

# 光伏发电功率预测方法综述

蔡源<sup>1,2</sup>, 吴浩<sup>1,2</sup>, 唐丹<sup>1,2</sup>

(1. 四川轻化工大学自动化与信息工程学院, 四川 宜宾 644000;

2. 人工智能四川省重点实验室, 四川 宜宾 644000)

**摘要:** 精确的光伏发电功率预测是实现光伏电站顺利并网的关键。然而, 太阳辐射、气候和地理条件等因素会导致光伏发电功率频繁波动, 给功率预测带来了巨大挑战。针对当前光伏新能源大规模并网的需求, 从多个角度探讨了光伏发电功率预测的意义及其分类, 综述了人工智能技术在光伏发电功率预测领域的最新应用, 包括传统机器学习、深度学习和组合方法, 并进行了对比和总结。目前研究的主要类型是单一光伏电站的超短期和短期光伏发电功率预测, 深度学习方法 and 组合方法是主流预测方法, 数据预处理、特征提取和误差补偿是提升预测精度的关键因素。最后, 展望了人工智能技术在光伏发电功率预测领域的未来趋势和研究创新点。

**关键词:** 光伏发电; 机器学习; 深度学习; 功率预测; 人工智能技术

**中图分类号:** TM 615 **文献标志码:** **文章编号:** 1003-6954(2024)02-0025-07

**DOI:** 10.16527/j.issn.1003-6954.20240205

## Reviews of Photovoltaic Power Prediction Methods

CAI Yuan<sup>1,2</sup>, WU Hao<sup>1,2</sup>, TANG Dan<sup>1,2</sup>

(1. School of Automation and Information Engineering, Sichuan University of Science & Engineering,

Yibin 644000, Sichuan, China; 2. Key Laboratory of Artificial Intelligence in Sichuan

Province, Yibin 644000, Sichuan, China)

**Abstract:** Accurate photovoltaic (PV) power prediction is the key to successful grid integration of PV power plants. However, factors such as solar radiation, climate and geographical conditions can cause frequent fluctuations in PV power generation, posing significant challenges to power prediction. In response to the current demand for large-scale grid integration of PV renewable energy, the significance and classification of PV power prediction are discussed from multiple perspectives. The latest applications of artificial intelligence (AI) technology in the field of PV power prediction are reviewed, including traditional machine learning, deep learning and hybrid methods, and are compared and summarized. Currently, the main types of researches are ultra-short-term and short-term PV power prediction for single PV power stations, and deep learning and hybrid methods are the mainstream prediction methods. Data pre-processing, feature extraction and error compensation are the key factors to improve prediction accuracy. Finally, future trends and research innovations in AI technology for PV power prediction are discussed.

**Key words:** photovoltaic power generation; machine learning; deep learning; power prediction; artificial intelligence technology

## 0 引言

近十年来, 化石能源消耗不断增加, 环境污染日趋严重, 已成为国际社会普遍关心的问题。世界上

**基金项目:** 四川省科技厅项目(2022YFS0518, 2022ZHCG0035); 四川轻化工大学研究生创新基金项目(Y2023294)

许多国家都在积极开发新的能源, 以解决能源短缺与环境污染问题, 因此, 太阳能作为一种洁净的能源, 已成为世界上最受重视的资源<sup>[1]</sup>。国际能源署2021年发布的全球光伏报告显示, 自2013年起世界范围内的光伏发电量持续稳定地增加, 至2021年中国新增光伏并网装机容量达到了54 880 MW, 创造历史新高。随着“双碳”的实施, 将会有越来越多

的光伏发电设施投入电网,这对电力系统的影响是不可小觑的,将电网带来巨大的冲击。

光伏电站主要由光伏阵列、转换器、逆变器、滤波器、变压器和保护装置组成,利用太阳能电池板的光伏效应,实现光能向电能的转换,然后并网输出。图 1 为光伏发电系统并网发电的基本结构。由于光伏系统的发电功率取决于许多高度不确定的气象变量,如太阳辐照度、温度、相对湿度、云层厚度、风速等,这使得光伏发电功率具有很强的波动性和不可控性<sup>[1]</sup>。

