

基于 BiLSTM-SA 的分布式光伏功率超短期概率预测

彭依明¹, 王佳¹, 周长城², 蒋雨晨¹, 程凯²

(1. 广东电网有限责任公司广州供电局电力调度控制中心, 广州 510610; 2. 南方电网数字电网研究院, 广州 510664)

摘要: 精确的光伏功率超短期概率预测可降低光伏出力不确定性对电力系统的影响, 为电网决策调度提供可靠依据。为此, 提出了一种基于深度学习技术的光伏出力超短期预测方法。首先, 基于历史光伏数据特性进行了特征相关性分析及 K-means++ 天气聚类, 选取适宜位置的分位点, 搭建了双向长短期记忆神经网络 (bidirectional long short term memory, BiLSTM) 挖掘双向时序特征。然后, 引入自注意力机制 (self-attention, SA) 动态聚焦序列关键信息, 并调用粒子群算法进行神经网络参数寻优, 将最优参数置入 BiLSTM-SA 优化模型进行点预测。最后, 基于点预测结果进行误差分析, 利用分位数回归 (quantile regression, QR) 构建了 QR-BiLSTM-SA 概率预测模型。算例结果表明, 所提方法在光伏出力超短期概率预测中精度可达 95% 以上, 并具有良好的泛化能力, 可为新型配电系统运行调度提供可靠依据。

关键词: 光伏功率预测; 概率区间预测; 深度学习; 分位数回归; 双向长短期神经网络; 自注意力机制

Ultra-Short-Term Probability Prediction of Distributed Photovoltaic Power Based on BiLSTM-SA

PENG Yiming¹, WANG Jia¹, ZHOU Changcheng², JIANG Yuchen¹, CHENG Kai²

(1. Guangzhou Power Bureau Dispatching and Control Center, Guangdong Power Grid Co., Ltd., Guangzhou 510610, China;

2. Digital Grid Research Institute, CSG, Guangzhou 510664, China)

Abstract: Accurate ultra-short-term prediction of photovoltaic (PV) power is pivotal in mitigating the adverse effects of PV output uncertainty on power systems, thereby furnishing a dependable foundation for grid decision-making and scheduling. Therefore, a method for ultra-short-term prediction of photovoltaic output based on deep learning technology is proposed. Firstly, leveraging historical PV data, feature correlation analysis and K-means++ weather clustering are performed to discern pertinent patterns. And employing strategically positioned quantiles, a novel bidirectional long short term memory (BiLSTM) neural network is then constructed to capture bidirectional temporal dependencies. Then, a self-attention mechanism (SA) is introduced to dynamically emphasize key sequential information and a particle swarm optimization algorithm is integrated to optimize the parameters of the neural network. Optimal parameters are then assimilated into the BiLSTM-SA optimization framework for point prediction. Finally, through meticulous error analysis, a quantile regression (QR) is developed to delineate QR-BiLSTM-SA probability prediction model. The results show that the proposed method achieves accuracy exceeding 95% in ultra-short-term PV output probability prediction and has a good generalization ability, offering a robust foundation for the operation and scheduling of modern power systems.

Key words: photovoltaic power prediction; probability interval prediction; deep learning; quantile regression; bidirectional long short-term memory network; self-attention mechanism

基金项目: 广东省自然科学基金资助项目 (2024A1515012428); 中国南方电网有限责任公司科技项目 (030100KK52222025)。

Foundation item: Supported by the Natural Science Foundation of Guangdong Province (2024A1515012428); the Science and Technology Project of China South Power Grid Co., Ltd. (030100KK52222025).

0 引言

全球能源格局剧变背景下, 以光伏发电为代表的可再生能源发电在世界范围内呈现出爆发式的发展态势^[1]。然而, 由于光伏出力的随机性、间歇性和波动性, 光伏渗透率的不断提高对电网运行的稳定性、安全性造成威胁^[2-4]。尤其是分布式光伏规模化接入配网, 使得配网潮流从单向转化为双向, 对配网的运行模式、电能质量以及保护和控制都提出新的挑战。在此背景下, 光伏出力的精准预测成为保障电网安全的核心支撑, 预测精度直接决定调度策略的有效性, 是预防配网故障的关键保障^[5]。

从预测结果输出形式上看, 光伏出力预测可分为点预测和概率预测^[6]。点预测即确定性预测, 该预测的输出为未来一段时间内确定性的预测值^[7]。但是, 点预测输出结果单一, 在实际光伏出力的预测中难以表征其不确定性, 尤其是恶劣天气场景下预测误差较大。与之相比, 以区间预测为代表的概率预测不仅可以提供未来某时刻的光伏出力值, 还能够实时估计未来光伏出力变化范围, 克服传统点预测输出精度有限的问题^[8-10]。文献[11]在保证预测区间可靠性的前提下, 通过自适应双层优化获取区间上下界的分位数实现了缩减区间宽度的概率预测模型优化。基于分位数回归(quantile regression, QR)的概率预测算法灵活性强, 与人工智能方法相结合可进一步构建高维的非线性映射关系, 为高不确定性的分布式新能源的功率预测提供了一条有效途径。文献[12]通过集合 QR、卷积神经网络(convolutional neural network, CNN)以及双向长短期记忆(bidirectional long short term memory, BiLSTM)神经网络进行了分类预测, 生成了可靠的预测区间。但是, CNN 的静态卷积核采用固定权重滑动, 无法根据输入功率数据的前后数据调整特征重要性, 对光伏功率的突变型波动响应滞后。

