

DOI: 10.19783/j.cnki.pspc.191591

结合交叉局部异常因子和注意力机制的 超短期风电功率预测方法

汪欣¹, 蔡旭¹, 李征²

(1. 上海交通大学风电研究中心, 上海 200240; 2. 东华大学计算机科学与技术学院, 上海 201620)

摘要: 风电样本数据的质量和风功率预测模型的结构直接影响风电功率预测的精度, 提出一种结合交叉局部异常因子(Local Outlier Factor, LOF)和注意力机制的高精度超短期风电功率预测方法。通过交叉 LOF 算法进行分钟级的风电数据异常孤立点检测, 有效提高了样本数据的质量。通过增加注意力机制避免长短期记忆(Long Short-Term Memory, LSTM)算法在编解码过程中固定长度向量导致的数据特性损失问题, 从而更有效利用历史数据的特征, 提高风功率预测的精度。最后, 对真实风场实测数据进行实验分析, 验证了所述方法的可行性与准确性。

关键词: 风电功率预测; 局部异常因子; 数据预处理; 注意力机制

Ultra-short-term wind power forecasting method based on a cross LOF preprocessing algorithm and an attention mechanism

WANG Xin¹, CAI Xu¹, LI Zheng²

(1. Wind Power Research Center, Shanghai Jiao Tong University, Shanghai 200240, China;

2. School of Information Science and Technology, Donghua University, Shanghai 201620, China)

Abstract: The quality of wind power sample data and the structure of a wind power prediction model directly affect the accuracy of wind power prediction. A high-precision ultra-short-term wind power prediction method combining cross Local Outlier Factor (LOF) and an attention mechanism is proposed. Outlier detection is of wind power data at minute level by a cross LOF algorithm. This effectively improves the quality of sample data to avoid the loss of data characteristics caused by a fixed length vector in the encoding and decoding process of the Long Short Term Memory (LSTM) algorithm. An attention mechanism is added, so that the characteristics of historical data can be used more effectively to improve the accuracy of wind power prediction. Finally, the feasibility and accuracy of the method proposed are verified by the experimental analysis of real wind field measured data.

This work is supported by National Natural Science Foundation of China (No. 51677117) and Key Research and Development Program of Shandong Province (No. 2019JZZY020804).

Key words: wind power prediction; local outlier factor; data preprocessing; attention mechanism

0 引言

大规模风能开发与高比例风电并网是目前的大趋势, 是实现能源可持续发展的战略需求^[1]。电力系统的安全稳定运行需要实现能量的实时平衡, 但风能出力受外界环境影响大, 具有随机性、波动性、间歇性、周期性的特点^[2]。为解决两者之间的矛盾,

在电网调度尺度上对风电功率进行准确预测, 利用预测数据提高系统的调度能力, 是最为经济的手段, 可有效地减少储能设备、灵活调节源端的投资^[3]。超短期预测指预测未来 15 min 至 4 h 内的风电出力, 可以帮助制定合理的电网调度指令, 实现短期内的电力平衡^[4]。

风电预测的方法通常分为三类: 机理预测、数据驱动预测和空间相关性预测^[5]。机理预测, 通常根据流体力学、热力学等知识建立物理模型, 通过求解非线性方程和风力机的功率曲线等计算风机的

基金项目: 国家自然科学基金资助(51677117); 山东省重点研发计划资助(2019JZZY020804)

输出功率。文献[6]基于随机矩阵理论建立了考虑风场状态的超短期预测模型。它无需大量历史数据,但建立模型需要明确刻画风电转化机理,同时会涉及很多难以定量表达的信息,如地形、地貌等^[7]。数据驱动预测通过分析历史样本数据来构建反映风速与风电功率之间非线性关系或风电功率变化趋势的模型。人工智能技术的应用为基于数据驱动的风电预测注入新的活力。传统的数据驱动预测有移动平均法、最小二乘回归算法等,文献[8]通过将预测误差校正与最小二乘支持向量回归算法结合,实现风电功率预测精度的提高。传统的数据驱动预测通过建立基于历史数据的非线性关系来训练预测模型,将动态时间建模问题转化为静态空间建模问题,忽略了风能的动态特性。而风电功率是一个典型的时间序列问题。循环神经网络(Recurrent Neural Network, RNN)考虑时间序列的时间相干性,从而可以利用历史信息。文献[9]指出 LSTM 算法对 RNN 简单的结构进行改造,保留 RNN 算法的递归特性的同时,避免传统 RNN 训练过程中的梯度消失和梯度爆炸问题,可以更好地利用时间序列的性质。文献[10]将循环网络与卷积时间网络相结合以提高预测精度。文献[11]将循环网络与变模式分解相结合从而提高预测的精度。空间相关性预测考虑风场的环境因素对预测精度进行优化,如文献[12]研究风场的地形条件和风场间距离等对预测效果的影响。