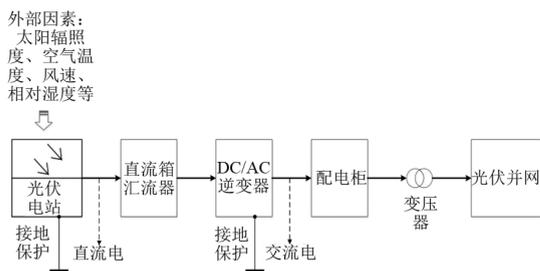


图 1 光伏电站并网发电的基本结构

可以预见,大规模光伏并网会极大地影响电力系统的稳定运行,造成电压浪涌、潮流分布变化等问题,同时给光伏产业渗透率的提升带来挑战。而可靠的光伏发电功率预测将大大减少这种影响,根据预测的光伏发电功率对电力资源进行调度,达到发电和消费之间的平衡,对提升电力系统运行的稳定性和电网管理的合理性具有重要意义。因此,精确的光伏发电功率预测是一个至关重要的研究领域,目前也已经取得了一定的研究成果。

下面首先从不同角度对光伏发电功率预测进行分类;然后对目前人工智能技术在光伏系统输出功率预测领域的最新应用,包括传统机器学习、深度学习和组合方法等进行了对比分析;最后对当下流行的光伏发电功率预测方法进行了总结,并对该研究领域的未来趋势和发展方向进行了展望,提出了一些可能的创新点。

## 1 光伏发电功率预测的分类

根据预测时间范围的不同,目前主要可以分为 3 种类型:预测范围小于 4 h 的超短期预测,主要用于控制和管理光伏系统、电能质量评估等;提前 24~72 h 的短期预测,主要用于控制电力系统运行、经济调度、机组投入等;中长期预测是时间尺度最长的预测,一般预测范围为一个月到一年,主要用于光伏

系统的维护和规划<sup>[2]</sup>。不同时间范围的预测,其精度也不同。随着时间范围变长,所需数据的量以及预测的复杂性都会增加,预测精度也会随之下降。

根据预测过程的不同,可分为直接预测和间接预测。直接预测,是通过实测的气象数据和历史光伏数据直接预测光伏发电功率;间接预测,是通过预测与光伏发电功率相关的气象因子,再通过数学模型输出光伏发电功率。由于间接预测的数学建模困难且误差较大,所以直接预测是目前的主流预测方法。

根据预测形式的不同,可分为点预测和区间预测<sup>[2]</sup>。点预测,即预测某一时刻的光伏发电功率;区间预测,即预测某一时间段的光伏发电功率波形,具有较强的不确定性。所以点预测是目前的研究重点。

根据预测空间大小的不同,可分为单光伏电站预测和区域光伏系统预测。由于区域光伏系统的功率预测需要大量且精确的光伏出力历史数据,数据处理难度较大,而且一个区域内的所有光伏电站并不是都有完整的数据系统,所以当前的区域光伏系统预测发展缓慢,但它们都对电力系统稳定运行以及电网消纳光伏具有积极作用<sup>[3]</sup>。

图 2 为光伏发电功率预测分类的依据和结果。

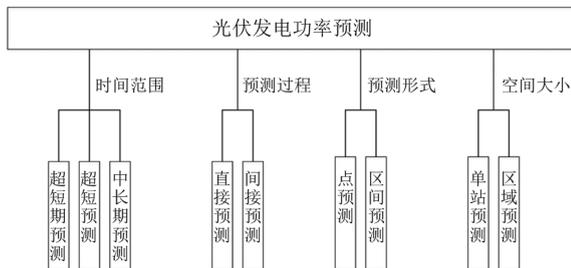


图 2 光伏发电功率预测分类

## 2 基于人工智能技术的光伏发电功率预测

人工智能技术有很多分支,但用于预测领域的主要有传统机器学习,包括监督学习、无监督学习等。深度学习也是机器学习的一个分支,它一般是由多层神经网络组成的模型,可以学习数据的各种抽象特征<sup>[4]</sup>。但传统机器学习方法和深度学习方法各有优劣,组合方法则可以将多种预测方法进行有效结合,取长补短,以此来提升功率预测的精度。

光伏发电功率预测的精度受到历史功率和多种气象因素的影响,可以用式(1)、式(2)描述光伏发

电功率预测问题。

$$\langle P_t, P_{t+1}, \dots, P_{t+k} \rangle = f_1(P_{t-1}, P_{t-2}, \dots, P_{t-n}) \quad (1)$$

$$\langle P_t, P_{t+1}, \dots, P_{t+k} \rangle = f_2(X_1, X_2, \dots, X_N) \quad (2)$$

