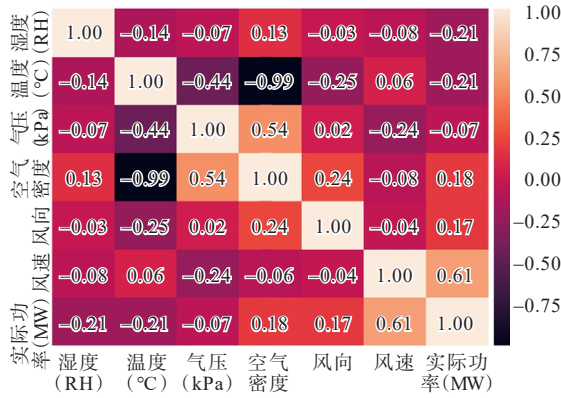


图5 特征相关性热图

Figure 5 Characteristic correlation heat map

综上所述,风速与发电功率高度相关,空气密度和风向其次,大气压强、温度和湿度与发电功率的相关度较弱。因此本文选取风速、风向的正弦值、风向的余弦值、空气密度作为风电发电功率的影响因子进行后续研究。

图6~9为不同季节的风力玫瑰图,四季风速都具有很强的随机性,但风速(W_s)和风向的趋势各个季节有明显不同,其中冬季风速较高且波动性最强,夏季风速较小,春、秋两个季节盛行西南风,风速适中。




图6 春季风力玫瑰

Figure 6 Wind rose chart of spring




图7 夏季风力玫瑰

Figure 7 Wind rose chart of summer




图8 秋季风力玫瑰

Figure 8 Wind rose chart of autumn




图9 冬季风力玫瑰

Figure 9 Wind rose chart of winter

3.2 功率数据异常值检测与处理

本文利用DBSCAN算法和线性拟合方法组合完成数据清洗。首先,对风速—功率散点图中分散点采用DBSCAN密度聚类异常值检测方法进行检测,DBSCAN有2个重要参数分别是邻域半径 ϵ 和最小样本数 P_{smin} ,一般通过人工选取,设定 ϵ 为0.08, P_{smin} 为220,实验结果如图10所示,聚类后将少数样本群体作为异常点。由于部分异常数据密度较大且与正常风速—功率曲线部分相连,难以通过人工调节邻域半径 ϵ 和最小样本数 P_{smin} 区分,进而采用线性回归算法对未被检测出的异常值进行补充识别。通过线性模型拟合风速和功率并计算预测值和真实值的误差值,当误差大于阈值则判定该点为异常值,实验结果如图11所示。该组合方法能够准确识别数据集中使风速—功率特性呈离散状的大量异常值。

为了保证数据时序连续性,在剔除异常值之后运用KNN算法通过选取近邻样本,通过样本值的均值、中位数进行缺失数据的填充。图12为经过异常值检测和数据重构后的风速功率特性曲线,该曲线与理论风速功率曲线已基本吻合。




图 10 DBSCAN

Figure 10 DBSCAN




图 11 线性回归

Figure 11 Linear regression




图 12 KNN 插值法

Figure 12 KNN interpolation method

为了验证异常值检测与处理方法的有效性,将原始数据集和异常值处理后的数据集基于 LSTM 算法模型进行预测对比。实验前划分实验数据,分别将数据集中 2018 年数据划分为训练集,2019 年的数据划分为测试集。得到实验预测误差如表 2 所示。

表 2 原始数据集和处理后数据集预测误差对比

Table 2 Comparison of prediction errors between original data set and processed data set MW

数据集	MAE	RMSE
原始	5.482	8.518
DBSCAN 处理后	5.329	8.062
DBSCAN 和线性回归处理后	5.244	7.961

由此可见,在经过 DBSCAN 算法和线性拟合方法组合完成数据清洗后,平均绝对误差和均方根误差都有所降低,预测的效果优于未经过异常值处理的原始数据集的预测效果。

3.3 模型预测结果与分析

为了验证本文算法的准确性,选取 BP、LSTM、GRU、BiLSTM、DA-LSTM^[19] 以及 TPA-LSTM 等模型进行实验对比。选取原始数据集中春、夏、秋、冬 4 个季节中各 1 天的数据作为测试集,其余数据经过 DBSCAN 和线性回归处理后作为训练集。预测结果如图 13~16 所示,预测误差对比如表 3 所示。




图 13 预测模型的对比实验结果(春季)

Figure 13 Comparative experimental results of prediction models (spring)