数据驱动预测的精度不仅取决于预测模型,而且取决于高质量的原始数据。高质量的预测效果必然依赖高质量的原始数据源,合理有效的数据预处理方法可以改进数据的质量,提高后续预测的准确率和效率^[13]。真实风电数据中,大多数情况下存在噪音,特别是分钟级的超短期预测,风电数据本身波动性、随机性极强,原始数据本身携带的噪音对预测效果的影响较大。GB/T 18710-2002 标准对数据检验质量提出了规定要求,但该标准只规定了小时级的数据质量标准^[14]。而对分钟级的风电数据并无统一标准。因此,针对分钟级的风电数据,可以通过统计学角度进行噪音识别与去除。常用的数据去噪方法如卡尔曼滤波^[15]、小波去噪^[16],是对单一的变量进行去噪平滑,但现实中风速的变化极为迅速,随机性很强,特别是分钟级的风电数据,其波动规律是预测的重点,类似卡尔曼滤波算法对风电数据的去噪,很难判断这类方法去除的是“噪音”还是我们一直寻求的“真相”^[17]。

本文提出一种结合交叉局部异常因子和注意力机制的风电功率预测方法。针对样本质量问题,考虑风向、风速与风功率间强相关特性,提出交叉验

证 LOF 算法的多尺度风电数据检验策略;针对预测模型合理性,考虑多种环境因素,利用注意机制对不同的时间节点分配不同的权重,结合 LSTM 算法更好地提取长时间尺度历史数据的有效特征信息,从而提高预测模型的精度;最后,采用某风场实测风电数据,验证了该方法的可行性与准确性。

1 结合交叉局部异常因子的多尺度数据预处理策略

GB/T 18710-2002 标准对风电数据质量进行了规定,需要对风电数据是否缺失、风电数据是否合理进行判断,检验出其中的异常样本和缺省样本。合理性检验的内容包括范围检验、趋势性检验以及相关性的检验。但该标准针对的是小时级的风电数据,对于分钟级风电数据,检验标准过于粗糙,不能有效剔除错误数据。分钟级风电数据随机性、波动性大,有很强的地域特性,无法明确规范其变化趋势与合理范围,因此本文使用统计学方法对其进行数据检验。

造成异常数据点的原因有很多,如测量过程中的测量误差、数据存储失误、测量延迟、机器故障等。这些偶然的失误从单一的变量本身进行数据特性挖掘会比较困难,难以将异常数据的随机波动与风力自身的随机波动有效进行区分,因此考虑通过风速-风功率的强相关性并结合交叉局部异常因子的多尺度数据预处理策略来剔除这些异常点。

1.1 局部异常因子算法原理

局部异常因子算法的主要目的是赋予每个对象一个离群值,这个值被称为该目标的局部离群因子。所谓的局部,是指离群程度取决于与该数据对象周围的局部邻域相比,该对象的孤立程度。数据集的不同部分可能会表现出完全不同的特征,通过其他领域中的其他对象来判断出某个数据对象是离群的概率是非常有意义的^[18]。具有高 LOF 值是低密度邻域的标志,作为异常值的可能性会更高,而 LOF 值低的数据对象对于其邻域更大程度是同一类数据。

令 M 为一个数据集, o 、 p 、 q 为 M 中的一些数据对象。定义距离函数 $D(o, p)$ 为 o 、 p 间的距离,通常选用欧式距离,则要计算数据集 M 中的数据对象 o 的 LOF 值的步骤如下:

(1) 计算 o 的 k -距离

定义 o 的 k -距离为数据集 M 中距离 o 点最近的第 k 个点到 o 点的距离,记为 $D_k(o)$ 。

若 o 的 k -距离是 o 、 p 间的距离,即 $D_k(o) = D(o,$

$p)$, 则满足:

至少存在 k 个对象 $p' \in M \setminus \{o\}$, 满足: $D(o, p') \leq D(o, p)$;

至多存在 $k-1$ 个对象 $p' \in M \setminus \{o\}$, 满足: $D(o, p') < D(o, p)$ 。

(2) 寻找 o 的 k -距离邻域

定义 o 的 k -距离邻域是指包含所有与 o 的距离小于等于 o 的 k -距离的数据对象集合, 记为 $N_k(o)$ 。即

$$N_k(o) = \{q \in M \setminus \{o\} / D(o, q) \leq D(o, p)\} \quad (1)$$

(3) 计算第 k 可达距离

定义 q 到 o 的第 k 可达距离为 o, q 间距离和 q 的 k -距离中的较大值, 记为 $R_k(o, q)$, 即

$$R_k(o, q) = \max\{D_k(q), D(o, q)\} \quad (2)$$

(4) 计算局部可达密度

定义 o 的局部可达密度为 o 的可达距离平均值的倒数, 记为 $\rho_k(o)$, 计算公式如式(3)所示。

$$\rho_k(o) = \left[\frac{\sum_{q \in N_k(o)} R_k(o, q)}{|N_k(o)|} \right]^{-1} \quad (3)$$