式中:  $P_t, P_{t+1}, \dots, P_{t+k}$  为预测功率;  $P_{t-n}$  为历史功率;  $X_1, X_2, \dots, X_N$  为影响光伏发电功率的  $N$  个气象因子, 例如太阳辐照度、温度等;  $f_1$  为历史功率和预测功率的函数关系;  $f_2$  为气象因子和预测功率的函数关系。

## 2.1 传统机器学习的应用

传统机器学习算法很早就开始运用, 它可以被用来解决一些分类和回归方面的问题, 即在输入和输出之间构造对应的函数关系; 还可以解决聚类 and 异常值检测等方面的问题, 即探索数据集中的规则, 以便更好地描述数据的特征<sup>[4]</sup>。

在光伏功率预测领域, 国内外的众多文献中, 主要用到的传统机器学习算法有: 支持向量机 (support vector machines, SVM)、 $k$  近邻 ( $k$ -nearest neighbour,  $k$ -NN)、人工神经网络 (artificial neural network, ANN)、模糊逻辑、极限学习机 (extreme learning machines, ELM) 等。文献[5]开发了一种混合改进的多元宇宙优化 (hybrid improved multi-verse optimizer, HIMVO) 算法, 优化 SVM 的超参数, 用于预测提前一天的某兆瓦级光伏电站的光伏发电功率。并在 3 种不同天气下进行测试, 将结果对比 SVM 和 MVO-SVM 方法, 该方法的平均绝对百分比误差 (mean-absolute percentage error, MAPE) 在 3 种天气下的预测精度均最优, 尤其是在晴天情况下, MAPE 仅 5.30%。文献[6]使用基于  $k$ -NN 的方法来预测安装在 3 个不同地区的小型千瓦级光伏电站的发电量, 说明  $k$ -NN 等简单技术也可以得到相对准确的预测结果。文献[7]使用了 ANN 方法, 把气象数据作为输入, 最优情况预测功率的平均绝对误差 (mean absolute error, MAE) 为 3.64%, 说明经过信号分解的数据可以作为有价值的特征输入, 对提升预测精度具有积极作用。文献[8]提出的基于 T-S 模糊的方法, 将大量气象因子作为输入, 预测某千瓦级光伏电站发电功率, 并分季节进行测试, 结果对比如 SVM 方法、ANN 方法和其他经验模型, 所提模型在天气多变的夏季的 MAE 为 9.77, 且各季节均优于其他模型。文献[9]利用多种优化算法优化多层感知器模型, 预测某千瓦级光伏电站提前一天的光伏发电功率, 其中灰狼优化算法表现出了更突出的寻优能力, 日最佳的 MAPE 仅为 2.598%。文献[10]提出

了一种在线顺序 ELM 方法, 预测某小型千瓦级光伏电站发电功率, 并进行了不同天气类型和不同季节的测试, 结果对比经典 ELM, 其归一化均方根误差 (normalized root mean square error, NRMSE) 和 MAPE 均更优。文献[11]通过精英反向策略的麻雀搜索算法 (elite opposition-based sparrow search algorithm, EOSSA) 优化 ELM 的超参数, 预测某小型千瓦级光伏电站发电功率, 结果与 ELM、SSA-ELM 等算法相比, 该方法具有更快的收敛速度, 并且适用于多种天气类型, 日最佳的 RMSE 仅 0.17, 具有较高的工程实用性。文献[12]利用分散搜索优化支持向量机回归, 预测提前一天的光伏发电功率。运用概率神经网络将数据分成 4 种天气类型训练, 并使用主成分分析提取减少输入特征维度。在某千瓦级光伏电站上测试, 最优预测日的平均相对误差为 4.06%, 但在雨天的效果较差, 决定系数  $R^2$  低于 0.9。文献[13]基于定制相似日分析找出与预测日相似的历史日, 以更好地学习预测日的特征, 并利用遗传算法优化 ELM, 再利用某千瓦级光伏电站一年四季的历史数据进行测试, 该方法的预测误差小于 SVM 和经典 ELM, 四季平均  $R^2$  达到 0.92, 证明了相似日聚类的有效性。