有鉴于此, 本文提出了一种基于深度学习技术的光伏出力超短期预测方法。首先, 考虑光伏出力数据集特性, 基于天气特征进行 K-means++ 天气聚类以及分位点选择。接着, 结合 BiLSTM 网络对双向时序的特征提取能力以及自注意力机制动态关注序列重要信息的优势, 搭建了分位数回归-双向长短期记忆神经网络-自注意力机制(quantile regression-bidirectional long short term memory-self

attention, QR-BiLSTM-SA)点预测模型, 并引入粒子群优化算法进行预训练以及参数寻优。然后, 通过 QR 重构点预测误差序列, 求解得到概率预测区间。最后, 通过算例验证了该方法的可行性和优越性。

1 光伏发电功率影响因素分析

光伏发电功率由于受各类天气及环境因素影响, 其输出往往具有显著不确定性^[13-14]。为定性分析各类气象因素对光伏出力的影响, 由某光伏电站实测数据^[15]得到太阳辐照度、气温、湿度 3 类气象特征与功率的对比曲线如图 1 所示。




图 1 3类气象特征-功率曲线

Fig. 1 Three types of meteorological features - power curves

计算各特征变量的相关系数并分析图 1 可知, 从曲线走势上看, 3 类太阳辐照度均与光伏发电功率呈显著正相关关系, 辐照度的波动直接导致光伏发电功率的波动; 从相关系数上看, 总辐照度、水平辐照度、法向辐照度与功率数据间的相关系数分别为 0.95、0.8 和 0.8, 与功率相关性最大。由于一般高温常对应晴朗天气, 温度与辐照度间正向相关, 故其升降趋势大体与光伏出力一致, 相关系数为 0.4; 但同等照度下, 温度与功率输出呈现负相关。湿度对光伏出力的影响主要可归结于空气中水

蒸气对水平辐照度的负面作用,故图1体现出二者整体在波动下呈负相关关系,相关系数为-0.39。

此外,考虑到光伏出力的时序特性,对某光伏电站实测数据^[15]进行时间序列分解,如图2所示。




图2 光伏出力时间序列分解结果

Fig. 2 Decomposition results of photovoltaic output time series

由图2可知,光伏出力以日为单位进行周期性的往复,其长期趋势较为稳定,功率值常年可维持在一定区间内。但天气等外界因素导致的出力不确定性波动于残留部分中体现,其幅度不定。因此,本文提出基于QR-BiLSTM-SA的概率预测模型,通过提取序列波动特征输出信息全面、可靠的预测区间,以降低光伏出力波动对电网运行的负面影响。

2 QR-BiLSTM-SA原理

2.1 分位数回归

分位数回归是最小二乘回归的扩展和改进,它通过估计数据的不同分位数来揭示自变量与因变量间的关系,提供因变量在不同置信水平下的预测结果^[16]。因此,可考虑通过引入QR来求解光伏出力序列的概率分布。QR模型定义如式(1)所示。

$$Q_\tau(\tau|X_i) = \beta(\tau)X_i, i = 1, 2, \dots, n \quad (1)$$

式中: n 为序列总行数; X_i 为第 i 个自变量; Y 为响应变量; τ 为分位点; $Q_\tau(\tau|X_i)$ 为 Y 的第 τ 个条件分位数; $\beta(\tau)$ 为分位点 τ 处的回归系数向量。

2.2 双向长短期记忆神经网络

对于时序相关性问题的,长短期记忆(long short term memory, LSTM)神经网络具有良好的非线性

建模能力,被广泛应用于时序数据中时间依赖关系的挖掘与学习^[17]。LSTM循环单元包含细胞状态、遗忘门、输入门和输出门4部分,其中细胞状态作为核心结构被另三者控制。在光伏出力数据的处理中,遗忘门决定训练过程中历史信息的保留或删除,以保证从历史出力中学习出有用的信息,而输入门与输出门基于当前和过去的记忆状态完成不同时刻数据信息的保持、更新及传递,达到“记忆”数据的作用。

将两个独立的LSTM层分别从正反两个方向组合起来,即可得到BiLSTM^[18-19]。由于其兼具顺、倒二序的特征提取与学习过程,相对于单向的LSTM可更好地捕捉双向的功率依赖,克服时序处理中相位滞后的问题,提供更全面的预测信息。BiLSTM的网络结构如图3所示。




图3 BiLSTM网络结构

Fig. 3 BiLSTM network architecture

2.3 自注意力机制

注意力机制(attention mechanism, AM)受人类观察行为中的选择性关注功能启发,其依据数据特点动态调节对某部位的重视程度,以此聚焦重要信息,抑制无关信息的影响^[20]。而自注意力机制是一种适于时序处理的注意力机制,在光伏发电功率预测中,其依时间步动态调整对各功率影响因素的注意力权重,可有效提升预测效率及准确度^[21]。

SA的引入过程可看作软寻址,如图4所示。输入数据集的特征可看作寻址操作期间的储存内容Key值(数据地址)和Value值(注意力值)。

3 基于QR-BiLSTM-SA的光伏功率概率预测模型的构建

本文融合BiLSTM处理双向时序数据的优势以及SA动态聚焦时序关键信息的特性,搭建BiLSTM-SA优化点预测模型,引入粒子群算法(particle swarm optimization, PSO)进行神经网络参




图 4 自注意力机制计算过程

Fig. 4 Calculation process of self-attention mechanism

数寻优; 在点预测工作的基础上计及误差分析引入 QR 实现不同置信度下的概率预测, 输出未来一段时间内的光伏出力预测区间。预测模型的具体构建过程如图 5 所示。主要流程说明如下。

1) 异常值预处理与数据分类。基于基础统计特征平均历史功率和法向辐照度进行 K-means++ 天气聚类^[22], 将数据划分为晴天、多云、雨天 3 类标签; 并以 4: 1 的比例将其划分为训练集和测试集。

在 0~1 的范围内预设多个分位点 q , 并定义分位数损失函数 $\rho_q(x)$ 如式(2)所示。

$$\rho_q(x) = \begin{cases} qx, & x \geq 0 \\ (q-1)x, & x < 0 \end{cases} \quad (2)$$

