

基于二次分解和深度学习的短期风电功率预测

刘 闯 高锦锦 郭泽航

华北水利水电大学 河南郑州 450045

摘 要: 针对风电功率预测中的随机性和波动性, 本文提出一种基于二次模态分解、样本熵及深度学习的超短期风电功率预测方法。首先, 通过模态分解技术对风电功率时间序列进行二次分解, 以克服一次模态分解导致的高频非平稳分量问题。其次, 应用样本熵重构三个具有典型特征的子分量, 并结合卷积神经网络优化的双向长短期记忆神经网络(CNN-BiLSTM)进行预测。通过与传统预测模型的对比分析, 结果显示所提出模型在预测精度上显著优于其他模型, 能够有效捕捉风电功率变化趋势, 并显著减少数据随机性和波动性对预测结果的影响, 表明该方法在实现国家“双碳”目标中的潜在应用价值。

关键词: 风电功率预测; 模态分解; CNN-BiLSTM

引言

2020年9月22日, 国家主席习近平在第七十五届联合国大会上宣布, 中国力争2030年前二氧化碳排放达到峰值, 努力争取2060年前实现碳中和目标^[1]。以风电和光伏发电等新能源为主体的新型电力系统, 是实现国家“双碳”目标的主要支撑^[2]。在新型电力系统中, 供电主体由煤电向风电和光伏发电等新能源转变。随着风光电源的大规模建设和并网运行, 风光功率的随机性、波动性和间歇性等不确定性因素给电网的安全稳定运行带来了严峻挑战^[3]。因此, 风电功率的准确预测, 对合理安排系统备用、保证电网稳定运行和提高经济效益具有重要意义^[4]。由于并网时需要保持电网稳定, 提前几小时对风电进行更准确的预测很重要, 而超短期预测需要更精准的结果, 时间范围更短, 同时难度更大, 因此本研究重点在于超短期风电功率预测的准确性^[5]。

近年来, 长短期记忆(Long-Short-Term Memory, LSTM)等深度学习方法因其在处理复杂非线性数据方面的优越预测能力以及在时间序列数据中有效捕获信息的能力, 在风电预测领域的应用也越来越受欢迎^[6]。Gu^[7]等人提出了一种基于改进的LSTM模型的短期风电功率预测方法。通过计算结果表明, 在不同时间尺度和季节下, LSTM模型的预测精度均高于反向传播(BP)

神经网络、粒子群优化和反向传播神经网络(PSO-BP)混合模型和小波神经网络(WNN)等模型。

由于风能的间歇性, 风电数据具有较高的随机性和波动性^[8]。由于其随机性和高波动性的特点, 仅用一种预测方法难以获得精确的风电预测结果。因此, 一些研究者提出了将人工智能方法与数据预处理策略相结合的混合方法。基于分解的方法是应用最广泛的数据预处理方法之一, 并取得了良好的预测效果^[9]。在基于分解的混合方法中, 将使用分解技术将原始风数据分解为几个相对平稳的子序列。然后对每个子序列建立预测模型, 并将预测结果相加, 得到最终的预测结果。将其分解为多个相对平稳的子序列, 并对每个子序列进行单独预报, 可以有效地提高风的预报精度^[10]。

基于上述分析, 本文提出一种基于二次模态分解、样本熵、深度学习的超短期风电功率预测方法。首先, 针对风电功率时间序列的随机性和一次模态分解产生的高频强非平稳分量的问题, 采用合适的模态分解方法对风电功率时间序列进行二次分解; 然后, 利用样本熵将子分量重构为具有典型特征的3个分量, 再利用卷积神经网络优化的双向长短期记忆神经网络进行超短期预测。与多个经典模型相比, 本文所提模型均有更高的预测精度。

一、二次分解

ICEEMDAN是一种改进自适应噪声完备集合经验模态分解方法, 与完备集合经验模态分解(CEEMDAN)方法的原理不同, ICEEMDAN是利用白噪声被经验模态分

作者简介: 刘闯(1999-), 男, 汉族, 河南周口人, 研究生, 作者单位: 华北水利水电大学, 研究方向: 新能源功率预测及其不确定性耦合机制。

解方法分解后的模态分量 (IMF) 来解决残留噪声和伪模态的问题, 该方法在解决模态混叠问题的同时使 IMF 中残余噪声大大降低, 对风电功率时间序列中所包含的不同尺度成分具有良好的分解和特征提取能力。

