

基于长短期记忆网络的风电功率超短期预测

刘吉雄¹, 许思为², 邹 瑞²

(1. 武汉电器科学研究所有限公司, 武汉 430050; 2. 湖北大学商学院, 武汉 430062)

摘要: 全球环境问题凸显, 风力发电作为污染小的可再生能源得到重视, 风力资源的波动性和间歇性给风电场输出功率预测带来困难, 影响电力系统的调度和运行。为提高风电场发电功率的预测精度, 充分考虑天气特征对风电功率输出的影响, 通过对风电场实测数据建模和预测, 对比分析了不同深度学习模型超短期预测的效果。结果显示, 基于一种长短期记忆神经网络的多变量时间预测的方法, 能够对风电功率进行有效的超短期预测, 较其他深度学习模型拥有更高的预测精度和稳定性。

关键词: 风电; 功率预测; 长短期记忆网络; 超短期

中图分类号: TP311.13 **文献标志码:** A **文章编号:** 1671-1807(2025)08-0039-06

风力能源相比于其他能源污染小, 属于是一种清洁能源, 得到大力的发展。通常发电站的发电功率有稳定的输出, 而风力发电的功率受天气、风速的影响不稳定变化, 存在波动性、随机性等特点, 这不利于风力发电的调控和调度, 成为风力发电一直以来面临的问题^[1-2]。

根据风力发电功率预测的实际应用场景, 通常将预测分为超短期预测、短期预测以及中长期预测。超短期预测通常是指 0~4 h 的发电量预测, 时间分辨率通常为 10 min, 要求精度比较高, 主要运用于电力系统的实时调整; 短期预测是指预测未来 0~72 h 的风电功率, 时间分辨率为 15 min, 短期功率预测国内主要用于拟定发电计划, 短期风电功率预测通常是采用预测模型来完成, 通常需要考虑风速、风向等气象条件。中长期预测通常是三天到数周的功率预测及月度、年度的电量预测, 中期预测主要用于对机组组合优化、常规电源开机计划制订、海上风电检修, 长期预测主要用于年、月电量平衡及制订燃料计划等。

风电功率预测的研究方法主要分为基于物理模型的研究和基于统计数据的研究, 物理模型基于风电场内部及其周围地形、风电场分布情况、风电机组特征参数等信息, 采用微气象学理论等方法来搭建对风电场风能资源分布特征描述的模型, 进而对风电场发电功率实现预测; 基于统计数据的研究

是从以往的风点数据中获得知识, 再将知识运用于之后的功率预测, 人工智能领域不断发展, 也逐渐运用到风电预测的领域, 由于其良好的预测能力, 逐渐成为主流的研究方法。

目前, 国内外学者对风机出力短期预测的研究主要集中在各种算法层面, 主要有单耗法^[3]、弹性系数法^[4]、趋势外推法^[5]、负荷密度法^[6]、神经网络^[7]及回归分析法^[8]等算法, 其中基于统计模型和机器学习的方法在风电功率预测领域的研究较多得到了迅速的发展。曹俊波等^[9]针对差分自回归移动平均模型进行风功率预测不具有普遍适用性问题, 提出一种确定不同出力特性的风电场风功率时间序列转化为平稳序列所需的最优差分次数的方法, 其改进模型具有更好的预测效果。赵征和汪向硕^[10]根据风功率不平稳的特性, 提出一种基于互补集合经验模态分解的差分自回归滑动平均组合多步预测模型, 具有较高的预测精度。张亚丽等^[11]针对风电预测中波动性和随机性造成的风电功率多步预测精确度不高的问题, 提出一种基于非平稳 Transformer 的超短期风电功率多步预测模型, 对不同预测步长下的风电功率进行预测时均具有较高的预测精度, 且预测结果更稳定。王耀健等^[12]提出一种基于在线高斯过程的短期风电概率预测方法, 结果具有较好的预测性能, 同时具有自适应性, 可以有效地应对模型参数时

收稿日期: 2024-07-05

作者简介: 刘吉雄(1971—), 男, 湖北荆州人, 研究方向为风机空气性能; 许思为(1999—), 男, 湖北天门人, 硕士研究生, 研究方向为数据挖掘、机器学习等; 邹瑞(1999—), 女, 陕西宝鸡人, 硕士研究生, 研究方向为数据挖掘、数据分析等。