式中 x 为功率点。

2) 将上述数据输入优化点预测模型, 先后完成 BiLSTM 前后向时序训练、SA 权重动态分配以及一系列激活和 Dropout 调整, 训练目标设为最小化分位数损失函数 L_{loss} , 如式(3)所示。

$$L_{\text{loss}} = \sum_{t=1}^T \sum_{q \in Q} \rho_q(|\varepsilon_t^q|) - \frac{1}{|Q|} \sum_{q \in Q} \log(\hat{\sigma}_t^q) \quad (3)$$

式中: T 为时间; Q 为分位数集合; θ 为分位数损失; ε_t^q 为时间 t 处分位数 q 的预测误差; $\hat{\sigma}_t^q$ 为时间 t 处分位数 q 的预测误差置信区间。

3) 调用 PSO, 将 BiLSTM 层的神经元数量和 Adam 优化器的学习率设为寻优目标, 以训练集误差绝对值之和作为约束函数, 求解最优目标函数值。当约束函数 $e_{\min}$ 全局最小时参数为最优, 其计算公式如式(4)所示。

$$e_{\min} = \sum_{t=1}^n |\hat{y}_t - y_t| \quad (4)$$




图 5 基于 QR-BiLSTM-SA 的光伏出力超短期预测流程

Fig. 5 Ultra-short-term probability prediction process for PV power based on QR-BiLSTM-SA

式中: $\hat{y}_t$ 为 t 时刻光伏出力预测值; y_t 为 t 时刻光伏出力真实值。

4) 将步骤 3) 中求出的最优参数置入点预测模型中, 输入测试集进行预测, 求出各预设分位数下的光伏出力曲线以及训练集预测误差, 依此计算点预测误差评价指标。计算误差 e_t 如式(5)所示。

$$e_t = \hat{y}_t - y_t \quad (5)$$

5) 给定置信度 α , 结合前述分位数计算结果, 取最优分位点求解预测区间, 并结合点预测误差计算对应的概率预测指标, 完成区间预测。

4 算例分析

4.1 数据预处理

本文选取我国某地 8 个分布式光伏场站 2019—2020 年的现场测量数据^[15]进行算例分析, 原始数

据分辨率为 15 min, 每日总计 96 个记录点, 平均实际输出从 4.2 MW~29.8 MW 不等。数据集涵盖历史功率以及 6 类数值天气预报特征, 分别为总辐射、直接辐射、散射辐射、气温、气压和湿度。

为简化预测流程、提高预测效果, 首先识别和替换处理明显异常值, 以线性插值方式填补缺失值, 对数值微小的负功率取绝对值。对数据进行相关性分析, 研究光伏出力与太阳辐射度等气象数据的非线性相关关系^[23-24]。接着, 采用 K-means++ 方法基于基础统计特征进行天气聚类。由于实际工程应用中天气复杂多变, 本文不考虑晴转多云、晴转雨等场景, 仅将数据集划分为晴天、多云、雨天 3 类天气标签, 聚类结果如图 6 所示。

最后, 对带有天气标签的数据进行特征-标签切片以及 MinMaxScaler 归一化操作, 并以 4:1 的比例进行训练集和测试集的划分。




图 6 K-means++ 天气聚类结果

Fig. 6 K-means++ weather clustering results

4.2 光伏功率预测评估指标

4.2.1 点预测指标

本文采用均方误差 E_{MSE} 、均方根误差 E_{RMSE} 、平均绝对误差 E_{MAE} ^[25] 和决定系数 R^2 作为光伏功率点预测模型的评价指标, 如式(6)~(9)所示。

$$E_{MSE} = \frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2 \quad (6)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (7)$$

$$E_{MAE} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (8)$$

$$R^2 = 1 - \frac{\sum_{t=1}^N (\hat{y}_t - y_t)^2}{\sum_{t=1}^N (\bar{y} - y_t)^2} \quad (9)$$

式中: $\bar{y}$ 为光伏发电功率真实值的平均值; N 为样本数量。

4.2.2 概率预测指标

本文以预测区间覆盖概率(prediction interval coverage probability, PICP) P_{PICP} 、平均区间宽度(mean interval width, MIW) D_{MIW} 和综合得分 S 作为概率区间预测评价指标^[26], 进行预测性能分析, 如式(10)~(12)所示。

$$P_{PICP} = \frac{1}{N} \sum_{t=1}^N C \quad (10)$$

$$D_{MIW} = \frac{1}{N} \sum_{t=1}^N \frac{L_{up\ t} - L_{low\ t}}{y_t} \quad (11)$$

$$S = \begin{cases} -2\alpha(L_{up\ t} - L_{low\ t}) - 4(L_{low\ t} - y_t), & y_t < L_{low\ t} \\ -2\alpha(L_{up\ t} - L_{low\ t}), & L_{low\ t} < y_t < L_{up\ t} \\ -2\alpha(L_{up\ t} - L_{low\ t}) - 4(y_t - L_{up\ t}), & y_t > L_{up\ t} \end{cases} \quad (12)$$

式中: C 为布尔量, 若光伏出力真实值落在预测区间范围内, $C=1$, 否则 $C=0$; $L_{up\ t}$ 、 $L_{low\ t}$ 分别为 t 时刻数据在置信度 $1-\alpha$ 下预测的上下限值。

在光伏出力预测中, P_{PICP} 反映光伏出力真实值落入预测区间内的概率, 以评估预测区间的稳定性。 D_{MIW} 用以评价预测区间宽度, 即上下包络线之间的宽度, 可反映该区间的灵敏度。 D_{MIW} 值越小, 代表区间灵敏度越高, 即预测精度越高。 S 反映综合的预测效果, 其绝对值越小, 预测效果越好。

