

基于数据驱动模式的波浪能装置短期发电功率预测方法

倪晨华

国家海洋技术中心,天津 300112

摘要 分析了随着波浪能发电技术的逐步成熟带来的功率预测技术现状,阐述了功率预测对规模化利用波浪能的现实需求,研究了不同模型的预测机理和特性,并在传统物理模型技术上提出了基于深度学习的数据驱动模型。基于长短时记忆网络的深度模型能够对波浪发电装置的短期功率开展预测,并通过与支持向量机、神经网络等模型比较,证明了长短时记忆网络模型预测方法能够获得更优的短期预测结果。

关键词 短期功率预测;波浪能发电装置;数据驱动模型;长短时记忆网络

近年来,以风电和光伏产业为代表的可再生能源装机规模不断扩大,可再生能源发电在电网中所占的比重也不断增加,根据相关研究预测,到2050年,全国风电装机容量将达14.4亿kW,太阳能发电装机容量将达21.6亿kW,新能源在发电装机占比将超过70%^[1]。电网中高比例的可再生能源对于减少碳排放、改善环境、延缓气候变暖具有重要积极意义,也对电网产生了新的挑战。第一,由于可再生能源利用小时数低,高比例的可再生能源电量需要数倍负荷的新能源装机容量,这将对系统的规划设计、生产管理、运行控制带来一系列的变革。第二,由于可再生能源的日内功率波动大,常规电源调节能力难以应对可再生能源功率的波动,可再生

能源的消纳面临巨大挑战。第三,可再生能源的间歇性和随机波动性导致出力周期不定,高出力长时间下将增大储能需求,低出力时需与其他电源共同实现功率平衡,这将给系统消纳、安全和储能技术带来巨大挑战。同时,可再生能源的尖峰出力功率大、电量小,为保证尖峰出力消纳需要调动巨大的灵活性资源。

为有效应对上述可再生能源占比增大带来的挑战,需要构建清晰的电网结构、创新安全稳定控制的思路 and 理论,加强源、网、荷、储特性的动态匹配和协同及预防性控制,实现高比例可再生能源电力系统的安全稳定控制。为解决调节能力不足的问题,需要通过对源、网、荷侧进行改造提升和协调

收稿日期:2020-10-12;修回日期:2020-12-21

基金项目:自然资源部海洋可再生能源资金资助项目(GHME2020ZC01)

作者简介:倪晨华,高级工程师,研究方向为海洋可再生能源开发利用,电子信箱:jeff_ni@126.com

引用格式:倪晨华. 基于数据驱动模式的波浪能装置短期发电功率预测方法[J]. 科技导报, 2021, 39(6): 59-65; doi: 10.3981/j.issn.1000-7857.2021.06.008

优化,增加系统内的灵活调节资源,发挥互联电网对可再生能源出力的尺度平滑作用,促进可再生能源发电的高效消纳。构建以电网为枢纽核心的综合能源系统,系统性应对和协调解决管理机制、技术需求、市场模式等多方面的挑战。可再生能源的功率预测技术是以电场环境数据、历史数据为基础,利用物理模型和科学统计等方法,直接或间接预测出电场短期甚至长期的发电功率输出,从而为电力消纳、调度、调峰等提供依据^[2]。

在外力作用下,海水质点在其平衡点位置附近作周期性运动,这就形成了波浪。海洋表面波浪所具有的动能和势能的总和称为波浪能^[3-4]。波浪能具有波动性、间歇性、高能流密度等特点,因此波浪能发电功率也是波动的、间歇的,当波浪能发电在电网中所占的比例非常小时,上述特点不会对电网造成明显的影响。但是,随着发电装机容量的迅速增加,其在电网中的比例也不断上升,一旦波浪发电的穿透功率超过极限比例,接入电网的机组将会对电力系统的安全、稳定运行及电能质量带来严峻挑战。因此,在制定发电计划和调度决定时必须充分考虑波浪功率的波动性和不确定性。通过波浪能功率预测技术,将未知的发电功率变为已知,从而合理安排应对措施,改善电网调峰能力,增加并网容量。