ICEEMDAN 产生的 IMF1 为高频强非平稳分量, 直接对其进行预测会产生较大误差, 因此对分解出的高频强非平稳分量 IMF1 使用 VMD 再次进行分解。经验小波变换 (Empirical Wavelet Transform, EWT) 是一种基于信号频谱构造经验尺度函数和小波函数的自适应信号处理技术。EWT 的基本思想是计算傅里叶段, 然后构造一系列小波滤波器, 从给定的风电信号中提取不同的模态。使用 EWT 对高频强非平稳信号进行处理步骤如下。

二、基于卷积神经网络的双向长短期记忆网络

卷积神经网络 (Convolutional neural network, CNN) 通过局部连接、权值共享和池化操作等运算, 在深度挖掘输入数据空间特征的同时, 有效降低了深层神经网络参数数量和数据维数, 使得卷积神经网络的计算速度和数据分析能力得到有效提升。卷积神经网络的基本结构由输入层 (Input layer)、卷积层 (Convolutional layer)、池化层 (Pooling layer)、全连接层 (Fully connected layer, FC) 及输出层 (Output layer) 构成。

BiLSTM 模型由输入层、前向 LSTM、反向 LSTM 和输出层构成。前向 LSTM 和反向 LSTM 可分别得到输入序列的过去信息和未来信息。输出 Q_t 由前向 LSTM 在时间节点 t 的隐状态 s_t^f 和反向 LSTM 在时间节点 t 的隐状态 s_t^r 共同构成。

前向 LSTM 的隐状态 s_t^f 、反向 LSTM 的隐状态 s_t^r 和输出层的 Q_t 可分别由式 (1)、(2) 和式 (3) 进行计算。

$$s_t^f = \sigma(W_{xs^f}x_t + W_{s^f s^f}s_{t-1}^f + b_{s^f}) \quad (1)$$

$$s_t^r = \sigma(W_{xs^r}x_t + W_{s^r s^r}s_{t+1}^r + b_{s^r}) \quad (2)$$

$$Q_t = W_{s^f Q}s_t^f + W_{s^r Q}s_t^r + b^Q \quad (3)$$

其中, σ 表示激活函数; b 表示的偏置向量; W_{xs^f} 表示输入层的权值矩阵; $W_{s^f s^f}$ 表示前向 LSTM 中隐藏层的权值矩阵; $W_{s^r s^r}$ 表示反向 LSTM 中隐藏层的权值矩阵; $W_{s^f Q}$ 和 $W_{s^r Q}$ 输出层的权值矩阵。

三、风光功率预测模型的构建

本文利用 CNN 模型深度挖掘风电功率数据与 NWP 数据间的特征关联特性以及天气性特征, 然后利用 BiLSTM 模型深度挖掘输入数据序列的时间相关性, 从而实现风光功率数据和 NWP 数据时空分布特性的精准获

取, 有效提高 BiLSTM 模型的预测精度。混合 CNN 模型、BiLSTM 模型的优点构建了 CNN-BiLSTM 预测模型, 实现对短期风光功率的精准预测。

四、评价指标

本文以内蒙某额定装机容量为 150 MW 的风电场数据为例进行分析, 以验证所提方法的有效性和可行性。从风电场数据空间中选取 2021 年 4 月 1 日至 2021 年 12 月 31 日九个月的时间序列数据, 采样间隔为 15 min/点, 一天共有 96 个点, 共 26400 个采样点作为实验样本。在我们的工作中, 数据集以 8: 1: 1 的比例被分成训练集、测试集和验证集。

同时采用两个模型评估标准——均方根误差 (RMSE)、平均绝对百分比误差 (MAPE), 其中 MAPE 是基于均值的评价指标, 可描述风电数据预测值和真实值的偏差, 反应误差的总体水平; RMSE 是基于均方的评价指标, 通过对预测偏差进行评估。其数学公式如下所示:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - p'_i)^2}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{p'_i - p_i}{p_i} \right| \times 100\%$$

其中 P_i 是功率的真实值; P'_i 为预测值; \bar{P}_i 为平均值; n 表示数据量。

五、算例分析

(一) 风电功率时间序列的模态分解结果

原始风电功率经过 ICEEMDAN 分解得到的子分量如图 5-1 所示, 使用 EWT 对 IMF1 进行第 2 次分解, 分解结果见图 5-2 所示。通过样本熵对两次分解后的子分量进