4.3 点预测

本文所用算法基于 Python 语言开发, 在 Tensorflow=2.10.0 环境下运行。模型预设 3 个分位点(0.1、0.5 和 0.9), 并定义分位数损失函数进行训练及测试。对于各层神经网络的初始参数, 设置时间步 time_step=5, 迭代次数 epochs=10, 批次大小 batch_size=512; 设置 Adam 算法为梯度下降优化器, RELU 为输出层激活函数, softmax 为自注意力机制层激活函数。

此外, BiLSTM 网络的神经元数量和优化器的学习率通过引入 PSO 寻优求得。设置粒子群数量为 2, 目标函数上下限分别为 [60, 70] 和 [0.001, 0.01]。经 10 次迭代, 约束函数和训练损失均达最小值, 得到最优的 BiLSTM 层神经元数量为 70, 优化器最优学习率为 0.008 981。将该最优参数置入 BiLSTM-SA 点预测模型中, 输入测试集数据, 迭代 100 次。考虑到光伏出力具显著日特性, 超短期

预测每次仅用 4 h 数据不易观察整体趋势, 故此处设置 3 d 尺度的预测点。最终, 结合点预测评价指标选择分位数为 0.5, 输出 3 类天气标签下的点预测结果如图 7 所示。

由图 7 可知, 晴天条件下光伏发电功率输出波动小, 功率曲线变化较平稳, 本文模型能准确预测输出功率的变化趋势, 预测值基本可与真实值相拟合; 多云和雨天条件下云层对太阳光线遮挡较严重, 光伏出力波动明显, 预测难度加大, 但本文模型在尖峰、转折等各功率突变点处反应灵敏, 整体而言能够有效判断功率的走向, 对于电网调度工作而言极具参考价值。




图 7 光伏出力点预测结果

Fig. 7 Photovoltaic output point prediction results

选取数据集中场站 4 的数据进行误差评价指标定量分析, 如表 1 所示。

由表 1 可知, 在场站 4 的预测中, 无论是测试集整体数据还是单独某一天气场景下的数据, 本文模型预测得到的 E_{RMSE} 和 E_{MAE} 均可保持在 0.2 以下, 即模型的平均预测误差在任一天气场景下均可控制在 0.5 MW 以下; R^2 在晴天、多云场景下均能达到 0.9 以上, 表明数据拟合程度较高。对比不同天气可知, 晴天功率由于规律性强、变化平稳, 平均

表 1 不同天气场景下光伏出力点预测误差指标统计

Tab. 1 Statistics of error indicators for predicting photovoltaic output points in different weather scenarios

测试集整体数据		E_{RMSE}	E_{MAE}	R^2
		0.066 2	0.027 9	0.919 6
晴天	典型日 1	0.042 6	0.025 5	0.982 8
	典型日 2	0.047 0	0.027 7	0.9787
多云	典型日 1	0.075 7	0.038 3	0.915 9
	典型日 2	0.052 0	0.024 7	0.969 2
雨天	典型日 1	0.028 3	0.012 7	0.747 3
	典型日 2	0.170 9	0.029 2	0.582 9

E_{MAE} 仅有 0.13, 整体预测误差最小; 而雨天功率数值低、波动剧烈, 平均 E_{MAE} 达到 0.17, 整体预测误差最大, R^2 所呈现的拟合程度也最低。值得特别说明的是, 对于雨天典型日 1, 虽然从 E_{RMSE} 和 E_{MAE} 来看, 其单日预测精度优于晴天典型日, 但该典型日的降雨强度持续稳定、光伏功率波动范围较小, 这种准稳态条件更有利于模型发挥时序预测优势。而对于以典型日 2 为代表的一般雨天样本, 间歇性强降雨易导致功率曲线出现剧烈跳变, 此时模型预测误差显著增大。可见, 降雨过程的时空异质性会对光伏功率预测产生一定影响。

为进一步证明本文所提 BiLSTM-SA 点预测模型性能的优越性, 本节采用统计模型 SVR、经典神经网络 LSTM、BiLSTM 以及 BiLSTM-AM 模型预测同一阴天日数据, 将各算法预测结果进行比较, 预测曲线如图 8 所示。




图 8 某日阴天场景下各算法预测曲线对比

Fig. 8 Comparison of prediction curves of various algorithms in a cloudy scene on a certain day

由图 8 可知, 本文所提模型在该日预测中整体效果最优, 不仅可有效预测功率趋势, 也能在局部细节上体现最佳拟合效果。如局部放大图所示, 该

功率剧烈波动点处本文模型所得预测值最贴近真实值,而其他几类模型明显偏离较大。

此外,表2中给出超前24 h预测下各算法的点预测评价指标。

表2 各算法点预测误差指标统计

Tab. 2 Statistics of prediction error indicators for each algorithm point

天气	采用算法	E_{MSE}	E_{RMSE}	E_{MAE}
晴天	SVR	3.015 9	1.736 6	0.976 9
	LSTM	0.001 3	0.146 1	0.021 3
	BiLSTM	0.001 1	0.143 0	0.020 5
	BiLSTM-AM	0.001 3	0.151 6	0.023 0
	BiLSTM-SA	0.001 6	0.039 8	0.020 3
多云	SVR	1.518 6	1.232 3	0.691 6
	LSTM	0.005 1	0.189 8	0.036 0
	BiLSTM	0.005 3	0.1823	0.033 2
	BiLSTM-AM	0.007 1	0.201 8	0.040 7
	BiLSTM-SA	0.007 4	0.198 6	0.039 4
雨天	SVR	6.522 7	2.554 0	1.431 5
	LSTM	0.001 7	0.142 5	0.020 3
	BiLSTM	0.001 3	0.134 0	0.018 0
	BiLSTM-AM	0.001 5	0.142 9	0.020 4
	BiLSTM-SA	0.001 6	0.125 6	0.011 2