1 长短时记忆网络(LSTM)模型预测方法

目前,主要有两类方法来预测波浪发电功率:物理模型方法和数据驱动方法。物理模型理论于20世纪50年代后期创建,从20世纪60年代开始被应用^[5-6]。物理模型方法的原理是首先根据海域水深地形等情况进行局地建模,从而获得波浪发电场所在海域的波浪天气预报,然后将该区域的波浪预报换算到预测机组所在剖面位置的波浪能量密度,最后结合机组的功率曲线(或功率矩阵),获得发电机组的功率预测值。经过多年的应用,风浪模式已经较为成熟并实现业务化运行。如美国国家海洋和大气管理局(NOAA)的波浪预报系统基于

WAVEWATCH III模型,该模型具有约50 km分辨率的全球范围和北半球海盆约18 km和约7 km分辨率的区域范围^[7]。Reikard团队^[8]利用ECMWF模式获取的预报数据进行波浪能和风能的功率的预测。在区域应用中,德克萨斯农工大学^[9]使用SWAN模型来预测墨西哥湾的海浪,并证明了该模型可以显著提高该地区的波浪预报准确性。

统计模型有2种思路,早期常使用数据模型表达海浪预报参数(波高、波向)与发电功率间的函数关系,再根据未来的海浪预报值,进行波浪的功率预测。另一种是近些年发展起来的人工智能技术,认为波浪电场历史发电功率数据中已经暗含了各种天气因素的影响,因此使用数学模型对历史数据进行学习并外推,从而得到波浪功率的预测值。广泛使用的线性模型有自回归移动平均(ARMA)方法^[10]、Box-Jenkins方法^[11]、卡尔曼滤波器^[12]和马尔可夫链模型^[13]等。人工神经网络(ANN)和支持向量机(SVM)是用于可再生能源预测的两种最受欢迎的非线性方法。Peres等^[14]分析了意大利海15年以上的浮标数据,并用ANN进行波高的预测,将结果与WAVEWATCH III/CFSR和ERA-Interim进行了比较,显示结果优于后者。前期的研究表明,物理模型适用于较长时间尺度的预测,而数据驱动的模型在短期的预测表现更加精确^[15]。深度学习作为最近快速发展起来的统计模型方法,已经成为解决预测问题的最合适方法之一^[16]。Wang等^[17]提出了一种基于小波变换和卷积神经网络的集成方法,用于风电短期预测,其结果证明模型具有较好的稳定性和鲁棒性。Liu等^[18]提出了一种将离散小波变换和LSTM网络相结合的方法来进行风电短期预测,并利用来自中国的2个风电场和荷兰的1个风电场的真实数据作为输入,验证方法的预测精度。

1.1 LSTM模型

LSTM是一种特殊的循环神经网络(RNN),具有学习长期记忆的能力,它在RNN的基础上增加了“记忆”功能(被称为“cells”),这些Cells在神经元内部决定是否应该写入或删除对信息的记忆,并且可以将之前的状态、现在的记忆和当前输入的信息结合在一起,对长期历史信息进行记录。正是

由于它的这种特性,LSTM 在处理时间序列的预测问题上的应用越来越多,预测效果也获得了较大的提升^[19-21]。

如图 1(a)所示,在循环神经网络的单元 A_t ,它的输入值是 X_t ,输出值是 H_t 。信息通过回路从网络的当前状态传递到下一个状态。其中 A_t 隐层的输出有 2 个:一个作为输出值,另一个输出到下一时刻的神经元中。 A_t 根据上一个时刻 $t-1$ 的隐层状态 A_{t-1} 和当前时刻 t 的输入 X_t 计算得到。假设函数 f 为隐层状态的激活函数,当前隐层状态 A_t 的计算公式为

$$S_t = f(W_{A_t} U_{X_t}) \quad (1)$$

式中, S_t 为 A_t 的隐层状态, W 为隐层状态 A 的权重参数矩阵; U 为输入序列信息 X 的权重参数矩阵。

图 1(b)中,LSTM 单元通过自循环连接神经元,从而让记忆单元随着时间推移,序列信息的输出能够保持独立,不受输入和输出环境的影响。输入门是决定哪些新输入的信息允许被更新,或者被保存到记忆单元中;与输入门相对的是输出门,用于决定记忆单元中哪些信息允许被输出;遗忘门则用于控制记忆单元是否记住或者丢弃之前的状态。