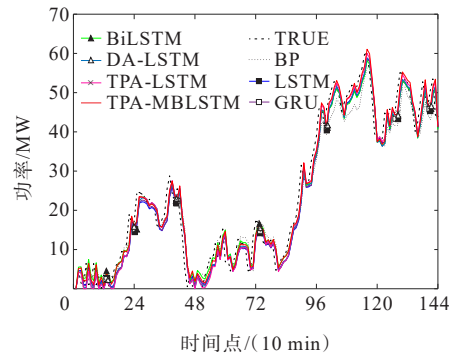


图 14 预测模型的对比实验结果(夏季)

Figure 14 Comparative experimental results of prediction models (summer)

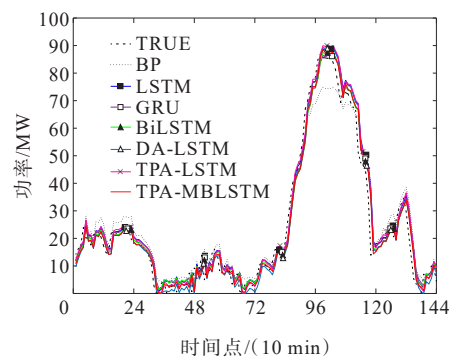


图 15 预测模型的对比实验结果(秋季)

Figure 15 Comparative experimental results of prediction models (winter)




图16 预测模型的对比实验结果(冬季)

Figure 16 Comparative experimental results of prediction models (winter)

表3 预测误差对比

Table 3 Prediction errors comparison MW

季节	模型	RMSE	MAE
春季	BP	6.148	4.827
	LSTM	4.455	3.368
	GRU	4.402	3.345
	BiLSTM	4.391	3.320
	DA-LSTM	4.284	3.248
	TPA-LSTM	4.174	3.198
	TPA-MBLSTM	4.087	3.099
夏季	BP	4.374	3.442
	LSTM	3.788	3.027
	GRU	3.775	2.996
	BiLSTM	3.627	2.868
	DA-LSTM	3.734	2.949
	TPA-LSTM	3.603	2.840
	TPA-MBLSTM	3.518	2.737
秋季	BP	5.850	4.427
	LSTM	4.745	3.359
	GRU	4.449	3.184
	BiLSTM	4.427	3.182
	DA-LSTM	4.656	3.466
	TPA-LSTM	4.675	3.289
	TPA-MBLSTM	4.306	3.113
冬季	BP	4.690	3.869
	LSTM	3.473	1.965
	GRU	3.178	1.541
	BiLSTM	3.134	1.445
	DA-LSTM	3.274	1.681
	TPA-LSTM	3.164	1.487
	TPA-MBLSTM	3.101	1.442

由图13~16可知,各模型在各季度的风电功率预测中具有较好的效果,针对不同季节、风机不同运行方式下本文方法TPA-MBLSTM模型具有更高的精度和预测能力。由表3可知,本文方法的RMSE和MAE指标在春、夏、秋、冬分别为4.087、3.518、4.306、3.101 MW和3.099、2.739、3.113、1.442 MW。特别是在春季典型日中,相比BP、LSTM、GRU、BiLSTM、DA-LSTM、TPA-LSTM,本文方法在RMSE上分别降低了33.52%、8.26%、7.16%、6.92%、4.60%和2.08%,MAE分别降低了35.80%、7.99%、7.35%、6.66%、4.59%和3.10%,其他季节数据见表3。

结合图6~9风力玫瑰图和图13~16模型预测过程可知,单一神经网络在面对风速变化剧烈的情况时(如春季和秋季)预测精度误差较大。通过时间模式注意力机制挖掘风速时序关联性和风速一功率的耦合性,利用多层双向LSTM神经网络层间非线性特征以及深层隐藏关联学习能力,快速捕捉气象因素的剧烈变化的相关特征,如图16所示。另外,由图13~15可知,传统LSTM模型在功率波动剧烈情况下不能适应功率的快速变化,其预测结果小于实际功率,偏差较大。结合图16冬季典型日模型实验对比结果和表3冬季预测结果可知,在功率波动平缓时段各模型都能较好地预测风电功率。

另外由表3可知,相较于LSTM模型,TPA-LSTM模型在4个典型日中的RMSE指标分别降低了6.18%、4.88%、1.48%和8.90%,MAE指标分别降低了5.05%、6.18%、2.08%和24.33%。TPA机制下的网络模型损失值相对更小,这是由于TPA机制对隐藏行状态矩阵进行特征提取,从不同时间步选择相关信息为时间模式矩阵分配权重,因此其能在各时段预测上均表现出较好的效果。多层堆叠双向LSTM神经网络对输入数据进行反复多次训练,增加了模型对于数据依赖性和系统的鲁棒性,加强了模型刻画信息的能力;同时引入时间模式注意力机制可以捕捉到时间序列中更重要的历史信息,通过对不同时间步权重的合理分配能够更好地提取数据中潜在的时序特征。