变问题。何星月等^[13]提出一种基于 COOT (Coot optimization algorithm) 的变分模态分解、分层主成分分析与门控循环单元神经网络的组合预测模型,有效提高了超短期风电功率预测精度。崔民勇等^[14]提出基于密度聚类与自适应噪声完备集成经验模态分解和卷积神经网络与长短期记忆网络结合的短期风电功率预测方法,预测过程通过聚类、分解和特征选择,有效提高了短期风电功率预测的准确度。王令文等^[15]基于海上风电场现场实测运行数据与区域电网负荷特性,通过定性与定量的角度对海上风电功率波动性规律进行分析,结果表明风电功率具有昼高夜低的日内变化特征和秋高夏低、冬低夏高的季节特征。卢雪平等^[16]提出一种基于低温寒潮天气风电功率短期组合预测方法,通过与正常天气样本建立的常态化功率预测模型组合,最终实现低温风电出力的准确预测。殷林飞等^[17]提出的多尺度卷积-残差网络具有特征提取尺度全面和稳定性强的特点,能够实现对未来 24 h 的风力发电功率的准确预测。郑文杰等^[18]提出一种利用差分自回归移动平均时间序列、长短期记忆网络和径向基函数神经网络建立组合模型对某地区风机出力进行短期预测,结果表明对季节性强和不规则性强的风电数据有更好的预测精度。但是,在先前提出的模型中存在着一些不足,大数据技术的不断发展,研究的数据维度和数据量都有了巨大的提升,对模型识别和提取数据深层次的特征有了更高的要求。

本文将风速、气温、气压、湿度等不同特征作为模型的多变量输入,风电功率作为模型的输出,利用风电场数据训练拟合模型,对风电功率进行短期的预测。通过评价指标验证不同神经网络短期预报的精度,期望长短期记忆模型能够具有较高的精度和稳定性。


1 模型及评价指标

1.1 LSTM 模型

长短期记忆模型 (LSTM) 是循环神经网络 (RNN) 改进而得到。LSTM 的单元与 RNN 不同的是,每个单元的状态可以看作两个向量 h_t 和 c_t , h_t 为短期状态, c_t 为长期状态,每个单元的输入为 x_t 和输出为 y_t ,同时也输出 h_t 和 c_t , t 为时间步长, $t-1$ 到 t 时间步长单元状态的变化结构如图 1 所示。

$$c_t = f_t \otimes c_{t-1} + i_t \otimes g_t \quad (1)$$

f_t 为遗忘门,控制 c_{t-1} 多少进入当前时刻,当



x_t 为当前 t 时刻的输入, y_t 为当前时刻的输出; c 为 LSTM 的记忆元状态 (保存过去的信息), 向下一时刻传递信息, c_t 为当前时刻的记忆元状态

图 1 LSTM 单元结构

$f_t = 0$ 时全部遗忘, 当 $f_t = 1$ 时, 全部进入当前时刻。

$$f_t = \sigma(W_{x_f}^T x_t + W_{h_f}^T h_{t-1} + b_f) \quad (2)$$

i_t 为输入门, 控制多少输入信息以及多少上一时刻的输出进入当前时刻。

$$i_t = \sigma(W_{x_i}^T x_t + W_{h_i}^T h_{t-1} + b_i) \quad (3)$$

h_{t-1} 为上一时刻的输出, h_t 为当前 t 时刻的输出, h_{t+1} 下一时刻的输出 y_t 。

$$y_t = h_t = o_t \otimes \tanh c_t \quad (4)$$

o_t 为输出门, 控制 c_t 多少信息会被输出。

$$o_t = \sigma(W_{x_o}^T x_t + W_{h_o}^T h_{t-1} + b_o) \quad (5)$$

在每个时间步长中, 长期状态 c_{t-1} 经过遗忘门丢掉了一些记忆长期记忆, 又通过一个输入门添加一些记忆, 得到输出 c_t 。短期状态 h_{t-1} 和输入向量 x_t , 进入 4 个不同的全连接层, 在图 1 中可以看到 g_t 、 f_t 、 i_t 和 o_t 4 个输出, 其中 g_t 作用是分析 h_{t-1} 和 x_t , 将其中重要的部分通过输入门存储在长期状态中。

$$g_t = \tanh(W_{x_g}^T x_t + W_{h_g}^T h_{t-1} + b_g) \quad (6)$$

式中: W_{x_f} 、 W_{x_i} 、 W_{x_o} 、 W_{x_g} 是 4 层中每层与 x_t 连接的权重矩阵; W_{h_f} 、 W_{h_i} 、 W_{h_o} 、 W_{h_g} 是 4 层中每层与前一短期状态 h_{t-1} 连接的权重矩阵; b_f 、 b_i 、 b_o 、 b_g 是 4 层中每层的偏置, 特别的, b_f 初始为全是 1 的向量, 防止训练一开始就会全部忘记单元中的内容。