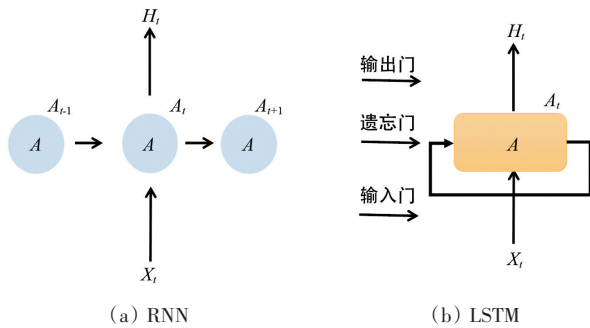


图 1 RNN 和 LSTM 的网络模型


图 2 详细介绍了 LSTM 记忆单元存储序列信息的过程。为了确定什么样的新信息可以被保存在记忆单元中(图 2(a)红色部分),需要计算输入门的激活值 i_t 和时间步 t 记忆单元的状态候选值 C'_t 。

$$i_t = \text{sigmoid}(W_i X_t + U_i H_{t-1} + b_i) \quad (2)$$


$$C'_t = \tanh(W_c X_t + U_c H_{t-1} + b_c) \quad (3)$$

式中, W_i 为在输入门输入控制时间步 t 的输入序列


数据的权重向量; U_i 为在输入门输入控制时间步 $t-1$ 输入状态值的权重向量; b_i 为输入门输入控制的偏置; W_c 为在输入门状态候选在时间步 t 的输入序列数据的权重向量; U_c 为在输入门状态候选时间步 $t-1$ 输入状态值的权重向量; b_c 为输入门状态候选的偏置。



(a) 输入门和状态后选址的计算过程的数据流



(b) 输出门和新状态值的计算过程的数据流



(c) 输出门和记忆单元输出值的计算过程的数据流

图 2 LSTM 记忆单元详细组织

在输入门中,得到了输入激活值 i_t 和记忆单元的状态候选值 C'_t ,如图 3(b)所示,需要计算输出门的激活值 f_t 和当前时间步 t 的新状态 C_t :

$$f_t = \text{sigmoid}(W_f X_t + U_f H_{t-1} + b_f) \quad (4)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot C'_t \quad (5)$$

式中,当前时间步的新状态值 C_t 为上一时间步的状态值 C_{t-1} 与遗忘门的激活值 f_t 相乘,作为决定丢弃旧状态中的信息量;输入门输出控制值 i_t 与候选状态值 C'_t 相乘,用于控制新状态的变化;最后把两者相加作为新的状态值。输出门的作用与输入门对称,如图 2(c) 中红色部分所示,需要计算时间步 t 记忆单元中输出门的输出激活值 O_t 和记忆单元的输出值 H_t

$$O_t = \text{sigmoid}(W_o X_t + U_o H_{t-1} + b_o) \quad (6)$$

$$H_t = O_t \odot \phi(C_t) \quad (7)$$

式中, H_t 为 A_t 的输出值,输出门的输出激活值与当前时间步 t 新状态值的 Tanh 函数相乘,最终得到输出状态 $H_t^{[22-25]}$ 。

1.2 模型结构

LSTM 模型的预测流程分为 4 个步骤,为了与实际应用需求结合,将预测策略分为 2 个时间段:超短期(4 h 以内)和短期(72 h 以内),分别评估 LSTM 模型在这两个预测周期中的效果。预测的时间步是根据预测周期长短分别取平均值。图 3 较好地描述了整个预测流程:(1) 收集整理历史波浪参数和历史发电数据;(2) 对数据进行预处理,包括去除奇异值、填充缺失测值等;(3) 将数据分成训练数据组、校对数据组和预测数据组;(4) 建立预测模型,将数据导入模型,调整优化模型参数,进行预测,并将结果与其他模型比较。