由表2可知,无论是晴天还是预测难度较高的雨天、多云场景,本文所提点预测算法的 E_{RMSE} 和 E_{MAE} 均显著低于其他4类模型,预测性能最出色。本文模型通过双向时序处理以及自分配注意力权重等优化方法,相对另几类模型更善于特征挖掘,可有效提升不平稳功率数据的预测准确度。以晴天场景为例,本文算法BiLSTM-SA相比于BiLSTM, E_{RMSE} 和 E_{MAE} 分别降低了72.17%和0.98%;相比于BiLSTM-AM, E_{RMSE} 和 E_{MAE} 分别降低了73.75%和11.74%。可见,SA的加入对模型性能提升贡献了5%~10%,使得模型具备更强的表征学习能力。

4.4 概率预测

考虑到点预测输出信息匮乏的局限性,本文在BiLSTM-SA点预测模型的基础上引入QR,基于分位数求解结果及点预测误差分析,给定置信度求解对应概率预测区间。经训练寻优,本文模型选定分位点 $q=0.5$,此时预测区间所呈现出对真实值的包裹性最佳。将测试集输入QR-BiLSTM-SA概率预测模型中进行超前72 h的预测,设置置信区间为95%,输出3

类天气标签下的区间预测结果如图9所示。




图9 光伏出力概率预测结果

Fig. 9 Photovoltaic output probabilities prediction results

由图9可知,本文模型所得概率区间沿袭了点预测中求解到的变化趋势,故对于功率的各式不确定性波动均能给出合理的预测。相对于点预测输出的单一曲线,QR-BiLSTM-SA模型输出各时间步宽度不一,但基本均可将真实值包裹在内的预测区间,当功率出现显著波动时预测区间较宽;反之较窄。该现象反映出本模型具有较强的抗干扰能力,显著降低了光伏出力预测的不确定性。

表3展示了改变置信度、改变时间尺度下本文所提概率预测模型的概率预测误差指标, S 为综合评价指标。分析表3可知,从总体数据来看,扩大置信区间,预测区间的区间覆盖概率提高、平均区间宽度增大、综合得分下降,预测精度提高。该现象符合概率区间预测规律,当预测时间尺度较长时尤为明显。本文所提QR-BiLSTM-SA模型在超短期预测中体现出优越的性能,预测区间的区间覆盖率达95%以上,且综合得分绝对值低于5。

进一步地,采用概率预测模型QR-LSTM、QR-BiLSTM、QR-BiLSTM-AM以及本文所提模型

表 3 不同置信度下光伏出力概率预测误差指标统计

Tab. 3 Statistical analysis of error indicators under different confidence levels for photovoltaic output probability prediction

超前时间	置信区间/%	P_{PICP}	D_{MIW}	S
超前 4 h	95	0.951 7	0.212 9	4.696 7
	90	0.962 5	0.178 7	4.596 1
超前 24 h	95	0.906 2	0.277 1	3.271 8
	90	0.895 8	0.232 5	3.853 5
超前 72 h	95	0.902 8	0.296 2	3.049 8
	90	0.857 6	0.248 4	3.452 1

QR-BiLSTM-SA 预测同一场站数据集, 设置置信度为 95 %, 将各算法概率预测误差指标结果进行比较, 如表 4 所示。

表 4 各算法概率预测误差指标统计

Tab. 4 Statistics of probability prediction error

indicators for various algorithms				
天气	采用算法	P_{PICP}	D_{MIW}	S
晴天	QR-LSTM	0.982 5	0.217 8	4.610 2
	QR-BiLSTM	0.986 0	0.221 1	4.671 7
	QR-BiLSTM-AM	0.983 0	0.215 1	4.818 3
	QR-BiLSTM-SA	0.992 0	0.212 9	4.565 3
多云	QR-LSTM	0.875 4	0.217 8	4.164 5
	QR-BiLSTM	0.878 4	0.221 1	4.351 2
	QR-BiLSTM-AM	0.885 1	0.214 5	4.295 2
	QR-BiLSTM-SA	0.885 2	0.212 9	4.157 5
雨天	QR-LSTM	0.957 7	0.217 8	4.496 2
	QR-BiLSTM	0.965 6	0.221 1	4.575 0
	QR-BiLSTM-AM	0.957 7	0.216 1	4.646 8
	QR-BiLSTM-SA	0.967 1	0.212 9	4.448 2

分析表 4 可知, 本文所提 QR-BiLSTM-SA 模型得益于 BiLSTM 和 SA 强大的特征挖掘与聚焦能力, 相较于另几类模型具有更出色的光伏出力值跟踪能力, 在 3 类天气场景下均体现出最优的预测效果。除晴天外, 对于功率波动剧烈的多云、雨天场景, 本文模型 P_{PICP} 值始终最大, 区间覆盖真实值概率最高; D_{MIW} 值始终最低, 区间灵敏度最高; 综合得分绝对值最低, 区间预测精度最高。以多云天气场景为例, 本文所提模型的综合评价指标 S 相对 QR-LSTM、QR-BiLSTM 和 QR-BiLSTM-AM 分别降低了 0.17 %、4.45 % 和 3.21 %。

4.5 泛化测试

将本文模型应用于数据集中另外 4 个场站进行

预测效果对比, 以验证模型泛化能力。随机选取得场站 1、2、3、7 分别命名为 A—D, 输入 QR-BiLSTM-SA 模型进行 3 类天气标签下的概率预测得预测区间如图 10 所示。

由图 10 可见, 在更换不同数据集后本文所提模型仍展现出优秀的预测性能。在对场站 A 晴天标签下的预测中, 对于午时出现的云层移动导致的功率波动, 模型通过 SA 关键信息聚焦得到的预测区间完整地覆盖了真实值; 在对 4 个场站雨天标签下的预测中模型均可相对准确地预测出光伏出力变化的趋势, 日间大部分时间下可做到预测区间对真实值的全面覆盖。由此可知, QR-BiLSTM-SA 模型具有较优的泛化能力。