传统机器学习算法易于实现和解释, 且目前在该领域的应用研究已趋于成熟, 应用范围主要是数据量较小的中小规模的光伏电站。但是对于复杂的非线性关系和庞大的数据量时, 传统机器学习算法的表现可能不如深度学习等新型算法。

## 2.2 深度学习的应用

在过去的几年时间里, 深度学习在各个领域都有很好的表现, 包括文字识别、语音识别、智能驾驶和图像处理等方面。在光伏功率预测领域, 主要是利用深度神经网络的自动学习能力, 构造从多输入到单输出或多输出的复杂映射关系<sup>[14]</sup>。

循环神经网络 (recurrent neural network, RNN) 基于其结构使它在预测问题上有着良好的表现, 但无法处理长期时间序列, 所以逐渐研发出了新的循环单元 (recurrent unit, RU) 来解决这一问题, 其中应用最广泛的主要是长短期记忆网络 (long short-term memory, LSTM) 和门控循环单元 (gated recurrent unit, GRU)<sup>[14]</sup>。文献[15]利用互信息熵 (mutual information entropy, MIE) 对高维气象因子进行降维以及筛选出相似日样本, 通过 LSTM 预测某兆瓦级光伏电站提前一天的功率输出, 预测日最优 MAPE

为 10.89%, 优于 BP (back propagation) 神经网络和 Elman 神经网络。文献[16]运用独立循环神经网络 (independent recurrent neural network, indRNN), 提取环境因子作为输入特征向量, 并且将该方法与 RNN 和 LSTM 进行对比, 实验表明: indRNN 解决了 RNN 的梯度弥散或爆炸难题, 而且该模型具有很强的记忆能力, 训练速度也更快; 采用小型兆瓦级光伏电站数据, 选取不同天气类型数据进行测试, 最优预测日的 MAE 为 0.41, 优于 BP、KNN 和经典 LSTM。文献[17]介绍了一种六层前馈深度神经网络, 用于某小型千瓦级并网光伏系统的光伏功率预测; 在最优测试日, 该方法远优于经典 DNN, MAPE 为 0.012, 然而在夏季的多变天气时预测的误差较大。文献[18]进行了一项关于不同深度神经网络的提前一天预测的比较研究, 该研究包括卷积神经网络 (convolutional neural network, CNN)、LSTM 和一个结合了 CNN 和 LSTM 的混合模型; 结果表明这 3 种模型的精度主要取决于可用数据集序列的大小, 证明了输入和输出序列的长短对预测精度的影响。文献[19]通过在 GRU 模型的隐藏层中添加注意力机制 (Attention), 计算各个输入特征向量的注意力概率分布权重, 形成 GRU-A 模型; 利用某兆瓦级光伏电站数据进行训练测试, 相比于 GRU、LSTM 和 BP 预测模型具有更好的精度表现, 最优预测日的  $R^2$  为 0.98。文献[20]设计了一种基于循环 LSTM 的方法, 同时提出了合成辐照度作为模型输入, 用于某兆瓦级光伏电站的光伏输出功率预测; 分季节进行测试, 与 RNN、广义回归神经网络 (general regression neural network, GRNN)、ELM 方法相比, 该方法的性能最佳, 且使用合成辐照度预报为输入特征时, 精度可提高 33%。文献[21]针对 LSTM 参数量多和处理长时间序列能力不足的问题, 提出 Attention-GRU 模型用于预测提前一天的光伏发电功率; 建立了 3 种不同天气类型的数据集, 实验表明在多云天和雨天时的预测精度不如晴天时的预测精度, 且测试晴天时的希尔不等系数 (Theil inequality coefficient, TIC) 为 8.48%, 对比 GRU、LSTM 和 Attention-LSTM 模型, 该方法在 3 种天气类型的表现均更优。文献[22]使用经典 LSTM 网络进行某大型千瓦级光伏电站的光伏发电功率预测, 探究了多种优化器对预测结果的影响, 每隔 5 天进行测试, 最终发现 Nadam 优化器在所有测试集中的误差指标均最低, 尤其对比 Ftrl 优化器的预测精度提高了 58.29%。

文献[23]利用近邻传播算法将区域内的兆瓦级光伏电站群进行聚类, 通过长短期时间序列网络 (long and short-term time-series network, LSTNet) 实现了群内多个光伏电站的同时预测, 对比单站预测, 该方法的训练时间和预测误差均大幅降低。文献[24]通过引入变量选择、长短期时间序列特征提取和一步时间卷积网络解码, 提出了一种新型预测模型 TCNformer, 并通过消融实验验证了各个模块的有效性; 设置不同预测步长与短期预测领域的众多算法进行比较, 随着预测步数的增加, 该方法的误差累积水平最低, MSE 远低于 LSTM。