式中, $|N_k(o)|$ 为 o 的 k -距离邻域内的数据点的个数。

$\rho_k(o)$ 的值越小, 表示 o 的密度越小, 表明 o 点越“孤独”, 即越有可能是离散点; 反之亦然。

(5) 计算 o 的局部离散因子

局部离散因子是一个决定数据对象是否是邻域中的离散点的比率, 记为 $LOF_k(o)$, 计算公式如下:

$$LOF_k(o) = \frac{\sum_{q \in N_k(o)} \rho_k(q)}{|N_k(o)| \rho_k(o)} \quad (4)$$

$LOF_k(o)$ 表征的是 o 为离散点的可能性。若 $LOF_k(o)$ 值越接近 1, 代表 o 的密度与邻域中其他对象点的密度越相似, 则 o 点为离散点的可能性越低; 若 $LOF_k(o)$ 值越大于 1, 则 o 点为离散点的可能性越高; 若 $LOF_k(o)$ 值越小于 1, 则 o 点为离散点的可能性越低。

1.2 结合交叉 LOF 算法的多尺度数据预处理策略

风速与风功率之间存在一定强相关性, 风速越大, 风功率越大。由于风场的地域地貌不同, 风向对风电场功率会有一定影响^[19]。同时考虑到不同风场中, 风机的布局特点不同, 尾流效应会加重不同风向对于风电功率的影响^[20]。相同的风速, 不同的风向下也许会产生完全不同的风电功率, 而这些差

异反映的是风场的发电特性, 并非异常, 因此只靠风速-功率两维数据判断异常点是不够准确的。增加风向信息, 建立考虑风向信息的风速-风功率数据 LOF 算法模型。

综合以上的研究, 针对分钟级的风电数据, 提出结合交叉验证的 LOF 算法多尺度风电数据检验策略。其流程图如图 1 所示。

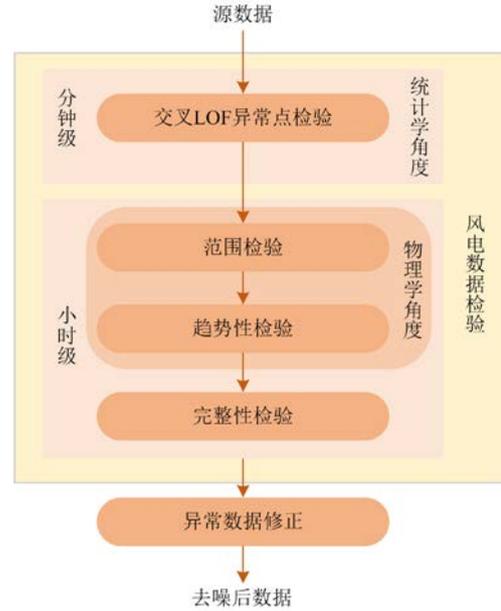


图 1 多尺度数据预处理方法流程图

Fig. 1 Flow chart of multi-scale data preprocessing method

按照风向的不同, 每 45° 为基本单位将数据划分为 8 块子数据集。分别对这 8 个子数据集进行风速-功率数据点的 LOF 算法异常数据点检验, 将 8 个子数据集判断出的异常数据点再进行一次 LOF 算法孤立点检验, 最后得到的非孤立点即为我们最终剔除的异常点。进一步对数据进行处理, 计算得到每小时的平均数据, 对其进行合理性检验, 即进行范围检验和趋势性检验, 对不合理的点进行标记, 即该点对应小时内的点皆为不合理点。随后对异常点进行修正, 对缺失数据进行补充。

至此, 对风电相关数据进行了全方面、多角度的数据检验。该多尺度策略, 从分钟级和小时级两个时间尺度进行数据检验, 通过风速-风力发电功率的强相关性进行异常点检验; 通过不同风向下 LOF 结果的交叉验证, 避免由于风向原因导致的相同风速呈现不同风电功率导致的异常点误判。

2 结合注意力机制的长短期风电功率预测模型

风电预测算法中,最常用的算法之一是 RNN 算法。风电数据在长、短时间尺度上皆具有一定规律性。理论上 RNN 具有建立长时间间隔的状态依赖关系的能力,但实际操作中,由于梯度爆炸或者消失问题,RNN 的简单结构并不能够应对长序列输入,LSTM 算法通过对 RNN 结构的改进解决该长期依赖问题。