5 结论

为克服传统点预测输出信息不足的局限性、更准确全面地预测光伏超短期发电功率, 本文利用改进深度学习技术, 结合 BiLSTM 对时序信息捕捉的敏感性和 SA 对序列重要信息关注度自适应调整的能力, 引入可生成预测区间的 QR 方法建立了一种基于 QR-BiLSTM-SA 的光伏发电功率超短期概率预测模型, 主要结论如下。

1) 针对现有点预测方法预测精度不足的问题, 选取 BiLSTM 模型进行双向时序处理并引入 SA 聚焦序列关键信息, 通过 PSO 算法进行参数寻优, 搭建 BiLSTM-SA 优化点预测模型。经算例验证所提方法的 ERMSE 较 LSTM、BiLSTM 分别降低了 72.76 %、72.17 %。

2) 针对单一确定性预测输出信息有限的问题, 在 BiLSTM-SA 点预测模型的基础上引入 QR 进行概率区间的求解, 通过概率区间预测达到了提升超短期光伏发电功率预测精度和稳定性的目的。经算例验证所提方法的综合评价指标 S 较 QR-LSTM、QR-BiLSTM 和 QR-BiLSTM-AM 分别降低了 0.17 %、4.45 % 和 3.21 %, 整体预测精度可达 95 % 以上, 并具有良好的泛化能力。

总的来讲, 本文搭建了一种高性能的深度学习融合预测模型, 可为电网调度工作者提供高精度、高信息量、高稳定性的超短期光伏出力预测。未来可考虑采用不同地区光伏出力数据进行预测, 以进一步证实模型的泛化能力。




图 10 不同场站下模型泛化能力测试

Fig. 10 Generalization ability testing of models at different stations

参考文献

- [1] AHMED R, SREERAM V, MISHRA Y, et al. A review and evaluation of the state-of-the-art in PV solar power forecasting: techniques and optimization [J]. Renewable and Sustainable Energy Reviews, 2020(124):109792. 1 – 109792. 12.
- [2] 卢俊杰, 蔡涛, 郎建勋, 等. 基于集群划分的光伏电站集群发电功率短期预测方法[J]. 高电压技术, 2022, 48(5):1943 – 1951.
LU Junjie, CAI Tao, LANG Jianxun, et al. Short-term power output forecasting of clustered photovoltaic solar plants based on cluster partition [J]. High Voltage Engineering, 2022, 48(5):1943 – 1951.
- [3] 王育飞, 杨启星, 薛花. 考虑混沌特征的增强型大脑情绪神经网络光伏发电功率超短期预测模型[J]. 高电压技术, 2021, 47(4):1165 – 1175.
WANG Yufei, YANG Qixing, XUE Hua. Ultra-short-term prediction model of enhanced brain emotional neural network considering chaotic characteristics for photovoltaic power generation[J]. High Voltage Engineering, 2021, 47(4):1165 – 1175.
- [4] 杨国华, 张鸿皓, 郑豪丰, 等. 基于相似日聚类 and IHGWO-WNN-AdaBoost 模型的短期光伏功率预测[J]. 高电压技术, 2021, 47(4):1185 – 1194.
YANG Guohua, ZHANG Honghao, ZHENG Haofeng, et al. Short-term photovoltaic power prediction based on similar day clustering and IHGWO-WNN-Ada-Boost model [J]. High Voltage Engineering, 2021, 47(4):1185 – 1194.
- [5] PAZIKADIN A, RIFAI D, ALI K, et al. Solar irradiance measurement instrumentation and power solar generation forecasting based on Artificial Neural Networks (ANN): a review of five years research trend [J]. Science of The Total Environment, 2020(715):136848.1–136848.10.
- [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 – 1155.
LI Jinghua, LUO Yichen, YANG Shuhui, et al. Review of uncertainty forecasting methods for renewable energy power