深度学习方法具有较强的非线性建模能力, 而且能够自动学习和提取输入数据的特征, 减少了人工干预和工作量; 并且可以处理大规模、高维度的数据, 适用于各种复杂的光伏系统。

### 2.3 组合方法的应用

组合方法主要是解决单个预测方法性能不足的问题, 为了提高预测准确度, 将多种预测模型组合, 达到优势互补的目的。目前主流的组合方式一般有两种, 第一种选择两种预测模型并行预测, 将得到的结果进行权值分配, 最后加权组合得到更为准确的预测结果; 第二种是采用信号分解技术, 对输入特征序列数据进行分解, 降低数据的波动性, 然后采用单个或多个预测模型再对各个子序列分别预测, 最后叠加重构各子序列的预测结果<sup>[25]</sup>。

文献[26]将历史样本数据依据天气进行分类, 通过扩展经验模态分解 (extended empirical modal decomposition, EEMD) 分解历史光伏数据为多个模态分量 (intrinsic mode functions, IMF) 以降低其波动性, 并且选取强相关量分别用 LSTM 网络训练测试, 最后将各分量预测结果重构叠加, 得到最终预测结果。对比 BP、SVM、KNN 和 LSTM 模型, 该模型的 RMSE 和 MAPE 均有不同程度的提高。

文献[27]将离散小波变换 (discrete wavelet transform, DWT)、CNN 和 LSTM 进行深度融合, 利用 CNN 分别提取经过 DWT 分解和未经过分解的输入特征序列, 再分别输入 LSTM 模型进行预测。在一年的测试集中选取 12 天典型天气进行测试, 实验结果表明, 对比多层感知机 (multilayer perceptron, MLP)、支持向量回归 (support vector regression, SVR)、CNN 和 LSTM 模型, 所做模型对不同天气的适应性具有明显优势, 并且各种误差评价指标都低于其他模型。

文献[28]同样使用了 CNN-LSTM 模型进行某千瓦级光伏输出功率的超短期预测,但不同的是融入了基于地基云图像转化的辐照系数作为输入特征,并加入了基于竞争随机搜索算法改进的 Attention 机制和误差补偿。在 3 种典型天气情况下,通过与典型文献的预测方法进行对比实验,该方法比次优方法的 RMSE 最多降低了 25.89%,但对未配备全天空成像仪的光伏电站,其工程意义较低。

文献[29]提出了组合式深度学习预测模型,用于某地光伏电站提前 15 min 的光伏输出功率预测。首先使用小波包分解(wavelet packet decomposition, WPD)对原始光伏功率序列数据进行分解,并分别采用 RNN、LSTM 和 GRU 3 种模型分别预测,将得到的 3 个预测结果利用强化学习算法 Q-learning 进行权值分配优化。同样在一年中选取 12 天典型天气进行测试,预测结果表明 WPD 确实可以提升预测准确率;组合模型对比 3 种单一模型的预测效果均更优秀;Q-learning 能够优化权值分配,提升了模型的适应性和预测精度;证明了强化学习对光伏发电功率预测精度提升具有积极作用。

文献[30]运用动态惯性因子的粒子群优化算法(particle swarm optimization algorithm based on dynamic inertia factor, DIFPSO)优化 BP 网络,同时利用互补集成经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)将原始序列分解为多个 IMF 和残差分量,最终各分量预测结果叠加,选用某千瓦级光伏电站数据的 3 天典型不同天气及性能测试,最优预测日的 MAE 为 2.84,而  $R^2$  达到 0.99。

文献[31],使用了集合经验模态分解(ensemble empirical mode decomposition, EEMD)和(variational mode decomposition, VMD)两阶段分解技术,再结合双向长短期记忆网络(bidirectional long-short term memory, BiLSTM)进行多步预测,用于某地光伏电站的短期功率预测。测试实验得出结论:两阶段分解可以显著降低数据的波动性和预测难度,对提升预测精度具有积极作用;BiLSTM 相对于 GRU、LSTM、ANN 等预测方法具有更高的预测精度,应用前景广阔。