比较 RNN 单元与 LSTM 单元结构,如图 2 所示。图中, x_t 为 t 时刻的输入, h_t 为 t 时刻隐藏层状态, C_t 为 t 时刻的状态, C_{t-1} 为 $t-1$ 时刻的状态。 f_t 、 i_t 、 o_t 分别为 LSTM 单元内 t 时刻的遗忘门、输入门、输出门的值; \mathcal{C}_t^o 为 t 时刻 tan 层中的候选值向量。

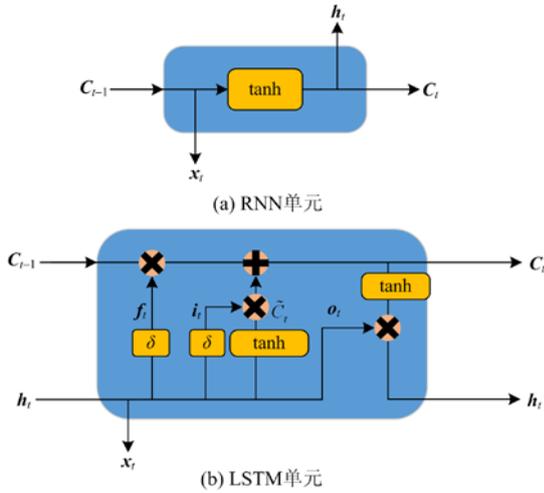


图 2 RNN 单元与 LSTM 单元结构示意图
Fig. 2 Structures of RNN unit and LSTM unit

由图 2 可以看出,传统的 RNN 单元通常使用比较简单的结构,而 LSTM 通过控制输入门、遗忘门和输出门实现对记忆单元的读取和修改^[21],将输入的数据处理分为三个部分。

第一部分是通过遗忘门决定丢弃的信息,计算公式如式(5)所示。

$$f_t = \delta(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5)$$

式中: W_f 为遗忘门的权重矩阵; b_f 为遗忘门的偏置项; δ 表示 sigmoid 激活函数。

第二部分是通过输入门决定保留的信息。tanh 层创建一个新的候选值向量,记作 \mathcal{C}_t^o ,随后该单元的状态将与 i_t 和 C_t 一起更新, C_{t-1} 被更新为 C_t , 计算公式分别如式(2)一式(4)所示。

$$i_t = \delta(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (6)$$

$$\mathcal{C}_t^o = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t * C_{t-1} + i_t * \mathcal{C}_t^o \quad (8)$$

式中: W_i 、 W_c 分别为输入门、输入单元状态的权重

矩阵; b_i 、 b_c 分别为输入门、输入单元状态的偏置项; \tanh 表示双曲正切函数激活函数; * 表示按元素相乘。

第三部分是确定要输出的值,计算公式如式(9)一式(10)所示。

$$o_t = \delta(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t * \tanh(C_t) \quad (10)$$

式中: W_o 为遗忘门的权重矩阵; b_o 为遗忘门的偏置项。

LSTM 保持了 RNN 算法中的递归属性,其具有的特殊记忆和遗忘模式,帮助 LSTM 更好地处理长序列信息^[22]。但是传统 LSTM 算法在编解码时有一定的局限性,特别是编码器和解码器之间的唯一关系向量 C_t ,其长度是固定的^[23],因此当输入序列过长时,序列信息会被压缩导致有效信息失真。

注意力(Attention)机制对编码过程中的每个隐藏状态设定一个权重值,解码过程中输出更侧重的编码状态取决于相应的权重值^[24]。因此产生的每一个输出都能充分利用输入序列所携带的信息,从而更好地抓住时间特征。

