

基于LSTM-ELM模型的风电机组超短期功率预测研究

王元强¹, 李家锋¹, 李秋鹏¹, 梁俊坚¹, 董家华¹, 苏长南¹, 汪步斌^{2*}

¹广东省风力发电有限公司, 广东 广州

²东南大学能源与环境学院, 江苏 南京

收稿日期: 2024年11月1日; 录用日期: 2024年12月3日; 发布日期: 2024年12月11日

摘要

风速的不稳定性和不规律性使得风电机组的发电量呈现较大的波动性, 从而可能对电网造成扰动, 增加电网的调度难度。针对这些不利影响, 提出了一种基于长短期记忆网络(LSTM)和极限学习机(ELM)的风电机组超短期功率预测模型。通过提前预测机组功率输出, 缓解风电并网所带来的波动性问题。首先利用风电机组风速历史序列数据建立LSTM模型预测下一个调度周期(15 min)的风速; 然后利用叶轮、主轴、齿轮箱、发电机等设备测点历史数据和预测风速建立超短期功率预测ELM模型。结合国内某风电场实例数据分析, 预测结果和误差分析表明所提方法在超短期功率预测上的有效性, 对于提高电网稳定性和可靠性具有重要意义。

关键词

长短期记忆网络, 极限学习机, 风电机组, 超短期, 功率预测

Research on Ultra Short Term Power Prediction of Wind Turbine Based on LSTM-ELM Model

Yuanqiang Wang¹, Jiafeng Li¹, Qiupeng Li¹, Junjian Liang¹, Jiahua Dong¹, Changnan Su¹,
Bubin Wang^{2*}

¹Guangdong Province Wind Power Generation Co., Ltd., Guangzhou Guangdong

²School of Energy and Environment, Southeast University, Nanjing Jiangsu

Received: Nov. 1st, 2024; accepted: Dec. 3rd, 2024; published: Dec. 11th, 2024

*通讯作者。

文章引用: 王元强, 李家锋, 李秋鹏, 梁俊坚, 董家华, 苏长南, 汪步斌. 基于 LSTM-ELM 模型的风电机组超短期功率预测研究[J]. 应用物理, 2024, 14(12): 765-771. DOI: 10.12677/app.2024.1412082

Abstract

The instability and irregularity of wind speed make the power generation of wind turbines show large volatility, which may cause disturbances to the power grid and increase the difficulty of grid scheduling. Aiming at these unfavorable effects, an ultra-short-term power prediction model for wind turbines based on long-short-term memory network (LSTM) and extreme learning machine (ELM) is proposed. By predicting the power output of the turbine in advance, the volatility problem caused by the grid integration of wind power is mitigated. Firstly, the LSTM model is established to predict the wind speed in the next dispatch cycle (15 min) by using the historical sequence data of wind speed of wind turbine; then the ELM model is established to predict the ultra-short-term power by using the historical data of measurement points of impeller, main shaft, gear box, generator and other equipment, as well as the predicted wind speed. Combined with the data analysis of a wind farm in China, the prediction results and error analysis show the effectiveness of the proposed method in ultra-short-term power prediction, which is of great significance for improving the stability and reliability of the power grid.

Keywords

LSTM, ELM, Wind Turbine, Ultra Short Term, Power Prediction

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

全球的气候变化和环境污染问题正日益加剧，世界各国和地区纷纷着手大力推动清洁能源的发展。海上风电作为一种可再生、无污染的能源，成为了能源转型的重要方向之一[1]。海上风能资源丰富，风电场开发规模通常比陆上更大，这有利于提高清洁能源的自给率[2]。我国海上风电靠近东部负荷中心，能够减轻西电东送通道建设压力，输电距离小，输电成本低，就地消纳方便。然而由于风能具有波动性，风电场并网功率的波动会对电网带来不利影响，如威胁电网的功率平衡和运行安全[3]。因此，为了保证电网的稳定、经济、可靠运行，针对风电机组有功功率开展超短期预测与分析，准确描述调度周期内机组出力情况显得尤为重要。