- [J]. High Voltage Engineering, 2021, 47(4): 1144 – 1155.
- [7] 欧阳卫年, 赵紫昱, 陈渊睿. 自样本特征构造的 IDCNN-BiLSTM 网侧光伏功率预测[J]. 电力系统及其自动化学报, 2023, 36(3): 1 – 9.
OUYANG Weinian, ZHAO Ziyu, CHEN Yuanrui. Photovoltaic power prediction at the inverter side based on IDCNN-BiLSTM with self-sample feature construction [J]. Proceedings of the CSU-EPSA, 2023, 36(3): 1 – 9.
- [8] 崔京港, 王芳, 叶泽甫, 等. 基于 QD 和因果注意力 TCN 的光伏功率区间预测[J]. 太阳能学报, 2024, 45(3): 488 – 495.
CUI Jinggang, WANG Fang, YE Zefu, et al. Photovoltaic power interval prediction based on quantile decomposition and causal attention temporal convolutional network [J]. Acta Energetica Sinica, 2024, 45(3): 488 – 495.
- [9] SUN Y, WANG P, ZHAI S, et al. Ultra short term probability prediction of wind power based on LSTM network and condition normal distribution[J]. Wind Energy, 2020, 23(1): 63 – 76.
- [10] 钟浩, 方晨, 李世春, 等. 考虑光伏出力波动性和微电网协同的配电网黑启动策略[J]. 电测与仪表, 2025, 62(8): 123 – 132.
ZHONG Hao, FANG Chen, LI Shichun, et al. Black-start strategy of distribution network considering photovoltaic output volatility and micro-grid synergy[J]. Electrical Measurement & Instrumentation, 2025, 62(8): 123 – 132.
- [11] ZHAO C, WAN C, Song Y. An adaptive bilevel programming model for nonparametric prediction intervals of wind power generation[J]. IEEE Transactions on Power Systems, 2020, 35(1): 424 – 439.
- [12] 王开艳, 杜浩东, 贾嵘, 等. 基于相似日聚类 and QR-CNN-BiLSTM 模型的光伏功率短期区间概率预测[J]. 高电压技术, 2022, 48(11): 4372 – 4388.
WANG Kaiyan, DU Haodong, JIA Rong, et al. Short-term interval probability prediction of photovoltaic power based on similar day clustering and QR-CNN-BiLSTM[J]. High Voltage Engineering, 2022, 48(11): 4372 – 4388.
- [13] ATSUSHI Y, TOMONOBU S, TOSHIHISA F. Application of recurrent neural network to short-term-ahead generating power forecasting for photovoltaic system [C]//2007 IEEE Power Engineering Society General Meeting, June 24 – 28, 2007, Tampa, USA. New York: IEEE, 2007: 1 – 6.
- [14] 白如雪. 基于改进相似日和 LSTM 神经网络的短期光伏功率预测方法研究[D]. 济南: 山东大学, 2024.
- [15] CHEN Y, XU J. Solar and wind power data from the chinese state grid renewable energy generation forecasting competition [J]. Scientific Data, 2022, 9(577): 1 – 12.
- [16] 王晓东, 鞠邦国, 刘颖明, 等. 基于 QR-NFGLSTM 与核密度估计的风电功率概率预测[J]. 太阳能学报, 2022, 43(2): 479 – 485.
WANG Xiaodong, JU Bangguo, LIU Yingming, et al. Probability prediction of wind power based on QR-NFGLSTM and kernel density estimation [J]. Acta Energetica Sinica, 2022, 43(2): 479 – 485.
- [17] 薛阳, 李金星, 杨江天, 等. 基于相似日分析和改进鲸鱼算法优化 LSTM 网络模型的光伏功率短期预测[J]. 南方电网技术, 2024, 18(11): 97 – 105.
XUE Yang, LI Jinxing, YANG Jiangtian, et al. Short-term prediction of photovoltaic power based on similar day analysis and improved whale algorithm to optimize LSTM network model [J]. Southern Power System Technology, 2024, 18(11): 97 – 105.
- [18] 焦丕华, 蔡旭, 王乐乐, 等. 考虑数据分解和进化捕食策略的 BiLSTM 短期光伏发电功率预测[J]. 太阳能学报, 2024, 45(2): 435 – 442.
JIAO Pihua, CAI Xu, WANG Lele, et al. BiLSTM short-term photovoltaic power prediction considering data decomposition and evolutionary predation strategies [J]. Acta Energetica Sinica, 2024, 45(2): 435 – 442.
- [19] 王凌梓, 沈海波, 邓力源, 等. 基于相似日聚类与 WOA-BiLSTM-Copula 算法的短期风光功率相关性概率区间预测方法[J]. 南方电网技术, 2025, 19(8): 44 – 52.
WANG Lingzi, SHEN Haibo, DENG Liyuan, et al. Short-term wind and photovoltaic power correlation probability interval prediction method based on similar day clustering and WOA-BiLSTM-Copula algorithm [J]. Southern Power System Technology, 2025, 19(8): 44 – 52.
- [20] JUNG S, MOON J, PARK S, et al. An attention-based multilayer GRU model for multistep-ahead short-term load forecasting[J]. Sensors, 2021, 21(5): 1 – 20.
- [21] 郝富冲. 基于自注意力机制的短期光伏发电功率预测[D]. 重庆: 重庆理工大学, 2024.
- [22] 陈振祥, 林培杰, 程树英, 等. 基于 K-means++ 和混合深度学习的光伏功率预测[J]. 电气技术, 2021, 22(9): 7 – 13, 33.
CHEN Zhenxiang, LIN Peiie, CHENG Shuying, et al. Photovoltaic power prediction based on K-means++ and hybrid deep learning [J]. Electrical Engineering, 2021, 22(9): 7 – 13, 33.
- [23] 李崎勇, 班斓. 基于长短期记忆神经网络的短期光伏发电预测技术研究[J]. 华北电力大学学报(自然科学版), 2020, 47(4): 46 – 52.
LI Qiyong, BAN Lan. Research on short-term photovoltaic power generation forecasting technology based on long and short memory neural networks [J]. Journal of North China Electric Power University (Natural Science Edition), 2020, 47(4): 46 – 52.
- [24] 胡文慧, 苏欣, 姜林, 等. 考虑预测误差时空相依性的短期风电功率概率预测[J]. 南方电网技术, 2023, 17(2): 137 – 144.
HU Wenhui, SU Xin, JIANG Lin, et al. Short-term probabilistic forecasting of wind power considering the spatiotemporal dependence of prediction errors [J]. Southern Power System Technology, 2023, 17(2): 137 – 144.
- [25] 国家电网公司风电功率预测功能规范[S]. Q/GDW 10588—2015. 北京: 中国电力出版社, 2015.
- [26] 王朋, 孙永辉, 翟苏巍, 等. 基于小波长短期记忆网络的风电功率超短期概率预测[J]. 南京信息工程大学学报(自然科学版), 2019, 11(4): 460 – 466.
WANG Peng, SUN Yonghui, ZHAI Suwei, et al. Ultra-short-term probability prediction of wind power based on wavelet decomposition and long short-term memory network [J]. Journal of Nanjing University of Information Science and Technology (Natural Science Edition), 2019, 11(4): 460 – 466.

收稿日期: 2025-02-10; 网络首发日期: 2025-05-29

作者简介:

彭依明(1989), 女, 通信作者, 高级工程师, 学士, 研究方向为电力系统调度自动化, 20951666@qq.com;

王佳(1990), 女, 高级工程师, 学士, 研究方向为电力系统调度自动化, wj19900121@163.com;

周长城(1993), 男, 工程师, 硕士, 研究方向为新能源功率预测、新型电力系统分析, zhoucc@csg.cn.