风力发电量除了受风速直接影响,还会受外界其他因素影响,如湿度、温度、风向、气压^[25]。通过考虑这些因素对风电功率的影响可以优化预测结果。

构建计及多因素的结合注意力机制的 LSTM 风力发电功率预测模型,原理图如图 3 所示。

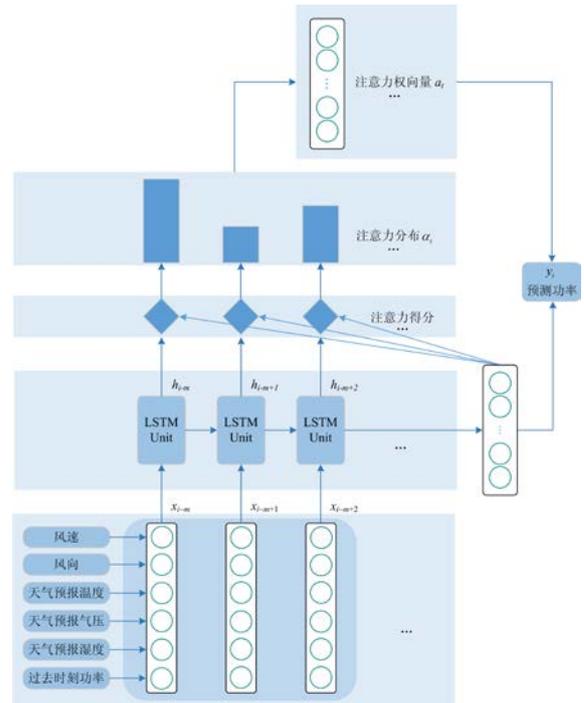


图3 结合注意力机制的LSTM风电预测模型

Fig. 3 LSTM wind power prediction model with attention

由图3可以看出,该方法的输入包括实测风速、实测风向、天气预报温度、天气预报气压、天气预报湿度还有实测风电功率。之所以采用天气预报数据而非实测数据,是考虑到现实场景下,大多数风电场只配备了风速、风向等数据测量设备,却没有配备测量温度、湿度、气压等数据的设备,因此为了实际操作中的可行性,我们选择更易获得的天气预报数据。

将长短期记忆模型结合注意力机制,具体过程如下。

计算 t 时刻的预测值,先对第 i 个时刻($1 \leq i \leq t-1$)的输入通过一个打分函数计算出其注意力得分 s_i ,然后通过使用 softmax 函数将注意力得分转换为注意力分布,记作 α_i 。公式如式(11)所示。

$$\alpha_i = \text{softmax}(s_i) \quad (11)$$

根据注意力分布 α_i ,计算 t 时刻的注意力权重向量 \mathbf{a}_{t-1} ,计算公式如式(12)所示。

$$\mathbf{a}_{t-1} = \sum_{i=1}^{t-1} \alpha_i \mathbf{h}_i \quad (12)$$

最后, \mathbf{a}_{t-1} 将与 \mathbf{h}_{t-1} 连接,作为全连接的输入,得到 t 时刻的预测值 y_t ,以此类推从而获得所有的输出值。

3 实测数据验证

3.1 实测数据收集及预处理

如果风速的时间间隔在 10 min 到 1 h 之间,可以忽略湍流引起的天气变化,从而减少其对风力发电的影响 [26]。此外,考虑到电网每 15 min 发布一次调度指令,本文预测时间尺度为 15 min。

为了验证该方法的可行性,本文收集了一组位于某三角洲冲积岛上风电场的发电功率数据,数据点间隔为 15 min。收集的数据特征包括实测风速、实测风向、天气预报温度、天气预报湿度、天气预报气压。

使用结合交叉 LOF 算法的多尺度数据检验方法对实测风电数据进行检验。其中,针对不合理数据或缺测数据,根据 GB/T 18710-2002 标准规定,用可供参考的邻近风机的同期数据进行替换处理。

