

长短期记忆网络在光伏与风电功率预测中的作用

闫立春 牛强 吕立进

摘要:截至2023年底,全国累计发电装机容量约29.2亿千瓦,同比增长13.9%。其中,太阳能发电装机容量约6.1亿千瓦,同比增长55.2%;风电装机容量约4.4亿千瓦,同比增长20.7%,长短期记忆网络(LSTM)在光伏与风电功率预测中扮演着核心角色。由于光伏与风电产出受到天气条件和季节变化的影响,存在高度的非线性和波动性,这使得传统的预测方法难以准确预测。LSTM作为一种特殊类型的循环神经网络(RNN),能够有效处理时间序列数据中的长期依赖关系,通过其独特的“门”结构(输入门、遗忘门和输出门),LSTM不仅能捕捉到时间序列数据中的长期趋势,还能适应数据中的短期波动,从而在预测未来光伏与风电产出方面表现出优越性。此外,LSTM的这一能力对于解决不稳定电能产出带来的挑战至关重要,可以帮助电力系统运营商更有效地进行资源规划和调度。

关键词:长短期记忆网络;光伏;风电功率预测;作用

随着全球能源结构的转型和可再生能源技术的不断发展,光伏与风电作为清洁能源的代表,在能源市场中占据了越来越重要的地位。就我国光伏产业而言,2023年1-11月,全国光伏累计新增装机163.88GW,其中11月光伏新增装机21.32GW,12月新增装机53GW,同比增长144%,然而,光伏与风电的功率输出受天气和环境因素的影响较大,这种间歇性和不确定性给电力系统的稳定运行带来了挑战。准确的功率预测不仅可以优化电网管理,减少备用容量的需求,还能降低电力成本,提高系统的经济性和可靠性。长短期记忆网络(LSTM)凭借其对时间序列数据处理的独特优势,成为了解决这一问题的有力工具。LSTM是一种特殊的循环神经网络,它通过学习历史数据中的长期依赖信息,能有效预测未来一段时间内的功率输出。

一、光伏与风电功率特性分析

1. 光伏发电原理及功率特性

(1) 光伏发电的基本原理

光伏发电技术是将太阳光能直接转换为电能的一种技术。其核心部件是太阳能电池,这种电池通过半导体材料受到光照时产生光电效应,从而生成电压和电流。最常用的半导体材料是硅,包括单晶硅和多晶硅。光伏系统通常包括电池板、控制器、蓄电池和逆变器等组成部分^[1]。

(2) 光伏功率的时间序列特性

光伏功率输出具有明显的时间序列特性,它依赖于日照强度、气温、季节、地理位置等多种因素。一般而言,光伏功率在白天产生,且在中午时分达到峰值,夜间则基本为零。除了这种日常周期性变化外,还会受到云层覆盖、空气质量等短期气象条件的影响,使得功率发生波动。

2. 风力发电原理及功率特性

(1) 风力发电的基本原理

风力发电是利用风能驱动风轮旋转,通过增速机构提高转速,带动发电机发电的一种技术。风力发电机组通常包括风轮、增速箱、发电机、控制系统以及塔架等部分。风能资源丰富的地区,特别是海上风力发电,已经成为重要的清洁能源发电方式。

(2) 风电功率的时间序列特性

风电功率的时间序列特性主要体现在风速的不规则变化上,而风速受地理位置、气候条件、季节和昼夜变化等因素的影响。因此,风电功率同样展现出显著的日常周期性和季节性特征,以及由天气系统引起的随机波动性。风电场的布局和地形也会对风速及其功率输出产

作者简介:

1. 闫立春(1978.02——),女,汉族,硕士学历,高级工程师,主要从事新能源发电、综合能源研究工作;
2. 牛强(1980.03——),男,汉族,硕士学历,高级工程师,主要从事新能源发电、综合能源研究工作;
3. 吕立进(1985.01——),男,汉族,本科学历,高级工程师,主要从事新能源、综合能源领域的规划、设计、研究以及工程管理方面的工作。

生影响^[2]。

二、长短期记忆网络理论基础

1. 长短期记忆网络的发展历程

长短期记忆网络的发展可以追溯到1997年，由Hochreiter和Schmidhuber首次提出。他们设计了一种特殊的循环神经网络隐藏层节点，即长短期记忆块，以解决标准循环神经网络面临的梯度消失和梯度爆炸问题。此后，LSTM经历了多次改进，特别是在遗忘门的控制机制、门控单元的规范和深度LSTM网络的异构结构设计等方面得到了进一步的发展和完善。如今，LSTM已成为处理序列数据问题中最著名和最成功的神经网络架构之一。