4 结语

本文提出了一种考虑时间模式注意力机制的多层堆叠双向LSTM神经网络的超短期风电功率预测方法。该方法充分挖掘超短期风功率与风速

等因素的内在关联性,利用时间模式注意力机制和多层堆叠双向LSTM神经网络针对风功率时序数据信息捕捉能力,建立风功率与风速、风功率历史数据等信息耦合关系,从而提高预测精度。另外,针对历史训练数据缺失、异常等问题,采用基于密度的含噪声空间聚类方法和线性拟合方法,准确识别训练数据的异常值并进行缺失填充。针对不同季节的预测实验验证了本文方法的有效性和合理性。

参考文献:

- [1] 张春雁,窦真兰,王俊,等. 电解水制氢—储氢—供氢在电力系统中的发展路线[J]. 发电技术,2023,44(3):305-317.
ZHANG Chunyan, DOU Zhenlan, WANG Jun, et al. Development route of hydrogen production by water electrolysis, hydrogen storage and hydrogen supply in power system[J]. Power Generation Technology, 2023, 44(3):305-317.
- [2] 欧旭鹏,任涛,王玉鹏,等. 基于改进麻雀搜索算法优化深度学习网络超参数的短期风电功率预测[J]. 智慧电力,2023,51(3):31-38+52.
OU Xupeng, REN Tao, WANG Yupeng, et al. Short-term wind power prediction by optimizing deep learning network hyper-parameters based on ISSA[J]. Smart Power, 2023, 51(3):31-38+52.
- [3] 李雪玲,刘洋,李振伟,等. 基于气象分型改进构造不确定集的多微网低碳鲁棒经济调度[J]. 电力建设,2023,44(8):142-156.
LI Xueling, LIU Yang, LI Zhenwei, et al. Robust low-carbon economic dispatch of multiple microgrids based on improved uncertainty set of meteorological classification[J]. Electric Power Construction, 2023, 44(8): 142-156[J]. Electric Power Construction, 2023, 44(8):142-156.
- [4] 贾睿,杨国华,郑豪丰,等. 基于自适应权重的CNN-LSTM&GRU组合风电功率预测方法[J]. 中国电力, 2022,55(5):47-56+110.
JIA Rui, YANG Guohua, ZHENG Haofeng, et al. Combined wind power prediction method based on CNN-LSTM & GRU with adaptive weights[J]. Electric Power, 2022, 55(5):47-56+110.
- [5] 杨本星,王伟,杨明轩,等. 辅助风电并网的构网型储能控制策略研究[J]. 高压电器,2023,59(7):56-64.
YANG Benxing, WANG Wei, YANG Mingxuan, et al. Research on grid-forming energy storage control strategy for auxiliary wind power grid-connection[J]. High Voltage Apparatus, 2023, 59(7): 56-64.
- [6] 韩丽,于晓娇,喻洪波,等. 基于波动趋势分段的风电功率区间预测[J]. 电力系统自动化,2023,47(18):206-215.
HAN Li, YU Xiaojiao, YU Hongbo, et al. Wind power interval prediction based on fluctuation trend segmentation[J]. Automation of Electric Power Systems, 2023, 47(18):206-215.
- [7] 胡正阳,高丙团,张磊,等. 风电机组双向支撑能力分析与自适应惯量控制策略[J]. 电工技术学报,2023,38(19): 5224-5240.
HU Zhengyang, GAO Bingtuan, ZHANG Lei, et al. Bidirectional support capability analysis and adaptive inertial control strategy of wind turbine[J]. Transactions of China Electrotechnical Society, 2023, 38(19): 5224-5240.
- [8] 刘新宇,蒲欣雨,李继方,等. 基于贝叶斯优化的VMD-GRU短期风电功率预测[J]. 电力系统保护与控制, 2023,51(21):158-165.
LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. Power System Protection and Control, 2023, 51(21):158-165.
- [9] 汤义勤,邹宏亮,蒋旭,等. 基于VMD和贝叶斯优化LSTM的母线负荷预测方法[J]. 电网与清洁能源,2023, 39(02):46-52+59.
TANG Yiqin, ZOU Hongliang, JIANG Xu, et al. A bus load forecasting method based on VMD and bayesian optimization LSTM[J]. Power System and Clean Energy, 2023, 39(02):46-52+59
- [10] 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 collaborative training[J]. Electric Power Engineering Technology, 2023, 42(6):232-240.
- [11] 基于频域分解和精度加权集成的分布式风电功率预测方法[J]. 电力建设,2023,44(5):84-93.
WANG Shaomin, WANG Shouxiang, ZHAO Qianyu, et al. Distributed wind power forecasting method based on frequency domain decomposition and precision-weighted ensemble[J]. Electric Power Construction, 2023, 44(5):84-93
- [12] 庞博文,丁月明,杜善慧,等. 基于CEEMDAN-BO-LSTNet的风电出力短期预测[J]. 电测与仪表,2023,60(9):109-116+170.
PANG Bowen, DING Yueming, DU Shanhui, et al. Short-term forecasting of wind power output based on CEEMDAN-BO-LSTNet[J]. Electrical Measurement & Instrumentation, 2023, 60(9):109-116+170.
- [13] 唐冬来,周强,宋卫平,等. 基于网格聚类的峡谷风电短期功率预测方法[J]. 供用电,2023,40(1):80-87.
TANG Donglai, ZHOU Qiang, SONG Weiping, et al. Short