文献[32]使用 CNN 提取输入数据分布特征,再通过 LSTM 提取时间特征,同时与极端梯度提升(extreme gradient boosting, XGBoost)模型并行预测,利用误差倒数法分配权值。选用某小型千瓦级光伏电站的 3 天典型不同天气进行测试,所做的组合模

型在最优预测日的 MAE 为 0.24,且测试结果均优于单一模型。

文献[33]提出改进松鼠觅食算法(improved squirrel search algorithm, ISSA)优化核极限学习机(kernel based extreme learning machine, KELM)。并利用 VMD 平稳化光伏发电功率序列,选取某千瓦级光伏电站的 3 天典型天气进行测试,最优预测日的 MAE 为 0.50, MAPE 仅 0.32%。

文献[34]研究结合自适应白噪声完备集成经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)来减少光伏输出功率的波动性,通过增量搜索法改进最小二乘支持向量机(least square support vector machine, LSSVM),同时建立差分自回归移动平均模型(autoregressive integrated moving average, ARIMA)进行误差修正,把误差功率预测值和最初功率预测值相加,得到最终预测结果。采用某地光伏电站历史数据进行验证,证明了进行误差预测可以减小平均误差,提升最终预测精度。

文献[35]提出了一种基于小波分解和 PSO-SVM 的组合方法,用于某地千瓦级光伏系统发电功率的短期预测。模型的输入数据为光伏系统历史功率和来自数值天气预报(numerical weather prediction, NWP)的气象参数。测试结果表明,对比 BP 和 SVM 模型,所提出的模型具有更好的性能,每日 MAPE 的平均值分别为 4.22%,平均计算时间小于 15 s。

文献[36]采用海洋捕食者算法(marine predators algorithm, MPA)优化 LSTM 的隐含层神经元数和网络超参数,提出利用统计学上的估计方法 Bootstrap 进行预测误差分析,获得给定置信水平下的误差分布区间。分季节进行区间预测的测试;对比参数法中的 Gaussian 分布和 Gamma 分布,Bootstrap 可以更准确描述光伏发电功率的误差分布,最优测试季节的预测区间覆盖率(prediction interval coverage probability, PICP)为 97.8%。

文献[37]利用模糊 C 均值算法对数据集进行相似日聚类,通过改进的自适应噪声完全集成经验模态分解对原始光伏数据进行分解,并基于样本熵重构,最后通过条件时间序列生成对抗网络(conditional time series generative adversarial networks, CTGAN)进行预测。所提出的混合模型在不同气象条件、不同位置和不同季节的多步预测性能均优于其他常规预测模型。

文献[38]通过在 LSTM 上引入注意力机制重建输入,并提出了扩张 CNN 和 BiLSTM 的平行结构,最后利用迁移学习策略减少对大量训练数据的依赖。测试结果明显表明,该混合模型在准确性和稳定性方面优于其他模型,优化了新光伏电站的预测时数据不足的问题。

组合方法通过将多个预测模型的结果进行综合或融入其他的数据处理方法,避免了单一模型的特殊性问题,因此在光伏发电功率预测中具有更加广泛的适用范围。随着新型预测模型和集成强化学习的出现,组合方法的预测可靠性和功能可扩展性也会进一步提升。

### 3 结 论

太阳能是一种清洁的可再生能源,未来也将会更多的光伏电站并网发电,基于人工智能技术的光伏发电功率预测技术可以减少光伏并网对电网的扰动<sup>[39]</sup>。上面回顾了国内外近几年来传统机器学习、深度学习和组合方法在光伏发电功率预测的应用,通过文献的对比分析,可以得到以下结论:

1) 国内外研究最多的是超短期和短期光伏输出功率预测,它们能为电力调度部门提供准确依据,减少因光伏发电功率易波动而对电网造成的冲击,这也是最符合电力系统稳定性需求的。相反,中长期预测的研究很少,主要是因为预测所需的数据量很大,预测输出的时间序列太长,预测精度低。

2) 将天气因素作为预测模型的输入特征,可以有效提升预测精度。将输入数据依据天气类型分别训练测试时,晴天的预测效果较好,而多云或雨天时的预测精度较差,主要是因为晴天的太阳辐射度比较稳定。其他天气情况时,由于云层遮挡情况和太阳照射情况变化较快,导致发电功率具有间歇性和波动性。