8 个风向区域 LOF 检测结果如图 4 所示。图中,红色圆圈为检验出的异常点,蓝色部分为正常点。

对 8 个区域检测出的异常点数据再次进行 LOF 算法,保留的非孤立点即为我们想要的风电数据的异常数据点,最终异常点检验结果如图 5 所示。其

中,红色点为最终的异常点,蓝色点为正常点。

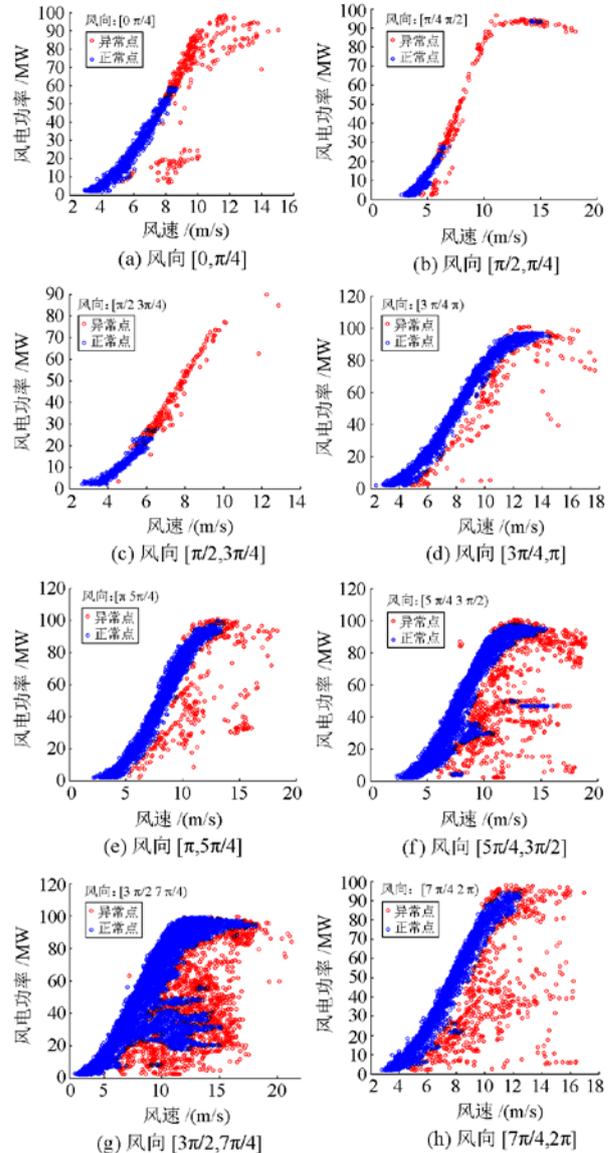


图4 子区域数据 LOF 算法识别结果

Fig. 4 Identification results of sub area data LOF algorithm

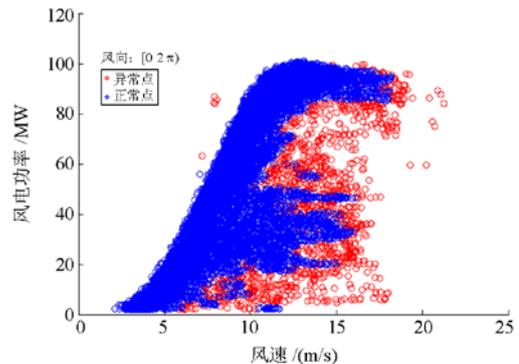


图5 数据检验最终结果

Fig. 5 Final results of data inspection

选择邻近风机对这些异常点数据进行补充修正。对数据进行数据预处理后, 将数据的前 80% 作为训练集, 剩余的 20% 作为测试集。

3.2 实测数据收集及预处理

本文提出的结合交叉局部异常因子和注意力机制的风电功率预测方法以 `pytorch` 为底层学习框架。为了更好地比较预测结果, 使用相同的训练集训练三种模型: 结合交叉 LOF 和注意力机制的 LSTM 预测模型(LOF-LSTM-Attention 模型)、未经 LOF 数据预处理的结合注意力机制的 LSTM 预测模型(未 LOF 预处理的 LSTM-Attention 模型)以及未经过 LOF 算法数据预处理的传统 LSTM 模型(未 LOF 预处理的 LSTM 模型)。

将三种模型用同一个测试集进行测试, 预测结果部分片段如图 6 所示。

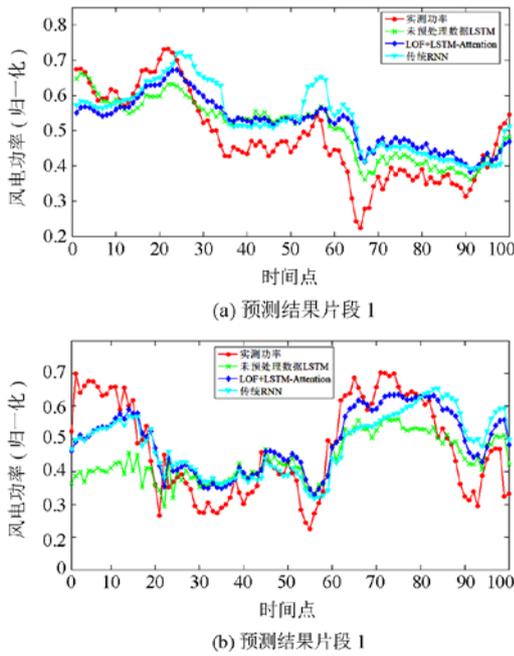


图 6 实验结果部分片段

Fig. 6 Partial experiment results

图 6 可见, 三个模型的预测功率曲线与实际功率曲线对比, 本文提出的 LOF-LSTM-Attention 模型预测效果最好。

选取均方根误差作为预测精度的评价指标。其计算公式如式(13)所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (13)$$

式中: \hat{y}_i 为实际功率值; y_i 为预测功率值。

两段 $RMSE$ 值计算结果如表 1 所示。

表 1 多预测模型的 $RMSE$ 值
Table 1 $RMSE$ of multi-prediction models

模型算法	片段序号	$RMSE$
LOF-LSTM-Attention 模型	a	0.0367
	b	0.0762
未 LOF 预处理的 LSTM-Attention 模型	a	0.0646
	b	0.0892
未 LOF 预处理的 LSTM 模型	a	0.0744
	b	0.1199

从表 1 可以看出, 相比未 LOF 预处理的 LSTM-Attention 模型, LOF-LSTM-Attention 模型的 $RMSE$ 值分别降低了 43.19% 和 14.57%, 定量地证明本文提出的结合交叉局部异常因子的多尺度数据预处理方法可以有效提高预测的精确度。相比未 LOF 预处理的 LSTM 模型, 未 LOF 预处理的 LSTM-Attention 模型的 $RMSE$ 值分别降低了 15.17% 和 25.60%, 说明增加注意力机制的长短期预测模型在风电超短期预测应用中能够有效提高其精准度。相比未 LOF 预处理的 LSTM 模型, 本文提出的 LOF-LSTM-Attention 预测方法的 $RMSE$ 值降低了 50.67% 和 36.45%, 证明本文提出的结合交叉 LOF 算法和注意力机制的风电功率