为了应对上述问题，众多学者在风电功率预测方面开展了大量研究工作。根据研究所用数据的来源，大致可分为基于风电场区域数值气象预报的预测和基于风电机组海量历史运行数据的预测。功率预测方法主要有物理模型方法、统计学方法、机器学习方法以及组合预测方法[4]。物理模型方法通过机理方程对风电场区域地理信息和机组信息进行建模，结合数值天气预报系统的气象数据，综合得到轮毂高度的风速和风向，代入功率曲线插值得到预测功率。该方法无需大量的历史观测数据，更适用于中长期和短期功率预测[5]。常见统计学方法主要有时间序列法、回归分析法和卡尔曼滤波法等，其通过建立机组历史运行记录数据和风电功率之间的映射关系，捕捉数据间的时空信息，构建预测方法的函数形式。机器学习方法则通过对海量历史运行数据的学习获得数据之间的非线性模型，进而根据实时数据预测功率。近年来，随着大数据和机器学习技术的飞速进步，以机器学习为基础的风电功率预测研究已经成为备受关注的热门领域[6]。师洪涛等[7]利用数值天气预报数据，构建了反向传播神经网络模型用于风电功率预

测，并在某个特定风电场的数据上分析了影响预测准确度的因素。叶林等[8]针对风速序列的非平稳性特征，提出了一种基于经验模态分解和支持向量机的短期风电功率组合预测方法。周松林等[9]则提出了主成分分析与前馈神经网络相结合的风电功率预测模型，通过预处理实现原始多维输入变量降维，简化了网络结构，提高了模型的收敛性和稳定性。杨锡运等[10]针对短期风电功率概率区间预测的问题，利用粒子群算法对核极限学习机模型进行了优化。朱抗等[11]基于极限学习机(extreme learning machine, ELM)实现了短期风速的预测。朱乔木等[12]提出一种基于长短期记忆(long short-term memory, LSTM)网络的多变量风电场超短期发电功率预测方法，利用多数据源中的有效信息，在时间序列预测方面表现出良好的性能。然而上述研究在建立功率预测模型时，未充分考虑风电机组运行状态参数和风速的综合影响。

针对上述情况，本文提出一种基于 LSTM-ELM 的风电机组超短期功率预测模型。首先利用风电机组数据采集与监视控制系统(supervisory control and data acquisition, SCADA)的历史风速序列数据构建风速预测 LSTM 模型，然后利用叶轮、主轴、齿轮箱、发电机等设备测点历史数据和预测风速构建基于 ELM 的超短期功率预测模型。通过国内某风电场的实测数据进一步分析，多指标验证所提方法。

2. 风电机组超短期功率预测模型

2.1. 长短期记忆网络

LSTM 作为一种适用于序列数据预测的深度学习模型，可以有效地捕捉序列数据中的长期依赖关系。对于风速数据这种具有时序性的数据，LSTM 模型能够高效地学习其特征和变化规律，同时避免传统循环神经网络所存在的梯度消失和梯度爆炸问题，从而实现对未来风速的预测。LSTM 网络单个神经元结构如图 1 所示，通过遗忘门 f_t 、输入门 i_t 、记忆单元 C_t 和输出门 o_t 增强神经网络的预测能力。 h_{t-1} 、 h_t 分别为 $t-1$ 时刻和 t 时刻隐藏层向量， C_{t-1} 、 C_t 分别为 $t-1$ 时刻和 t 时刻的元胞状态， x_t 为 t 时刻的输入， x 为值域为 $[0,1]$ 的 Sigmoid 激活函数， \tanh 为值域为 $[-1,1]$ 的双曲正切激活函数。

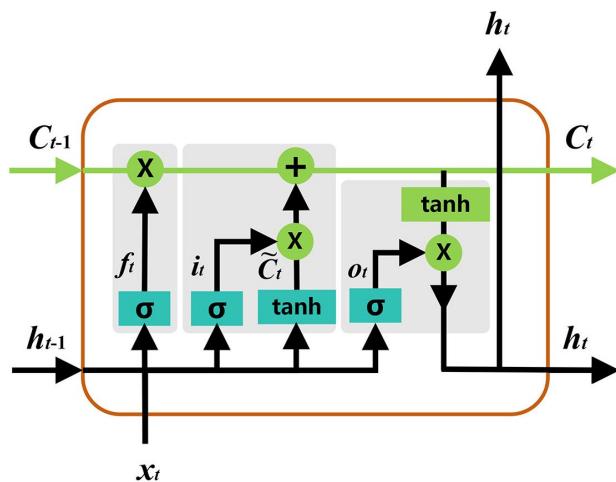


Figure 1. LSTM neural network
图 1. LSTM 神经网络

2.2. 极限学习机

ELM 是一种单隐层前馈神经网络，具有快速训练和良好泛化能力的特点，适合于处理较大规模的 SCADA 数据集和实时性要求较高的任务。其主要思想是将神经网络的训练过程简化为一个单次的随机