LSTM 模型的输入为时间序列,为减少数据的维度,将输入数据降维处理,在经过主成分分析后,输入参数包括有效波高(m)、有效波周期(s)和发电功率(W),最终模型参数如表 1 所示。

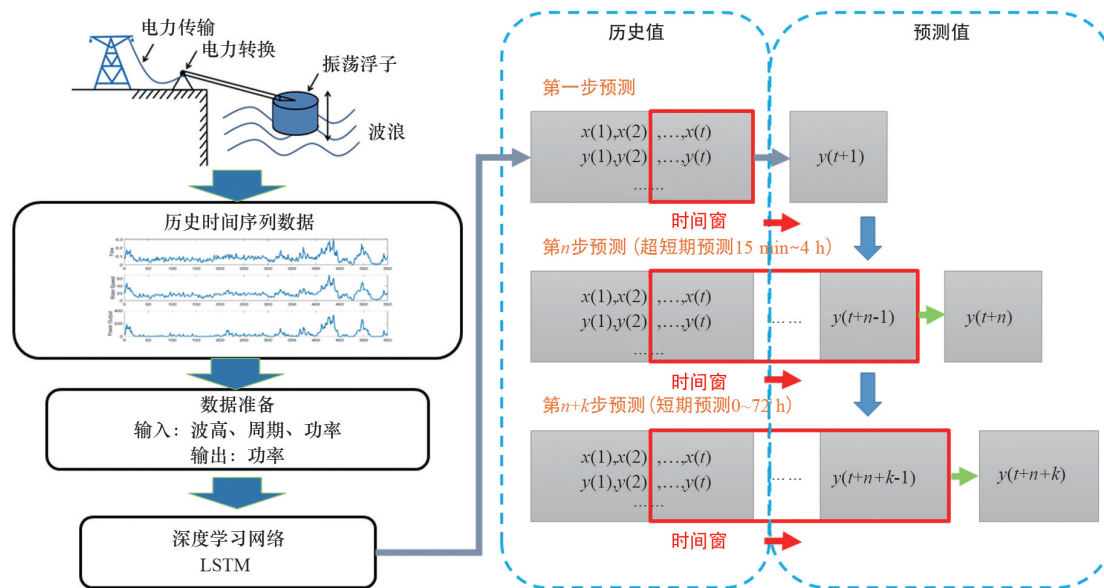


图 3 LSTM 预测模型结构示意图

表 1 采用的 LSTM 模型参数

参数	值
输入序列	3
隐藏 LSTM 单元	200
输出层	1
Batch Size	200
Epoch 数量	100

1.3 试验数据来源

为了使模型达到较好的效果,采用了 10 kW 的波浪发电装置样机的海试数据作为输入。该装置为振荡浮子式波浪能发电,通过浮子的上下运动俘获波浪能量。它包含了能量吸收装置、能量转换装置和能量传输装置 3 部分。

1.4 模型评价指标

为了客观地评价模型的效果,采用平均绝对百分比误差(mean absolute percentage error, MAPE)、均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE),计算公式分别如下:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{\varphi}_i - \varphi_i}{\hat{\varphi}_i} \right| \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\varphi}_i - \varphi_i)^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{\varphi}_i - \varphi_i| \quad (10)$$

2 模型结果

基于以上参数和模型结构,将发电装置的功率预测分为超短期(4 h以内)和短期(72 h以内),在此选择50时间步作为预测值和真实值的校验。如图4所示。对超短期预测时间步来说,每一步代表

15 min,总预测时长为5 h。显然超短期SVM的预测结果曲线能够大体反映出实测值的趋势,但偏离实测值较多,模型效果较差。基于NN的模型结果能够较好地跟随实测趋势,且偏差显著减小。图4(c)展示了LSTM在超短期预测的结果,可以看出,其预测结果与实际值的偏差较小,尤其在短期时的预测曲线基本与实测值吻合,说明LSTM在超短期的预测结果具有较高的精度。