2. LSTM网络结构分析

(1) LSTM神经元结构

LSTM神经元结构是该网络的核心。每个LSTM神经元包含三个门（输入门、遗忘门和输出门）和一个细胞单元。细胞状态在神经元中扮演着“记忆”的角色，它可以保存、写入和读取信息。门控单元负责调节信息流，以确定何时允许更新细胞状态，何时保留之前的状态，以及何时让细胞状态影响输出。这种结构使得LSTM能够有效地解决长期依赖问题，即在序列数据中捕捉到距离较远的信息点之间的关联。图1为以时间序列表示的LSTM网络，其由多个LSTM单元组成，每个时刻的A模块均代表一个LSTM单元，随着时间t的增加，可得到各时刻的隐藏层输出 h_t ，网络中的记忆信息也会随之更新^[3]。




图1 LSTM网络时序展开图

(2) LSTM的网络流程

LSTM的网络流程描述了信息如何在LSTM神经元中流动和处理。在时刻t，输入门根据当前的输入和上一时刻的隐藏状态来决定哪些信息需要被更新到细胞状态中。接下来，遗忘门决定哪些信息需要从细胞状态中丢弃。细胞状态更新后，输出门控制细胞状态对当前隐藏状态的影响程度。最终产生的隐藏状态将作为网络的输出，并传递给下一个神经元。这一流程在每一个LSTM神经元中不断重复，沿着时间展开，形成了处理整个序列的机制。

三、基于LSTM的光伏与风电功率预测模型构建

某屋顶分布式光伏电站，该电站由平行安装于建筑物屋顶的80片太阳能电池组件构成。一张太阳能光伏板的长度为2m，宽度为1.5m，光伏板总面积为120m²，光伏板固定安装，倾斜角度为20°，装机容量为40kWp。分布式光伏电站监测平台对其输出功率与所在环境进行实时监测并记录，主要包括光伏发电功率（P/kW）、太阳辐射强度（S/W·m²）、环境温度（T/℃）、电池板温度（t/℃）、风速（F/m·s⁻¹）、风向（°），测量范围与精度分辨率的具体参数如表1所示。部分实时监测的环境数据如表2所示。

表1 监测参量与传感器精度

监测对象（实时）	测量范围	分辨率
实时功率/kW	0~10	0.01
辐射强度/W·m ⁻²	0~1000	1.00
环境温度/℃	-50~100	0.10
电池板温度/℃	-50~50	0.10
风速/m·s ⁻¹	0~45	0.10
风向/(°)	0~360	1.00

表2 部分实时监测环境数据

时刻	辐射强度 (W/m ²)	电池板温 度(℃)	环境温度 (℃)	风速 (m/s)	风向
12: 50	956	23.8	17.2	2.6	东 105
12: 56	952	24.3	16.9	0.9	东南 131
13: 02	907	23.2	16.5	1	东南 121
13: 08	890	23	15.9	4.4	东 108

1. 预测模型的框架设计

建立PSO-SLTM模型，将EEMD分解出的分量信号

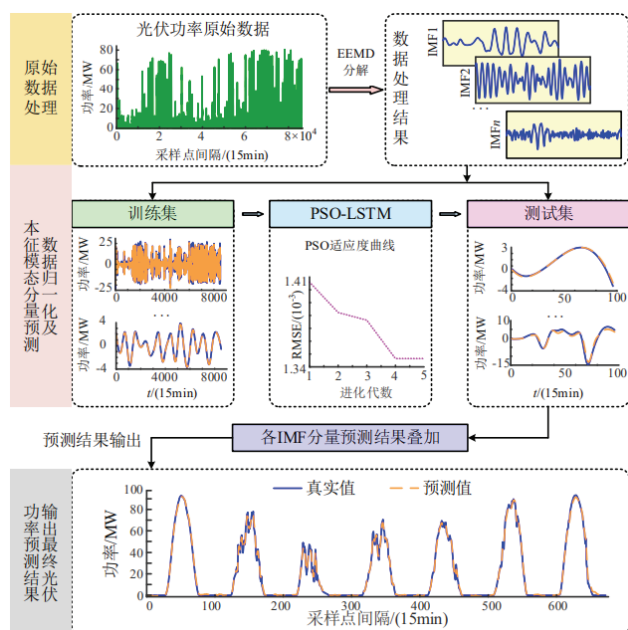


图2 光伏功率组合预测流程图

分别输入 PSO-LSTM 并建立预测模型，该组合预测算法流程如图 2 所示，其具体步骤如下：(1) 原始数据处理。利用 EEMD 方法对原始的光伏功率数据进行分解，得到一组 IMF 分量 $\{IMF_1, IMF_2, \dots, IMF_n\}$ 和残余项 m 。(2) 数据标准化。将每个 IMF 分量和剩余项进行归一化处理。并将数据分为训练集和测试集，训练集用于训练对应的预测模型。(3) 本征模态分量预测。将每个 IMF 分量和残余项分别输入经训练的 PSO-LSTM 模型进行预测。(4) 当所有序列预测都进行完毕时，将其预测结果叠加得到模型的最终预测结果。