初始化权重和偏置的问题，而不需要迭代优化。这些权重和偏置是从一个随机分布中抽取的，如均匀分布或高斯分布。在随机初始化隐藏层后，ELM 将数据输入隐藏层，然后通过一个线性输出层来计算输出。这一步骤涉及到将输入数据与随机初始化的隐藏层权重相乘，然后通过一个激活函数来得到隐藏层的激活值。最后，通过线性组合这些隐藏层的激活值，得到输出。ELM 通过解线性方程组来输出权重，不需要迭代优化算法，从而实现了高效的训练。ELM 在初始化阶段随机选择输入层权重和隐藏层偏置后，根据穆尔-彭罗斯广义逆矩阵，通过最小化均方误差(MSE)损失函数来优化模型参数，对输出层权重进行解析计算。通过将新的输入数据输入到已经训练好的模型中，可以进行目标参数的预测计算。ELM 网络结构如图 2 所示，给定 N 个任意不同的训练样本 $\{(\mathbf{x}_i, \mathbf{t}_i)\}_i^N$ ，其中 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 、 $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$ 分别为输入向量和输出向量。标准 ELM 包含 n 个输入神经元、 L 个隐藏神经元和 m 个输出神经元，激活函数表示为 $g(x)$ 。

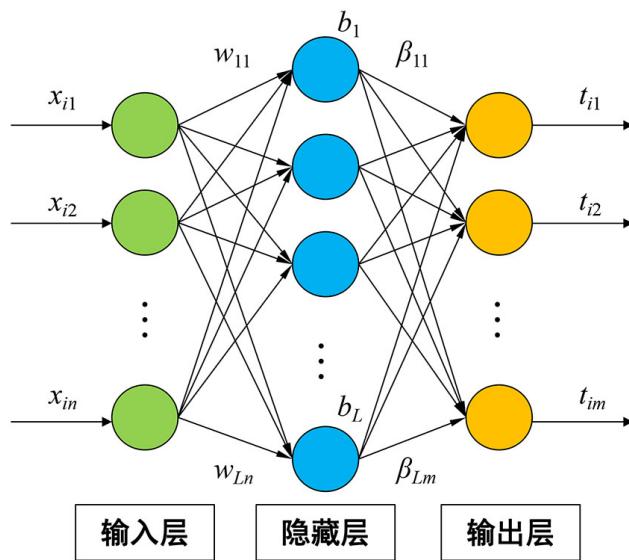


Figure 2. ELM neural network
图 2. ELM 神经网络

2.3. 风电机组超短期功率预测模型

基于 LSTM-ELM 的风电机组超短期功率预测模型流程如图 3 所示。首先对 SCADA 系统中历史风速序列数据进行异常值清洗和缺失值处理，进而利用 LSTM 神经网络建立风速预测模型。然后从 SCADA 中筛选出环境温度、叶轮转速、齿轮箱油温等作为表征风电机组运行状态的参数变量，结合参数历史数据和预测风速建立超短期功率预测 ELM 模型。ELM 作为单隐藏层的前馈神经网络，目的是解决反向传播算法学习效率低、参数设定繁琐等问题。在实时预测时，则以当前时刻的运行状态参数和预测风速作为输入变量，输出下一时间点的功率预测值。



Figure 3. Predictive modeling overall process
图 3. 预测模型整体流程

考虑到风电机组的额定功率, 使用归一化均方根误差(normalized root mean squared error, NRMSE)和归一化平均绝对误差(normalized mean absolute error, NMAE)指标来衡量预测效果, 表达式如下所示, 其中 y_i 为实际功率, \hat{y}_i 为预测功率, Y 为风电机组额定功率, n 为预测样本个数。