从短期预测结果来看,图5展示了SVM和NN的短期预测结果。对于短期预测时间步来说,每一步代表3 h,总预测时长为60 h。同样SVM的预测结果较差,NN的预测结果相比较提升了很多。LSTM的短期预测结果见图5(c),显然短期预测的结果较超短期要差一些,这也与统计模型本身的特点相一致。可见,预测曲线基本能够与实测值的趋势保持一致,但在振幅较大区域的跟随性变差。表2的模型评价指标值也表明了一致的情况,超短期预测结果指标明显优于短期预测结果,而且LSTM的指标值也普遍优于NN模型。




图4 超短期功率预测结果




图5 短期功率预测结果

表2 模型的评价指标值

评价指标	SVM 模型		NN 模型		LSTM 模型	
	超短期	短期	超短期	短期	超短期	短期
MAPE/%	69.1922	>100	52.2785	73.0661	45.5339	58.7547
MAE	24.0299	12.6071	19.9902	16.4192	17.0937	12.4224
RMSE	48.2022	17.3575	30.2096	24.2756	23.08347	19.9789

3 结论

随着风能、太阳能和海洋能等可再生能源发展,发电装置的输出功率预测已成为一项至关重要的技术。回顾了基于物理模型和统计模型的两大类预测方法的发展和特性,并在统计模型基础上研究了基于 LSTM 深度学习模型的适用性,将这类方法应用于海洋波浪能发电装置的功率预测中。由于波浪的间歇性和可预测性,物理模型方法主要通过海浪预报获取波浪参数,再根据发电装置的功率矩阵从而得到装置在预期时间的输出功率。而统计模型则通过历史数据的训练分析,建立波浪参数与发电功率间的复杂关系,提取训练集的特征,从而预测未来一段时间内的功率输出。

运用 LSTM 模型对一种振荡浮子式波浪能发电装置的发电功率进行超短期和短期的预测,并将结果与 SVM 模型和 NN 模型进行对比。实验结果表明,如果选取合适的模型参数,采用统计方法的波浪功率预测能够获得较好的结果。在模型准确性方面,LSTM 模型在时间序列的波浪能发电装置功率预测中比其他模型具有更好的表现。此外,试验证实了基于统计方法的波浪能发电装置功率预测方法较宜开展短期和超短期预测,对于中长期预测,基于物理模型的方法一般能获得更高的精度。

参考文献(References)

[1] 郭剑波. 高比例新能源电力系统的挑战[C]//2020中国可再生能源学术大会. 昆明: 中国可再生能源学会, 2020: 8-10.
 [2] 王桓, 徐龙博. 风电功率预测技术与实例分析[M]. 北京: 中国水利水电出版社, 2016: 34-38.
 [3] 吴必军, 邓赞高, 游亚戈. 基于波浪能的蓄能稳压独立