预测方法对于超短期风电预测中能够有效地提高其预测精度。

4 结论

本文对结合交叉 LOF 预处理算法和注意力机制的风电功率预测方法进行分析与总结, 并得到以下结论:

(1) 提出一种结合交叉验证 LOF 算法的多尺度风电数据检验方法, 针对行业对数据质量规范时间尺度较大的问题, 从分钟级和小时级两个时间尺度对风电场出力数据进行检验。

(2) 根据风向信息对风电数据分块检验, 交叉验证, 减少数据检验中的异常点误判情况。

(3) 提出一种基于注意力机制的风电出力超短期预测方法, 综合考虑风速、风向、温度、湿度和压力等环境因素, 加入注意机制, 捕捉并保留长期风电数据的时间特性。

(4) 以某三角洲冲击岛某风场的实测数据进行验证分析, 结果表明本文提出的结合交叉 LOF 预处理算法和注意力机制的风电功率预测方法能够获得较好的预测精度。

风电预测的主要目的是为了能够更好地参与风电并

离网运行,未来后续可基于当前实际风场的管理与控制,在风电预测基础上对风电并网运行策略及能量管理等方面进行研究。

参考文献

- [1] 李婷,胥威汀,刘向龙,等. 含高比例可再生能源的交直流混联电网规划技术研究综述[J]. 电力系统保护与控制, 2019, 47(12): 177-187.
LI Ting, XU Weiting, LIU Xianglong, et al. Review on planning technology of AC/DC hybrid system with high proportion of renewable energy[J]. Power System Protection and Control, 2019, 47(12): 177-187.
- [2] 于东,孙欣,高丙团,等. 考虑风电不确定出力的风电并网协调优化模型[J]. 电工技术学报, 2016, 31(9): 34-41.
YU Dong, SUN Xin, GAO Bingtuan, et al. Coordinated optimization model for wind power integration considering wind power uncertainty output[J]. Transactions of China Electrotechnical Society, 2016, 31(9): 34-41.
- [3] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.
- [4] 韩斌,王忠杰,赵勇,等. 智慧风电场发展现状及规划建议[J]. 热力发电, 2019, 48(9): 34-39.
HAN Bin, WANG Zhongjie, ZHAO Yong, et al. Development status and planning suggestions of smart wind farms[J]. Thermal Power Generation, 2019, 48(9): 34-39.
- [5] 杨茂,张罗宾. 基于数据驱动的超短期风电功率预测综述[J]. 电力系统保护与控制, 2019, 47(13): 171-186.
YANG Mao, ZHANG Luobin. Review on ultra-short term wind power forecasting based on data-driven approach[J]. Power System Protection and Control, 2019, 47(13): 171-186.
- [6] 杨茂,周宜. 计及风电场状态的风电功率超短期预测[J]. 中国电机工程学报, 2019, 39(5): 1259-1268.
YANG Mao, ZHOU Yi. Ultra-short-term prediction of wind power considering wind farm status[J]. Proceedings of the CSEE, 2019, 39(5): 1259-1268.
- [7] WANG L, TAN A C, CHOLETTE M, et al. Comparison of the effectiveness of analytical wake models for wind farm with constant and variable hub heights[J]. Energy Conversion & Management, 2016, 124: 189-202.
- [8] 李霄,王昕,郑益慧,等. 基于改进最小二乘支持向量机和预测误差校正的短期风电负荷预测[J]. 电力系统保护与控制, 2015, 43(11): 63-69.
LI Xiao, WANG Xin, ZHENG Yihui, et al. Short-term wind load prediction based on improved LSSVM and error forecasting correction[J]. Power System Protection and Control, 2015, 43(11): 63-69.
- [9] RENANI E T, ELIAS M F M, RAHIM N A. Using data-driven approach for wind power prediction: a comparative study[J]. Energy Conversion & Management, 2016, 118: 193-203.
- [10] 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 networks[J]. Renewable Energy, 2019, 37(3): 456-462.
- [11] WANG Ruoheng, LI Chaoshun, FU Wenlong, 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.
- [12] 薛禹胜,陈宁,王树民,等. 关于利用空间相关性预测风速的评述[J]. 电力系统自动化, 2017, 41(10): 161-169.
XUE Yusheng, CHEN Ning, WANG Shumin, et al. Review on wind speed prediction based on spatial correlation[J]. Automation of Electric Power Systems, 2017, 41(10): 161-169.
- [13] 张倩,马愿,李国丽,等. 频域分解和深度学习算法在短期负荷及光伏功率预测中的应用[J]. 中国电机工程学报, 2019, 39(8): 2221-2230, 5.
ZHANG Qian, MA Yuan, LI Guoli, et al. Applications of frequency domain decomposition and deep learning algorithms in short-term load and photovoltaic power forecasting[J]. Proceedings of the CSEE, 2019, 39(8): 2221-2230, 5.
- [14] 中华人民共和国国家质量监督检验检疫总局. 风电场风能资源评估方法: GB/T 18710—2002[S]. 北京: 中国标准出版社, 2002.
- [15] 杨明莉,刘三明,王致杰,等. 卡尔曼小波神经网络风速预测[J]. 电力系统及其自动化学报, 2015, 27(12): 42-46.
YANG Mingli, LIU Sanming, WANG Zhijie, et al. Kalman filter and wavelet neural network wind speed prediction[J]. Proceedings of the CSU-EPSA, 2015, 27(12): 42-46.