其余 3 个是门控制器, 使用逻辑激活函数进行输出, 范围是 $0 \sim 1$, 并被送到逐元素乘法运算。具体, f_t 输出到遗忘门, 控制长期状态中应当被删除的部分; i_t 输出到输入门, 控制 g_t 中需要添加到长期状态中的部分; o_t 输出到输出门, 控制在当前时间步长中读取哪些部分输出到 h_t 和 y_t 。

1.2 评价指标

采用均方误差(MSE)和平均绝对误差(MAE)作为模型预测精度的评价指标,其指标数值越小表明模型精度越高。各指标的计算公式如下:

$$E_{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (8)$$

式中: y_i 为样本的真实值; \hat{y}_i 为样本模型的预测值。

2 算例分析

利用 LSTM 模型进行风电功率预测的具体流程如图 2 所示。

2.1 数据集

数据集采用某风电场的运行数据,采样时间为 2019 年 1 月 1 日至 2020 年 12 月 31 日,采样间隔为 15 min,样本数量为 70 095。数据集特征包含风电场实际功率、地理信息及天气特征等,共 40 个特征。其中天气特征具体包含 10 m 高度处风速(m/s)、10 m 高度处风向(°)、30 m 高度处风速(m/s)、30 m 高度处风向(°)、50 m 高度处风速(m/s)、50 m 高度处风向(°)、70 m 高度处风速(m/s)、70 m 高度处风向(°)、风机轮毂高度处风速(m/s)、风机轮毂高度处风向(°)、气温(°C)气压(hPa)、相对湿度(%)等。

2.2 数据预处理

首先对样本探索性分析,了解数据的缺失情况以及数据的类型,进行特征选择,删除明显与风电功率预测无关的特征,如“起报时间”“场站名称”等以及相关性小于 0.05 的特征,特征相关性分析结果,如图 3 所示。

LSTM 模型采用反向传播算法训练模型参数,不同特征的量纲不同,不同特征的取值大小差异过

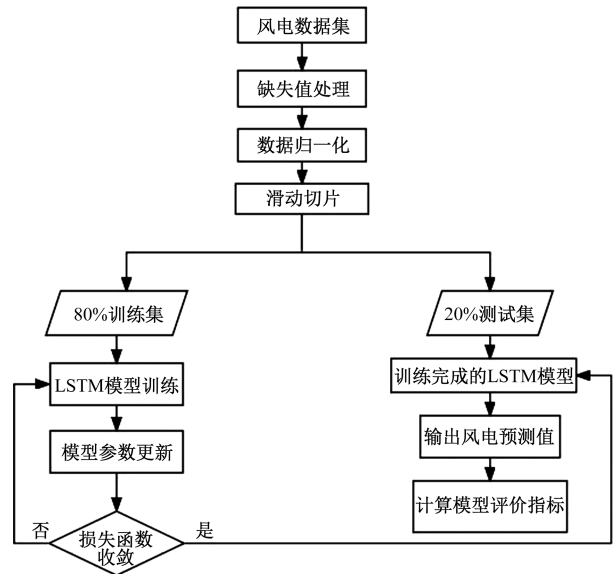


图 2 风电功率预测流程




图 3 特征相关性热力图

大,不利于模型的求解,需要对每个特征数据数值进行归一化处理。如风速气温、湿度等特征采用 Z-score 标准化,公式为

$$x^* = \frac{x - \mu}{\sigma} \quad (9)$$

式中: x 为原始数值; μ 为特征的均值; σ 为特征的方差; x^* 为 Z-score 标准化后的值。

数据集中风向特征,其单位是度,不适用于最大最小标准化,风向反映的是风在特定方向上的投影系数,按照其物理意义使用其正弦值作为归一化结果,公式为

$$x^* = \sin x \quad (10)$$

式中: x 为原始数值; x^* 为正弦标准化后的值。

最后按 LSTM 模型的输入要求,对数据集进行切片处理。采用数据滑动切片方法,将起始时间起点 t_i 逐次移动一个时间单位,提取需要的序列长度 $(n+m)$,每个建模切片包含特征和功率,只预测功率;具体为利用 $t_i \dots t_{i_n}$ (i 为切片编号, n 为建模序列长度)时段的风电运行数据去预测 $t_{i_{n+1}}, t_{i_{n+2}}, \dots, t_{i_{n+m}}$ (m 为预测序列长度)时段的风电功率。由于数据切片之间是相互独立的,考虑提高模型训练的效果,把数据切片打乱之后训练模型。