2. 数据预处理与特征工程

数据预处理主要包括数据清洗和归一化两个关键过程。数据清洗的目的是去除或修正数据集中的噪声和异常值，这些通常由传感器误差、数据传输错误或设备故障引起。归一化则是将数据变换到统一的尺度，使得不同特征之间具有可比性，这有助于 LSTM 网络更好地理解数据中的模式。特征工程涉及到从时间序列数据中提取有助于预测的特征，如时间戳、天气条件、历史功率输出等。通过构建滞后变量、滑动窗口统计特征和频域变换等，可以增强模型对数据中潜在趋势和依赖性的识别能力。例如，通过分析前一天同一时刻的功率输出，可以获得日周期性特征；通过计算滑动平均或趋势线，可以捕捉数据的中长期趋势。这些特征一旦提取，便构成了训练 LSTM 网络的输入矩阵，为模型训练和预测提供了基础^[4]。

3. LSTM 模型的构建与训练

LSTM 模型参数设置涉及层数、每层神经元数量、激活函数的选择以及用于防止过拟合的正则化技术。这些参数的选择需要根据具体的数据集和预测需求进行调整。模型训练与验证过程开始于数据的划分，一般按照一定比例分为训练集、验证集和测试集，以确保模型的性能可以在独立数据上进行评估。使用训练集数据对 LSTM 模型进行训练时，反向传播算法会根据误差梯度更新网络权重。验证集则用于监控模型训练过程中的性能变化，避免过拟合，并指导模型的保存和早期停止。一旦模型在验证集上的性能不再提升，即可停止训练并保留当前最优模型。最终，使用测试集对训练完成的 LSTM 模型进行评估，确保模型的泛化能力和实用性。

4. 模型评估与误差分析

模型评估与误差分析是基于 LSTM 的光伏与风电功

率预测模型构建的最后阶段。评估指标选择对于衡量模型性能至关重要，常用的指标包括均方误差 (MSE)、根均方误差 (RMSE) 和平均绝对误差 (MAE) 等，这些指标能够从不同角度反映预测结果的准确性和稳定性。误差分析与模型调整是提高预测性能的关键环节。通过深入分析预测误差，可以识别出模型在特定条件下的表现不足，并针对性地调整 LSTM 网络的结构、参数或预处理方法。例如，如果发现模型在波动较大的天气条件下预测误差较大，可能需要增加相关的输入特征或调整网络以更好地捕捉这种变化。这个过程可能需要多次迭代，每次根据误差分析的结果调整模型，然后重新训练和评估，直到达到满意的预测效果。

结语

长短期记忆网络 (LSTM) 的应用在光伏与风电功率预测领域展现出显著的效能和潜力。通过深入分析和学习历史功率数据及其与环境因素之间的复杂关系，LSTM 不仅提高了预测的准确性，还增强了电力系统对可再生能源波动的适应能力。在未来，随着深度学习技术的进一步发展和计算能力的提升，结合更多维度的数据和更先进的模型结构优化，LSTM 有望在光伏与风电功率预测中发挥更大的作用，为实现能源结构的绿色转型和可持续发展贡献力量。因此，持续探索和优化 LSTM 在能源预测领域的应用，将是未来研究和实践的重要方向。

参考文献

- [1] 孙玮澳, 王文超, 张震, 等. 基于主成分分析和长短期记忆神经网络的光伏功率区间预测[J]. 吉林电力, 2024, 52(01): 1-5.
- [2] 张秘源, 蔡希彪, 王新凯, 等. 基于长短期记忆网络-模糊控制的光伏最大功率点跟踪算法[J]. 电子器件, 2024, 47(01): 201-208.
- [3] 崔明勇, 董文韬, 卢志刚. 基于密度聚类模态分解的卷积神经网络和长短期记忆网络短期风电功率预测[J]/OL. 现代电力, 1-11[2024-06-11].
- [4] 薛阳, 燕宇铖, 贾巍, 等. 基于改进灰狼算法优化长短期记忆神经网络的光伏功率预测[J]. 太阳能学报, 2023, 44(07): 207-213.