图 5-1 ICEEMDAN 分解图




图5-2 EWT分解图




图6 模型预测值比较

行复杂性评估由样本熵结果可知，子分量8至15的样本熵接近，说明它们产生新模式的概率大小基本一致，可以重构作为一个分量进行预测，它们重构得到的分量可以大致反映原始功率的总体趋势，所以称该重构分量为趋势分量。同理将样本熵接近的子分量1-1至1-2、4至7重构为振荡分量，将其余样本熵接近的子分量重构为随机分量。

(二) 预测结果分析

为了证明本文提出的ICEEMDAN-EWT-CNN-BiLSTM预测模型的优越性，本节对ICEEMDAN-EWT-CNN-BiLSTM模型、CNN-BiLSTM模型、BiGRU模型、PSO-ELM模型、BiGRU模型和BiLSTM模型的预测结果进行对比分析。

表2 各模型在预测中的性能比较

Predicate Model	MAPE	RMSE
ICEEMDAN-EWT-CNN-BiLSTM	2.529	3.090
CNN-BiLSTM	3.490	4.104
PSO-ELM	4.813	5.385
BiLSTM	3.461	5.349
BiGRU	3.373	5.345

图6为各种预测模型的风电功率预测结果，其中黑色实线为风电场实际输出功率，蓝色实线为ICEEMDAN-EWT-CNN-BiLSTM模型预测值，黄色实线为CNN-BiLSTM模型预测值，绿色实线为BiGRU模型预测值，红色实线为PSO-ELM模型预测值，紫色实线为BiLSTM模型预测值。由图6和表2可知，本文所提出的

ICEEMDAN-EWT-CNN-BiLSTM预测模型与其余几种预测模型相比,能够更加准确描述风电功率的变化趋势,利用经验小波变换(EWT)和改进自适应噪声完备集合经验模态分解(ICEEMDAN)将数值天气预报数据和风电功率数据分解为具有时间信息的频率数据,可有效消除数据信息中随机性和波动性对预测精度的影响,提高模型的预测精度。

参考文献

[1] 中华人民共和国国务院新闻办公室. 新时代的中国能源发展.[2020-12-21].

[2] 龚莺飞, 鲁宗相, 乔颖, 等. 光伏功率预测技术[J]. 电力系统自动化, 2016, 40(04): 140-151. 张天任. 基于混合深度学习的短期风光功率预测及不确定性分析[D].[硕士学位论文]. 郑州: 华北水利水电大学, 2021.

[3] 慎慧强. 基于混合预测模型的风光短期功率预测及不确定性分析[D].[硕士学位论文]. 郑州: 华北水利水电大学, 2022.

[4] 曹景胜, 于洋, 王琦, 等. 基于优化VMD-CNN-BiLSTM的电机轴承智能故障诊断研究[J]. 现代电子技术, 2024, 47(12): 115-121. DOI: 10.16652/j.issn.1004-

373x.2024.12.020.

[5] 张德文, 张健, 曲利民, 等. 基于PSO-ELM的变压器油纸绝缘状态无损评估方法[J]. 电力工程技术, 2024, 43(03): 201-208.

[6] 茆美琴, 龚文剑, 张榴晨, 等. 基于EEMD-SVM方法的光伏电站短期出力预测[J]. 中国电机工程学报, 2013, 33(34): 17-24.

[7] Gu B, Zhang T, Meng H, etc. Short-term forecasting and uncertainty analysis of wind power based on long short-term memory, cloud model and non-parametric kernel density estimation[J]. 2021.

[8] 赵泽妮, 云斯宁, 贾凌云等. 基于统计模型的短期风能预测方法研究进展[J]. 太阳能学报, 2022, 43(11), 224-234.

[9] 李溪, 胡梦浩, 冯耀冬. 一种新型日前光伏功率概率区间预测方法研究[J]. 自动化应用, 2023, 64(03): 71-74+78.

[10] 朱琼锋, 李家腾, 乔骥, 等. 人工智能技术在新能源功率预测的应用及展望[J]. 中国电机工程学报, 2023, 43(08): 3027-3048. DOI: 10.13334/j.0258-8013.pcsee.213114.