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

$$\text{NMAE} = \frac{1}{nY} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

3. 算例分析

3.1. 数据来源

为验证所提模型的预测效果, 选用中国广东省某风电场的 SCADA 历史数据进行算例分析。该风电场选用机组的额定功率为 6450 kW, 其切入风速为 3 m/s, 切出风速为 25 m/s, 额定风速为 10.5 m/s。该风电机组 SCADA 数据记录于 2023 年 3 月 17 日至 5 月 31 日, 采样间隔为 15 min, 记录数据为采样间隔内的平均值。算例分析目标为实现机组超前一个电网调度周期(15 min)的超短期功率预测。

3.2. 风速预测模型

从 SCADA 数据中提取出风速历史信息, 并对其进行缺失值填充、异常值处理等数据预处理。设定当前风速为目标值, 以前 m 个风速为特征值, 构建一个风速预测数据集。以 60%、20% 和 20% 的比例划分训练集、验证集和测试集。采用均方根误差(root mean squared error, RMSE)和平均绝对误差(mean absolute error, MAE)来评价风速预测模型的性能。当设置特征输入序列长度 m 为 8 时, 预测效果如图 4 所示, RMSE 和 MAE 分别为 0.6067 m/s 和 0.4683 m/s。尽管风速是影响风电机组功率输出的重要因素之一, 但功率输出还受到多种其他因素的影响, 如机组状态参数。因此下一步将风速预测结果作为功率预测模型的特征值之一, 结合其它相关测点数据建模实现功率预测。

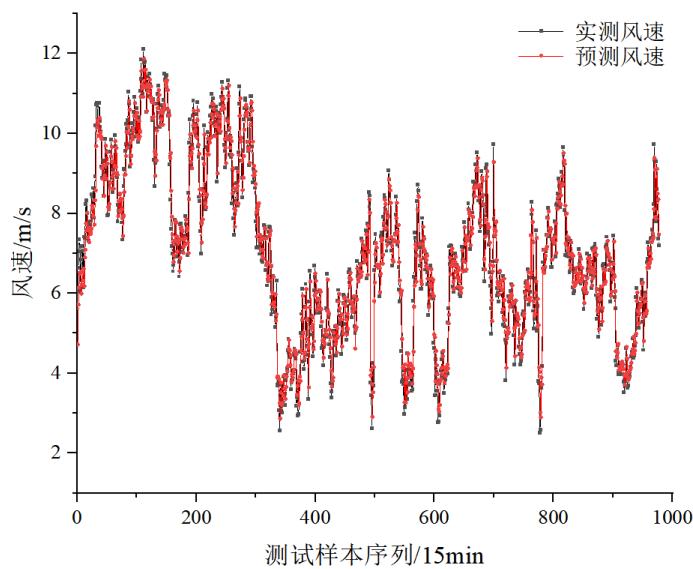


Figure 4. Wind speed prediction results

图 4. 风速预测结果

3.3. 功率预测模型与预测结果

在完成 LSTM 风速预测模型之后，开展 ELM 模型训练。以 SCADA 历史数据中 t 时刻的环境温度、叶轮转速、齿轮箱油温等状态参数和 $t+1$ 时刻(时间间隔为 15 min)的预测风速共同组成特征值，以 $t+1$ 时刻的有功功率为目标值，建立超短期功率预测 ELM 模型，实现对下一调度周期的功率预测。LSTM-ELM 模型在测试集上的功率预测结果如图 5 所示，预测功率与真实值之间存在良好拟合，且二者呈现一致趋势。