3) 利用信号分解技术可以降低光伏发电功率序列的波动性,经过分解的特征序列作为模型输入一定程度上提高了预测准确率。近几年研究人员开发了许多误差预测方法,实验结果表明,误差预测分析可以描述光伏功率的波动范围,并进一步提升预测精度。

4) 目前的大多数研究是针对单个光伏电站的功率预测,而针对整个区域光伏系统或者微电网的光伏出力预测相对较少,准确率也比较低。根据近

两年的国内外文献的数量来看,主流的预测方法是深度学习和组合方法。

未来,为了提高基于人工智能技术的光伏发电功率预测的准确性,可以从以下几个方面考虑:创建高质量的大型历史光伏数据集;开发新的数据预处理方法,包括数据分析、异常值识别和缺失值检测;应用最新的强化学习和集成学习方法,并与其他预测模型组合;将人工智能预测方法与物理模型相结合。

#### 参考文献

- [1] 陈嘉铭. 基于深度学习和强化学习的光伏发电功率预测研究[D]. 广州: 广东工业大学, 2022.
- [2] 田剑刚. 基于 GRU 深度学习的光伏发电超短期功率预测研究[D]. 南昌: 华东交通大学, 2021.
- [3] 孟祥剑. 基于数据驱动的光伏发电系统最大功率跟踪及功率预测方法[D]. 济南: 山东大学, 2021.
- [4] MELLIT A, MASSI PAVAN A, OGLIARI E, et al. Advanced methods for photovoltaic output power forecasting: a review[J]. Applied Sciences, 2020, 10(2):487.
- [5] 马骏, 吴锐, 丁倩, 等. 基于多元宇宙优化支持向量机的短期光伏发电功率预测[J]. 热力发电, 2020, 49(4): 87-92.
- [6] ZHANG Y, BEAUDIN M, TAHERI R, et al. Day-ahead power output forecasting for small-scale solar photovoltaic electricity generators [J]. IEEE Transactions on Smart Grid, 2015, 6(5):2253-2262.
- [7] ZHU H L, LI X, SUN Q, et al. A power prediction method for photovoltaic power plant based on wavelet decomposition and artificial neural networks[J]. Energies, 2015, 9(1):11.
- [8] LIU F, LI R R, LI Y, et al. Takagi-Sugeno fuzzy model-based approach considering multiple weather factors for the photovoltaic power short-term forecasting[J]. IET Renewable Power Generation, 2017, 11(10):1281-1287.
- [9] COLAK M, YESILBUDAK M, BAYINDIR R. Daily photovoltaic power prediction enhanced by hybrid GWO-MLP, ALO-MLP and WOA-MLP models using meteorological information[J]. Energies, 2020, 13(4):901.
- [10] WANG J D, RAN R, Zhou Y. A short-term photovoltaic power prediction model based on an FOS-ELM algorithm[J]. Applied Sciences, 2017, 7(4):423.
- [11] 陈骏豪, 张娜, 刘广忱, 等. 基于 EOSSA-ELM 的光伏短期输出功率预测[J]. 可再生能源, 2022, 40(7): 890-898.
- [12] 王昕, 黄柯, 郑益慧, 等. 基于 PNN/PCA/SS-SVR 的光伏发电功率短期预测方法[J]. 电力系统自动化, 2016, 40(17):156-162.