2.3 建模预测与结果分析

使用不同建模序列时间长度 d 的数据,包括 6 h、12 h、1 d 等,用于预测其后 k 个时间单位 (15 min) 的风电功率,即每个切片序列包含 $24 \times d + k$ 个时间步,其中预测 k 个值。数据切片后乱序处理,并按照 4:1 的比例划分为训练数据和测试数据。使用训练数据对 LSTM 模型进行训练,训练好的模型对测试数据中的风电功率进行预测,并与真实值进行比较,计算模型的性能。

使用 LSTM 网络的隐藏层维度为 4,层数为 1;模型学习率设为 0.001,dropout 为 0.5,训练批次设为 128,迭代次数为 50,并选择 Adam 优化器。

在风电功率预测中,单纯靠功率历史时间序列预测未来是不准确的,所以需要考虑在模型中加入相应的天气特征,如风速、风向等,然而在众多的天气特征中,引入无关的天气特征会对模型造成干扰,反而降低模型的预测性能。所以对模型的输入特征做了筛选,通过天气特征和输出功率的相关性分析,提取相关系数大于 0.05 的天气特征作为模型输入,筛选后的特征个数为 18。特征筛选前后模型的预测性能对比如表 1 所示,在进行特征筛选后,模型的各项评价指标较之前有较大的提升,MSE 减小

0.015,MAE 减小 0.035。结果表明筛选特征有助于提高模型性能,以下实验的结果均采用筛选后的特征集。

为了验证 LSTM 模型对风电功率预测的精度,基于相同的数据集和模型参数设置,与其他 4 种神经网络模型进行对比。4 种不同的模型分别是全连接神经网络、卷积神经网络(CNN)、循环神经网络(RNN)和 LSTM。将经过标准化和筛选特征后的数据分别输入模型,通过误差评价指标(MSE、MAE)综合评价预测结果。

首先,将 d 设置为 0.25、0.5、1、2、3,代表不同时间长度的训练数据,将 k 设置为 1,即预报 15 min,观察各模型预测的结果,如表 2 和表 3 所示,结果表明 LSTM 模型的预测精度要优于其他模型,以训练数据长度 6 h 为例,其中 MSE 为 0.192 5,MAE 为 0.263 3,在其他训练长度下,LSTM 模型的 MSE、MAE 均是最小。在单步预测中,LSTM 模型较全连接、CNN 模型有较大的优势,MSE 和 MAE 有明显的减小;和 RNN 相比,本文模型也有一定的优势。

表 1 数据集特征筛选前后预测误差对比

预测模型	MSE	MAE
原始特征集	0.213	0.298
筛选特征集	0.192	0.263

表 2 不同模型单步预测的 MSE 对比

预测模型	训练数据时间长度				
	6 h	12 h	24 h	48 h	72 h
全连接	0.255 8	0.338 2	0.284 3	0.476 9	0.461 2
CNN	0.210 2	0.227 5	0.237 0	0.254 2	0.257 9
RNN	0.203 3	0.219 5	0.206 0	0.226 4	0.214 1
LSTM	0.192 5	0.205 3	0.200 6	0.216 7	0.203 4

表 3 不同模型单步预测的 MSE 对比

预测模型	训练数据时间长度				
	6 h	12 h	24 h	48 h	72 h
全连接	0.342 2	0.451 8	0.386 8	0.483 1	0.467 5
CNN	0.279 3	0.303 9	0.319 2	0.315 2	0.336 1
RNN	0.270 2	0.291 2	0.273 6	0.279 4	0.278 4
LSTM	0.263 3	0.269 6	0.260 4	0.264 2	0.264 1