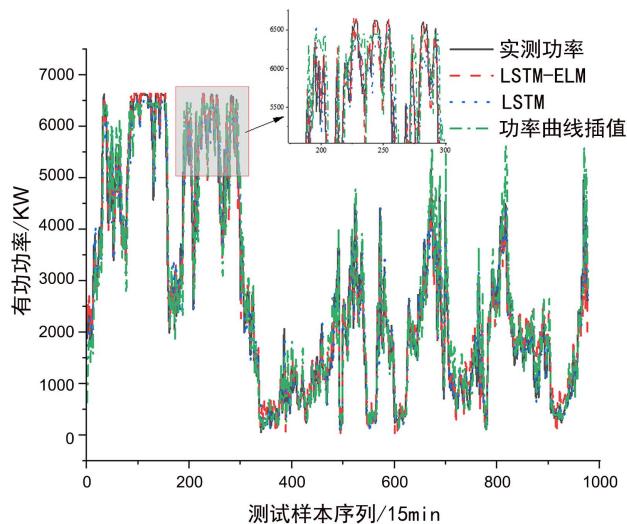


Figure 5. Power prediction results

图 5. 功率预测结果

同时与仅使用功率数据建立的 LSTM 预测模型和预测风速 - 功率曲线插值方法比较，其中功率曲线取机组出厂参数。不同模型预测效果如表 1 所示，LSTM-ELM 在两个指标上均更优。LSTM 功率预测模型表现较差的原因主要是没有考虑风速信息和机组运行状态参数。出厂功率曲线根据机组设计特性和额定工况制定，插值预测效果差的原因是其并没有考虑到实际运行中机组的动态响应和特性。

Table 1. Predictive effectiveness of different models
表 1. 不同模型的预测效果

模型	NRMSE/%	NMAE/%
LSTM-ELM	4.95	3.65
LSTM	6.52	4.65
风速 - 功率插值	8.50	5.96

4. 结论

本文针对风电机组的超短期功率预测问题展开研究，提出了一种 LSTM-ELM 预测模型。该模型首先利用 LSTM 对风速历史序列数据进行学习，预测下一个调度周期的风速。随后，结合风电机组的运行状态参数，通过 ELM 模型开展超短期功率预测。通过对实测 SCADA 数据的分析，验证了所提模型的有效性和优越性。对比分析结果显示，LSTM-ELM 模型在 NRMSE 和 NMAE 两个指标上均优于仅使用功率数据的 LSTM 模型和基于出厂功率曲线的插值方法。这表明，考虑风速信息和机组运行状态参数对于提

高超短期功率预测的精度至关重要。其中 LSTM 能够有效捕捉风速序列的时序特性, 而 ELM 则能够快速准确地学习并预测风电机组的功率输出, 两者的结合为风电功率预测提供了一种新思路。该模型有助于优化电力调度和规划, 缓解风电并网过程中产生的波动性问题, 进而提高电网的稳定性和可靠性。同时, 对风电场的智能化管理和优化运行也有着积极的推动作用。未来的研究可探索更多的影响因素, 如天气条件、机组维护状态等, 以进一步提升预测模型性能。

基金项目

2022 年广东能源集团科技创新“揭榜挂帅”项目“海上风电运维关键技术研究与应用(机组可靠性研究)”。

参考文献

- [1] 涂云川, 魏子栋. “双碳”愿景下的能源技术变革[J]. 科技导报, 2023, 41(19): 142-148.
- [2] 李德军, 周剑, 钟孝泰, 等. 海上风电场升压站变压器和 GIS 的设计、应用和展望[J]. 高压电器, 2021, 57(1): 1-11.
- [3] 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.
- [4] 王丽婕, 廖晓钟, 高阳, 等. 风电场发电功率的建模和预测研究综述[J]. 电力系统保护与控制, 2009, 37(13): 118-121.
- [5] 薛禹胜, 郁琛, 赵俊华, 等. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015, 39(6): 141-151.
- [6] 彭小圣, 熊磊, 文劲宇, 等. 风电集群短期及超短期功率预测精度改进方法综述[J]. 中国电机工程学报, 2016, 36(23): 6315-6326, 6596.
- [7] 师洪涛, 杨静玲, 丁茂生, 等. 基于小波-BP 神经网络的短期风电功率预测方法[J]. 电力系统自动化, 2011, 35(16): 44-48.
- [8] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.
- [9] 周松林, 范美琴, 苏建徽. 基于主成分分析与人工神经网络的风电功率预测[J]. 电网技术, 2011, 35(9): 128-132.
- [10] 杨锡运, 关文渊, 刘玉奇, 等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报, 2015, 35(S1): 146-153.
- [11] 朱抗, 杨洪明, 孟科. 基于极限学习机的短期风力发电预测[J]. 电力科学与技术学报, 2019, 34(2): 106-111.
- [12] 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.