- term power prediction method for canyon wind power based on grid clustering[J]. *Distribution & Utilization*, 2023,40(1):80-87.
- [14] 王鑫,李慧,叶林,等.考虑风速波动特性的VMD-GRU短期风电功率预测[J].*电力科学与技术学报*,2021,36(4):20-28.
WANG Xin,LI Hui,YE Lin,et al.VMD-GRU based short-term wind power forecast considering wind speed fluctuation characteristics[J]. *Journal of Electric Power Science and Technology*,2021,36(4):20-28.
- [15] 张群,唐振浩,王恭,等.基于长短时记忆网络的超短期风功率预测模型[J].*太阳能学报*,2021,42(10):275-281.
ZHANG Qun,TANG Zhenhao,WANG Gong,et al.Ultra-short term wind power forecasting model based on short-term and short-term memory network[J]. *Acta Energiac Solaris Sinica*,2021,42(10):275-281.
- [16] 朱乔木,李弘毅,王子琪,等.基于长短期记忆网络的风电场发电功率超短期预测[J].*电网技术*,2017,41(12):3797-3802.
ZHU Qiaomu,LI Hongyi,WANG Ziqi,et al.Short-Term Wind Power Forecasting Based on LSTM[J]. *Power System Technology*,2017,41(12):3797-3802.
- [17] 薛阳,王琳,王舒,等.一种结合CNN和GRU网络的超短期风电预测模型[J].*可再生能源*,2019,37(3):456-462.
XUE Yang,WANG Lin,WANG Shu,et al.An ultra-short-term wind power forecasting model combined with CNN and GRU net-works[J]. *Renewable Energy Resources*, 2019,37(3):456-462.
- [18] 韩朋,张晓琳,张飞,等.基于AM-LSTM模型的超短期风电功率预测[J].*科学技术与工程*,2020,20(21):8594-8600.
HAN Peng,ZHANG Xiaolin,ZHANG Fei,et al.Ultra-short-term wind power prediction based on AM-LSTM model[J]. *Science Technology and Engineering*, 2020,20(21):8594-8600.
- [19] 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.
YANG Jingxian,ZHANG Shuai,LIU Jichun,et al.Short-term photovoltaic power prediction based on variational mode decomposition and long short-term memory with dual-stage attention mechanism[J]. *Automation of Electric Power Systems*,2021,45(3):174-182.
- [20] SHIH S Y,SUN F K,LEE H.Temporal pattern attention for multivariate time series forecasting[J]. *Machine Learning*,2019,108:1421-1441.
- [21] 杨茂,杨琼琼.风电机组风速—功率特性曲线建模研究综述[J].*电力自动化设备*,2018,38(2):34-43.
YANG Mao,YANG Qionqiong.Review of modeling of wind speed-power characteristic curve for wind turbine [J]. *Electric Power Automation Equip-ment*, 2018,38(2):34-43.
- [22] MORRISON R,LIU X,LIN Z.Anomaly detection in wind turbine SCADA data for power curve cleaning[J]. *Renewable Energy*,2022,184:473-486.
- [23] 娄建楼,胥佳,陆恒,等.基于功率曲线的风电机组数据清洗算法[J].*电力系统自动化*,2016,40(10):116-121.
LOU Jianlou,XU Jia,LU Heng.Wind turbine data-cleaning algorithm based on power curve[J].*Automation of Electric Power Systems*,2016,40(10):116-121.
- [24] KISVARI A,LIN Z,LIU X.Wind power forecasting-A data-driven method along with gated recurrent neural network[J].*Renewable Energy*,2021,163:1895-1909.
- [25] KUSIAK A,VERMA A.Monitoring wind farms with performance curves[J].*IEEE transactions on sustainable energy*,2012,4(1):192-199.