在单步预测的基础上,进一步增加预测步长将 k 设置为 4、8、12、16,观察模型预测 1 h(4 个时间步长)、2 h(8 个时间步长)、3 h(12 个时间步长)和 4 h(16 个时间步长)的预测精度,结果如表 4 和表 5 所示。在多步预测中可以发现,LSTM 模型预测结果要比其他模型更加稳定且精度更高,在多步预测

中,LSTM模型MSE和MAE评价明显比其他模型更低,说明在多步预测中LSTM模型预测更加稳定。而在不同训练时间长度下,LSTM模型没有表现出较大差异。总体来看,LSTM模型在不同的预测步长中表现是最优的,比其他模型的预测精度高。

表4 不同模型多步预测的MSE结果对比

预测步长	预测模型	训练数据长度				
		6 h	12 h	24 h	48 h	72 h
4	全连接	0.510 4	0.506 6	1.000 9	0.505 2	1.008 2
	CNN	0.284 7	0.284 2	0.291 7	0.310 6	0.325 2
	RNN	0.283 9	0.280 1	0.278 8	0.279 1	0.282 6
	LSTM	0.275 4	0.268 4	0.268 0	0.266 2	0.274 6
8	全连接	0.476 5	0.437 6	0.534 0	0.444 3	0.997 3
	CNN	0.353 9	0.373 5	0.346 2	0.385 4	0.385 1
	RNN	0.350 2	0.371 3	0.341 6	0.370 9	0.368 5
	LSTM	0.333 7	0.355 9	0.327 4	0.347 8	0.326 8
12	全连接	0.575 1	0.595 8	0.993 8	1.000 5	1.006 6
	CNN	0.394 4	0.420 4	0.417 3	0.431 9	0.451 2
	RNN	0.392 7	0.410 6	0.397 5	0.414 1	0.413 2
	LSTM	0.377 4	0.399 1	0.382 6	0.386 8	0.393 4
16	全连接	0.566 7	0.628 7	0.555 6	0.985 2	0.618 1
	CNN	0.447 4	0.455 5	0.439 2	0.473 2	0.514 7
	RNN	0.438 6	0.454 5	0.423 3	0.448 5	0.469 1
	LSTM	0.423 4	0.430 1	0.407 4	0.438 7	0.414 9

表5 不同模型多步预测的MAE结果对比

预测步长	预测模型	训练数据长度				
		6 h	12 h	24 h	48 h	72 h
1 h	全连接	0.529 6	0.519 5	0.816 5	0.522 6	0.817 3
	CNN	0.347 5	0.350 1	0.358 4	0.389 0	0.388 7
	RNN	0.342 5	0.339 2	0.341 6	0.340 5	0.344 3
	LSTM	0.343 0	0.334 0	0.332 7	0.339 7	0.336 2
2 h	全连接	0.506 0	0.514 6	0.546 5	0.525 4	0.815 9
	CNN	0.412 3	0.413 5	0.403 4	0.435 2	0.441 2
	RNN	0.405 1	0.396 0	0.400 9	0.405 2	0.415 9
	LSTM	0.394 1	0.400 0	0.394 8	0.401 6	0.387 0
3 h	全连接	0.582 0	0.579 4	0.813 0	0.818 8	0.818 9
	CNN	0.448 3	0.455 3	0.473 8	0.464 5	0.478 2
	RNN	0.443 5	0.449 6	0.440 1	0.456 9	0.445 7
	LSTM	0.439 8	0.441 3	0.436 5	0.440 1	0.434 0
4 h	全连接	0.576 0	0.620 8	0.569 6	0.812 4	0.603 6
	CNN	0.476 1	0.479 2	0.483 6	0.497 7	0.524 0
	RNN	0.475 0	0.483 0	0.462 0	0.476 1	0.485 7
	LSTM	0.464 1	0.469 4	0.462 3	0.471 6	0.461 9