征稿启事

《南方电网技术》是由中国南方电网公司主管、南方电网科学研究院有限责任公司主办的电力技术类科技期刊,向国内外公开发行人。刊登电力系统的科研、规划、设计、工程、生产运行、设备和系统维护等方面的成果、经验和动态,尤其是科研创新方面的论文。设有特约专稿、高压直流输电、高电压与绝缘、系统分析与运行、控制与保护、调度与通信、输变电技术、电力技术经济、智能电网、分布式电源与微电网、低碳电力等栏目。热烈欢迎国内外的电力研究人员、工程技术人员、大专院校师生踊跃投稿。

1 文稿要求

1)文稿应未在其他刊物上发表过,译文稿件须附上原作者的书面许可证明。内容要有科学性、创新性和实用性;论点明确、数据可靠、说理严谨、数学推导简明;语言流畅、文字简练、层次分明、重点突出。

2)学术论文请按GB 7713—1987《科学技术报告、学位论文和学术论文的编写格式》书写,篇幅以版面不超过9 000字(包括图表所占篇幅)为宜。同时请写明如下a,b,c,d,e五项:

a)作者署名(不宜超过7位)、作者单位、地址、电话、email信箱和邮政编码;

b)论文题目和作者单位英译文,作者姓名的汉语拼音;

c)作者的简历,包括姓名、出生年、性别、籍贯、职称、学位、当前从事的研究或工作等项;

d)350字左右的中文摘要,3~8个关键词,以及摘要和关键词相应的英文文本。摘要采用第三人称写法,内容包括论文的目的、方法、结果和结论;

e)若为国家基金资助项目或部、省级重大科研攻关项目,需提供项目名称及编号。

2 书写格式

1)要求文稿正文字号为5号,汉字字体为宋体,英数字体为Times New Roman,希腊字体为Symbol。文稿须采用可编辑的电子文档形式。

2)计量单位采用国家法定计量单位和符号,不能用“大气压”、“kgf/cm²”、“卡”、“ppm”等已废除的计量单位。

3)文中和公式中容易混淆的字符请注明文种(希文、英文、罗马字等)、大小写、上下标及上下标字母含义,表示矢量及矩阵的字符用黑斜体表示或特别注明。

4)文稿标题中不宜用缩略词(化学符号和公知公用者除外);摘要和正文中的缩略词在第一次出现时必须写出全称,后加括号附缩略词。

3 表格、插图及参考文献

1)表格尽量采用“三线表”。表格的上方写表序和表名。表名应有自明性且中文、英文表名并列。表注放在表底,缩入1个汉字以“注:”起头排版。

2)插图的下方面应有图序和图名。图名应有自明性且中英文图名并列。工程图、电气图和函数图采用AutoCAD、

Adobe Illustrator或Corel DRAW软件绘制,工程图和电气图要符合国家标准规定,函数图要标明曲线序号及其注释,坐标轴上要有标值、标目,注明物理量和单位;数码照片图具备200万总像素以上。

3)图片和表格中的文字、变量、单位和数字要齐全、清晰。

4)参考文献应选用公开发表的资料,按引用的先后次序列表于文后,以[1]、[2]…标识序号,且与正文中的指示序号一致。按《信息与文献 参考文献著录规则,GB/T 7714—2015》和《中国学术期刊(光盘版)检索与评价数据规范,CAJ-CD B/T 1—2006 修订版试行稿》的要求著录文后参考文献。中文参考文献后要并列其英文译文(如示例[6]所示)。

文献类型及其标识为:普通图书[M];会议论文[C];报纸文章[N];期刊文章[J];学位论文[D];报告[R];标准[S];专利[P];汇编[G];档案[B];古籍[O];参考工具[K];其他未说明的文献类型,例如可公开的政府行政部门编号文件、行业或大公司的技术规范或工作手册[Z]。网上期刊[J/OL];网上电子公告[EB/OL]。电子文献尚需在载体标记后加上发表或更新日期(加圆括号)、引用日期(加方括号)和电子文献网址。

4 投稿

1)请登录《南方电网技术》编辑部网站<https://nfdwjs.csg.cn>,选择“作者登录”,登录或注册登录后选择投稿并按提示操作,登录方面出现问题请致电020-36625646咨询。

2)投稿时务必附上联系电话(手机为佳)。

3)编辑部不保证留存稿件,请作者自留底稿。稿件评审进程和结论可在《南方电网技术》编辑部网站上即时查询。作者也可致电020-36625642、36625643或发送电子邮件到nfdwjs@csg.cn向编辑部了解审稿情况。

4)文章一经发表,编辑部便取得作者的自动授权,可将文章收录入本刊网站,及与本刊有合作关系的数据库。

参考文献著录格式示例:

- [1] 刘国钧,陈绍业,王凤翥. 图书馆目录[M]. 北京:高等教育出版社,1957:15-18.
- [2] 钟文发. 非线性规划在可燃毒物配置中的应用[C]//赵玮. 运筹学的理论与应用——中国运筹学会第五届大会论文集. 西安:西安电子科技大学出版社,1996:468-471.
- [3] 冯西桥. 核反应堆压力管道与压力容器的LBB分析[R]. 北京:清华大学核能技术设计研究院,1997.
- [4] 中国国家标准化管理委员会. 信息与文献 参考文献著录规则:GB/T 7714—2015[S]. 北京:中国标准出版社,2015.
- [5] 邓一刚. 全智能节电器:200610171314.3[P]. 2006-12-13.
- [6] 陈祥. 无线技术在现代电网管理中的应用与展望[J]. 南方电网技术,2009,3(6):85-89.
CHEN Xiang. Development of wireless technology in modern power grid management and its perspective [J]. Southern Power System Technology, 2009,3(6):85-89.
- [7] 王明亮. 关于中国学术期刊标准化数据库系统工程的进展[EB/OL]. (1998-08-16) [1998-10-04]. <http://www.cajcd.edu.cn/pub/wml.txt/980810-2.html>.

《南方电网技术》编辑部