发电系统仿真[J]. 电力系统自动化, 2007, 31(5): 50-56.
 [4] 刘延俊. 波浪能发电装置设计与制造[M]. 北京: 化学工业出版社, 2019: 66-69.
 [5] Phillips O M. On the generation of waves by a turbulent wind[J]. *Journal of Fluid Mechanics*, 1957, 2: 417-445.
 [6] Phillips O M. The equilibrium range in the spectrum of wind-generated waves[J]. *Journal of Fluid Mechanics*, 1958, 4: 426-434.
 [7] Tolman T L. User manual and system documentation of WAVEWATCH-III version 2.22[R/OL]. [2020-12-05]. <http://polar.ncep.noaa.gov/waves/wavewatch/manual.v4.18.pdf>.
 [8] Reikard G, Robertson B, Bidlot J R. Combining wave energy with wind and solar: Short-term forecasting[J]. *Renewable Energy*, 2015, 81: 442-456.
 [9] Surf's up: Professor using models to predict huge waves[R/OL]. [2005-2-23]. *ScienceDaily*, <https://www.sciencedaily.com/releases/2005/02/050222193810.htm>.
 [10] Liu H, Erdem E, Shi J. Comprehensive evaluation of ARMA-GARCH(-M) approaches for modeling the mean and volatility of wind speed[J]. *Applied Energy*, 2011, 88(3): 724-732.
 [11] Helga S, Claudiu C. Wind speed prediction using Box-Jenkins method[J]. *Journal of Computer Science & Control Systems*, 2008(1): 208-212.
 [12] Poncela M, Poncela P, Perán J R. Automatic tuning of Kalman filters by maximum likelihood methods for wind energy forecasting[J]. *Applied Energy*, 2013, 108(12): 349-362.
 [13] Song Z, Jiang Y, Zhang Z. Short-term wind speed forecasting with Markov-switching model[J]. *Applied Energy*, 2014, 130: 103-112.
 [14] Peres D J, Iuppa C, Cavallaro L, et al. Significant wave height record extension by neural networks and reanalysis wind data[J]. *Ocean Modelling*, 2015, 94: 128-140.
 [15] Reikard G, Pinson P, Bidlot J R. Forecasting ocean wave energy: The ECMWF wave model and time series methods[J]. *Ocean Engineering*, 2011, 38(10): 1089-

- 1099.
- [16] Kumar N K, Savitha R, Al Mamun A. Regional ocean wave height prediction using sequential learning neural networks[J]. *Ocean Engineering*, 2017, 129: 605–612.
- [17] Wang H Z, Li G Q, Wang G B, et al. Deep learning based ensemble approach for probabilistic wind power forecasting[J]. *Applied Energy*, 2017, 188: 56–70.
- [18] Liu Y, Guan L, Hou C, et al. Wind power short-term prediction based on LSTM and discrete wavelet transform[J]. *Applied Sciences*, 2019, 9(6): 1108.
- [19] 陈仲铭, 彭凌西. 深度学习原理与实践[M]. 北京: 人民邮电出版社, 2018: 268–270.
- [20] Sepp H, Jürgen S. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735–1780.
- [21] Yan X, Wang Y, Du N, et al. Multi-step short-term power consumption forecasting with a hybrid deep learning strategy[J]. *Energies*, 2018, 11: 3089.
- [22] ElSaid A, Wildy B, Higgins J, et al. Using LSTM recurrent neural networks to predict excess vibration events in aircraft engines[C]//IEEE 12th International Conference on e-Science. Piscataway NJ: IEEE, 2016: 260–269.
- [23] Zhao Z, Chen W, Wu X, et al. LSTM network: A deep learning approach for short-term traffic forecast[J]. *IET Intelligent Transport Systems*, 2017, 11(2): 68–75.
- [24] Kiperwasser E, Goldberg Y. Simple and accurate dependency parsing using bidirectional LSTM feature representations[J]. *Transactions of the Association for Computational Linguistics*, 2016, 4: 313–327.
- [25] 吴岸城. 神经网络与深度学习[M]. 北京: 电子工业出版社, 2016: 67–68.

Short term prediction of ocean wave energy power using long-short term memory network

NI Chenhua

National Ocean Technology Center, Tianjin 300112, China

Abstract The prediction technologies of the power generation from the wave energy converters (WEC) are an urgent and crucial problem in the renewable energy planning, the power grid dispatching and the economic operation. Besides the statistical modelling, this paper presents a novel hybrid DDM for very short term (15 min–4 h) and short term (0–72 h) predictions of the wave energy power, based on the long-short term memory (LSTM) network and the results are compared with those obtained by the Artificial neural networks (ANN) and the support vector machine. The experimental results indicate that the proposed deep learning models enjoy a better performance with a high accuracy in the WEC power prediction than other related models. Furthermore, the proposed DDM methods are shown to be robust and timesaving in training and deployment, with advantages over the statistical methods in very short term and short term WEC power predictions.

Keywords short-term prediction; wave energy converter; data-driven modelling; long-short term memory ●



(责任编辑 刘志远)