综上所述,在单步预测和多步预测的结果分析发现,LSTM模型在预测精度和预测稳定性上都要优于其他模型。

3 结论

本文针对风电功率输出的波动性和随机性等问题,使用多种神经网络模型建模,并用模型进行

超短期预测,对比分析得到如下结论。

(1)对建模数据进行特征筛选后建模后预测的精度要优于原始数据直接建模所得的模型预测精度。

(2)在不同神经网络模型的对比中,LSTM通过对天气特征的筛选并加入模型的输入中,提升了风电功率预测的准确性,LSTM模型的超短期预测能力明显要优于其他模型。

(3)在超短期风电功率预测中,LSTM模型保持较高的预测精度和较强的稳定性。

参考文献

- [1] 温锦斌,王昕,李立学,等.基于频域分解的短期风电负荷预测[J].电工技术学报,2013,28(5):66-72.
- [2] 张海亮,王艺博,蔡国伟,等.面向风电消纳与电熔镁高载能负荷调控的源荷协调优化策略[J].电工技术学报,2022,37(17):4401-4410.
- [3] 靳春旭,董福贵.长期风电负荷预测方法比较[J].广东电力,2018,31(9):70-76.
- [4] 陈宋宋,王阳,周颖,等.基于客户用电数据的多时空维度负荷预测综述[J].电网与清洁能源,2023,39(12):28-40.
- [5] 王强钢,郭莹霏,莫复雪,等.计及变压器短期急救负载的城市高压配电网负荷优化分配[J].电力系统自动化,2023,47(19):106-115.
- [6] 唐玮,钟士元,舒娇,等.基于GRA-LSSVM的配电网空间负荷预测方法研究[J].电力系统保护与控制,2018,46(24):76-82.
- [7] TORRES J F, MARTÍNEZ-ÁLVAREZ F, TRONCOSO A. A deep LSTM network for the Spanish electricity consumption forecasting[J]. Neural Computing and Applications, 2022, 34(13): 10533-10545.
- [8] 周坤,许云飞,祁浩伟.基于改进ARIMA的新能源发电短期动态调度模型[J].电脑与信息技术,2024,32(1):56-61.
- [9] 曹俊波,周任军,邓学华,等.考虑优化ARIMA模型差分次数的风功率预测[J].电力系统及其自动化学报,2019,31(1):105-111.
- [10] 赵征,汪向硕.基于CEEMD和改进时间序列模型的超短期风功率多步预测[J].太阳能学报,2020,41(7):352-358.
- [11] 张亚丽,王聪,张宏立,等.基于非平稳Transformer的超短期风电功率多步预测[J].智慧电力,2024,52(1):108-115.
- [12] 王耀健,顾洁,温洪林,等.基于在线高斯过程回归的短期风电功率概率预测[J].电力系统自动化,2024,48(11):197-207.
- [13] 何星月,杨靖,朱兆强,等.基于COOT算法的VMD-HPCA-GRU超短期风电功率预测[J/OL].北京航空航天大学学报,1-13(2023-10-25).<https://doi.org/10.>

- 13700/j. bh. 1001-5965. 2023. 0255.
- [14] 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]. 现代电力, 2024, 41(4): 631-641.
- [15] 王令闻, 黄玲玲, 张智伟. 基于运行数据的海上风电场功率特性分析[J]. 现代电力, 2020, 37(5): 532-538.
- [16] 卢雪平, 董存, 王铮, 等. 低温寒潮天气下的风电短期功率预测技术研究[J]. 电网技术, 2024, 48(12): 4833-4843.
- [17] 殷林飞, 仝博文, 李雯吉. 基于多尺度卷积-残差网络的短期风电预测[J/OL]. 综合智慧能源, 1-10(2024-09-05). <https://link.cnki.net/urlid/41.1461.TK.20240904.1013.002>.
- [18] 郑文杰, 谭慧娟, 赵瑞锋, 等. 基于 ARIMA-LSTM-RBF 组合模型的风机出力短期预测[J]. 电力科学与技术学报, 2024, 39(4): 153-159.

Short-term Prediction of Wind Power Generation Based on LSTM

LIU Jixiong¹, XU Siwei², ZOU Rui²

(1. Wuhan Computer Peripheral Equipment Research Institute, Wuhan 430050, China;
2. School of Business, Hubei University, Wuhan 430062, China)

Abstract: As global environmental issues become more prominent, wind power, a low-pollution renewable energy source, has garnered attention. However, the variability and intermittency of wind resources pose challenges for predicting wind farm output, affecting power system scheduling and operation. To improve the accuracy of wind power forecasting, weather characteristics influencing power output must be fully considered. By modeling and predicting actual wind farm data, the effectiveness of different deep learning models for ultra-short-term forecasting was compared. The results show that a multivariate time prediction method based on a long short-term memory(LSTM) network effectively predicts wind power, achieving higher accuracy and stability than other deep learning models.

Keywords: wind power; power prediction; LSTM; ultra-short term