- [13] ZHOU Y, ZHOU N R, GONG L H, et al. Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine [J]. Energy, 2020, 204:117894.
- [14] MELLIT A. An overview on the application of machine learning and deep learning for photovoltaic output power forecasting [C]//Proceedings of the 2nd International Conference on Electronic Engineering and Renewable Energy Systems, April 13–15, 2020, Saidia, Morocco: Springer, 2020:55–68.
- [15] 吉铎格,李慧,刘思嘉,等.基于 MIE-LSTM 的短期光伏发电功率预测[J].电力系统保护与控制,2020,48(7):50–57.
- [16] 王超洋,张蓝宇,刘铮,等.基于特征挖掘的 indRNN 光伏发电功率预测[J].电力系统及其自动化学报,2021,33(4):17–22.
- [17] SON Junsen, PARK Yongtae, LEE Junu, et al. Sensorless PV power forecasting in grid-connected buildings through deep learning[J]. Sensors, 2018, 18(8):2529.
- [18] WANG K J, QI X X, LIU H D. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network [J]. Applied Energy, 2019, 251:113315.
- [19] 张进,刘运,彭曙蓉.基于特征挖掘的 GRU-A 光伏发电功率预测[J].实验室研究与探索,2020,39(5):25–30.
- [20] HOSSAIN M S, MAHMOOD H. Short-term photovoltaic power forecasting using an LSTM neural network and synthetic weather forecast [J]. IEEE Access, 2020, 8:172524–172533.
- [21] 刘国海,孙文卿,吴振飞,等.基于 Attention-GRU 的短期光伏发电功率预测[J].太阳能学报,2022,43(2):226–232.
- [22] SHARMA J, SONI S, PALIWAL P, et al. A novel long term solar photovoltaic power forecasting approach using LSTM with Nadam optimizer: A case study of India [J]. Energy Science & Engineering, 2022, 10(8):2909–2929.
- [23] 王晓霞,俞敏,霍泽健,等.基于近邻传播聚类与 LSTM 的分布式光伏电站群短期功率预测[J].电力系统自动化,2023,47(6):133–141.
- [24] LIU S P, NING D J, MA J. TCNformer model for photovoltaic power prediction [J]. Applied Sciences, 2023, 13(4):2593.
- [25] 王莹.基于深度学习的光伏发电功率短期预测研究[D].青岛:青岛科技大学,2022.
- [26] 卢忠山,袁建华.基于 EEMD-LSTM 方法的光伏发电系统超短期功率预测[J].中国测试,2022,48(12):125–132.
- [27] 刘旭丽,莫毓昌,吴哲,等.基于 DWT-CNN-LSTM 的超短期光伏发电功率预测[J].郑州大学学报(理学版),2022,54(4):86–94.
- [28] 余光正,陆柳,汤波,等.基于云图特征提取的改进混合神经网络超短期光伏功率预测方法[J].中国电机工程学报,2021,41(20):6989–7003.
- [29] 孟安波,许炫淙,陈嘉铭,等.基于强化学习和组合式深度学习模型的超短期光伏功率预测[J].电网技术,2021,45(12):4721–4728.
- [30] NIU D X, WANG K K, SUN L J, et al. Short-term photovoltaic power generation forecasting based on random forest feature selection and CEEMD: A case study [J]. Applied soft computing, 2020, 93:106389.
- [31] LIN W S, ZHANG B, LI H Y, et al. Multi-step prediction of photovoltaic power based on two-stage decomposition and BiLSTM [J]. Neurocomputing, 2022, 504:56–67.
- [32] 汤德清,朱武,侯林超.基于 CNN-LSTM-XGBoost 模型的超短期光伏功率预测[J].电源技术,2022,46(9):1048–1052.
- [33] 商立群,李洪波,侯亚东,等.基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J].电力系统保护与控制,2022,50(21):138–148.
- [34] 王瑞,高强,逯静.基于 CEEMDAN-LSSVM-ARIMA 模型的短期光伏功率预测[J].传感器与微系统,2022,41(5):118–122.
- [35] ESEYE A T, ZHANG J H, ZHENG D H. Short-term photovoltaic solar power forecasting using a hybrid wavelet-PSO-SVM model based on SCADA and meteorological information [J]. Renewable Energy, 2018, 118:357–367.
- [36] 宋绍剑,罗世坚,李国进,等.基于 MPA-LSTM 模型和 Bootstrap 方法的短期光伏功率区间预测[J].广西大学学报(自然科学版),2022,47(4):986–997.
- [37] LI F Y, ZHENG H F, LI X M. A novel hybrid model for multi-step ahead photovoltaic power prediction based on conditional time series generative adversarial networks [J]. Renewable Energy, 2022, 199:560–586.
- [38] TANG Y G, YANG K, ZHANG S J, et al. Photovoltaic power forecasting: A hybrid deep learning model incorporating transfer learning strategy [J]. Renewable and Sustainable Energy Reviews, 2022, 162:112473.
- [39] 吴硕.光伏发电系统功率预测方法研究综述[J].热能动力工程,2021,36(8):1–7.

#### 作者简介:

蔡源(2000),男,硕士研究生,研究方向为光伏发电功率预测;

吴浩(1980),男,博士,教授,硕士生导师,研究方向为智能信息处理、电力系统及智能控制;

唐丹(1999),女,硕士研究生,研究方向为电缆故障识别和定位。

(收稿日期:2023-06-09)