- [16] 范小龙, 谢维成, 蒋文波, 等. 一种平稳小波变换改进阈值函数的电能质量扰动信号去噪方法[J]. 电工技术学报, 2016, 31(14): 219-226.
FAN Xiaolong, XIE Weicheng, JIANG Wenbo, et al. An improved threshold function method for power quality disturbance signal de-noising based on stationary wavelet transform[J]. Transactions of China Electrotechnical Society, 2016, 31(14): 219-226.
- [17] 张里, 王兰, 李红军, 等. 基于聚类分析的风电功率预测数据预处理方法[J]. 可再生能源, 2018, 36(12): 1871-1876.
ZHANG Li, WANG Lan, LI Hongjun, et al. Wind power prediction data pre-processing technology based on clustering approach[J]. Renewable Energy, 2018, 36(12): 1871-1876.
- [18] 张丹丹, 游子毅, 郑建, 等. 基于改进的局部异常因子检测的优化聚类算法[J]. 微电子学与计算机, 2019, 36(11): 43-48.
ZHANG Dandan, YOU Ziyi, ZHENG Jian, et al. Optimal clustering algorithm based on modified local outlier factor detection[J]. Microelectronics & Computer, 2019, 36(11): 43-48.
- [19] 陈翔, 王福军, 刘天琪, 等. 考虑风电场布局以及风向角的风电功率预测[J]. 电工电能新技术, 2013, 32(1): 9-12.
CHEN Xiang, WANG Fujun, LIU Tianqi, et al. Wind power prediction considering wind farm layout and wind direction[J]. Advanced Technology of Electrical Engineering and Energy, 2013, 32(1): 9-12.
- [20] 姜文玲, 王勃, 汪宁渤, 等. 基于风速衰减因子法的大型风电场尾流效应模拟方法研究[J]. 电网技术, 2017, 41(11): 3499-3505.
JIANG Wenling, WANG Bo, WANG Ningbo, et al. A study of the wake simulation method of the large-scale wind farms based on wind attenuation factor[J]. Power System Technology, 2017, 41(11): 3499-3505.
- [21] 张宇帆, 艾芊, 林琳, 等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. 电网技术, 2019, 43(6): 1884-1892.
ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level[J]. Power System Technology, 2019, 43(6): 1884-1892.
- [22] KANNAN S, YENGERA G, MUTTER D, et al. Future-state predicting LSTM for early surgery type recognition[J]. IEEE Transactions on Medical Imaging, 2020, 39(3): 556-566.
- [23] 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.
- [24] 王轲, 钟海旺, 余南鹏, 等. 基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解[J]. 中国电机工程学报, 2019, 39(1): 75-83, 322.
WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Nonintrusive load monitoring based on sequence-to-sequence model with attention mechanism[J]. Proceedings of the CSEE, 2019, 39(1): 75-83, 322.
- [25] 黄小燕, 张明军, 王圣杰, 等. 西北地区近 50 年日照时数和风速变化特征[J]. 自然资源学报, 2011, 26(5): 825-835.
HUANG Xiaoyan, ZHANG Mingjun, WANG Shengjie, et al. Characteristics of variation in sunshine duration and wind speed in the last 50 years in northwest[J]. Journal of Natural Resources, 2011, 26(5): 825-835.
- [26] 贺嘉馨. 风工程与工业空气动力学[M]. 北京: 国防工业出版社, 2006.

收稿日期: 2019-12-24; 修回日期: 2020-02-16

作者简介:

汪欣(1994—), 女, 硕士研究生, 研究方向为风电建模及并网接入技术; E-mail: 250425471@qq.com

蔡旭(1964—), 男, 通信作者, 博士, 教授, 研究方向为可再生能源并网技术、大功率电力电子与电力系统控制; E-mail: xucai@sju.edu.cn

李征(1961—), 女, 博士, 教授, 研究方向为风力发电系统控制、分布式电能系统控制及接入、储能系统应用。E-mail: lizheng@dhu.edu.cn

(编辑 张爱琴)