

文章编号: 1005-0523(2020)04-0109-07

DOI: 10.16749/j.cnki.jecjtu.2020.04.017

基于 CNN-LSTM 网络模型的风电功率短期预测研究

李艳^{1,2}, 彭春华¹, 傅裕², 孙惠娟¹

(1. 华东交通大学电气与自动化工程学院, 江西 南昌 330013; 2. 国网江西省电力有限公司赣州供电分公司, 江西 赣州 341000)

摘要: 风电功率预测对电力系统的稳定运行与经济调度至关重要。为充分挖掘历史数据中的有效信息以提高风电功率短期预测精度, 提出一种基于卷积神经网络(convolution neural network, CNN)和长短期记忆(long short-term memory network, LSTM)网络模型的风电功率短期预测方法, 利用 CNN 序列特征提取能力进行有效信息的提取, 保留更长的有效记忆信息以解决梯度弥散问题, 弥补了 LSTM 网络模型面对过长序列时出现不稳定与梯度消失现象的不足。用国内某风电场数据进行实验, 预测结果表明文中提出的方法与反向传播神经网络和 LSTM 网络预测方法相比, 具有更高的预测精度。

关键词: 风电功率预测; 卷积神经网络; 长短期记忆网络; 卷积神经网络-长短期记忆网络模型

中图分类号: TM614

文献标志码: A

本文引用格式: 李艳, 彭春华, 傅裕, 等. 基于 CNN-LSTM 网络模型的风电功率短期预测研究[J]. 华东交通大学学报, 2020, 37(4): 109-115.

Citation format: LI Y, PENG C H, FU Y, SUN H J. Short term wind power prediction based on CNN-LSTM network model[J]. Journal of East China Jiaotong University, 2020, 37(4): 109-115.

目前, 风电功率预测方面的研究方法一般可以分为物理模型、统计模型和人工智能三种^[1-12]。物理模型是通过物理因素及气象数据来预估风电功率, 其在短期预测中表现欠佳。统计方法是利用基于历史数据的数学模型进行风速、风功率预测, 典型统计模型是以风速数据是正态分布且为线性相关为前提的, 因不符合实际情况, 所以预测性能将不能得以保证。

为改进 LSTM 存在的不足, 提出一种基于 CNN-LSTM 网络模型的风电功率预测方法。借助 CNN 序列特征抽象能力以有效提取子序列特征, 去除干扰信息后输入数据至 LSTM, 保留更长的有效记忆信息以解决梯度弥散问题。与仅使用单一 LSTM 模型进行比较, CNN-LSTM 网络模型能提供大量的有效数据作为 LSTM 的输入数据, 从而提高预测精度。

1 风电功率预测影响因素

从物理本质上来说, 风电功率影响因素包含风速、风向及温度等^[13]。在现有的部分研究中, 只使用历史功率数据对未来值进行预测, 而不考虑其它相关环境影响因素, 此类模型的外推能力不足。因此, 为提升预测的精度, 在建立模型时需要考虑其它可能对风电出力造成影响的因素。

存在多个变量时, 找出影响预测发电功率较大的变量十分必要。采用 Spearman 方法进行相关性分析。式(1)为 2 个 n 维向量 x, y 的 Spearman 相关系数, 其中 x, y 表示进行相关性分析的两个变量。

$$\rho_s = \frac{\sum_{i=1}^N (R_i - \bar{R})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^N (R_i - \bar{R})^2} \sqrt{\sum_{i=1}^N (S_i - \bar{S})^2}} = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2 - 1)} \quad (1)$$

式中: R_i 和 S_i 分别是向量 x, y 进行排序后观测值 i 的秩次; \bar{R} 和 \bar{S} 分别是向量 x 和 y 的平均秩次; N 是 i 的总

收稿日期: 2020-02-24

基金项目: 江西省自然科学基金项目(20192ACBL20007); 江西省教育厅科技项目(GJJ1903013)

作者简介: 李艳(1994—), 女, 硕士研究生, 主要研究方向为电力系统及其自动化。

通信作者: 彭春华(1973—), 男, 教授, 博士, 主要研究方向为智能电网优化运行。

数量; $d_i = R_i - S_i$, 表示两个变量中 i 的秩次之差。Spearman 相关系数中 ρ_s 是 $[-1, 1]$ 中的实数。

本文实验获取数据包含我国某风电场 2018 年的实际测量数据变量, 数据采样间隔为 15 分钟。数据包含: 测风塔 10 m 高度风速、30 m 高度风速、50 m 高度风速、70 m 高度风速和轮毂高度风速、风向、温度、气压、湿度、发电功率。通过对风电场 2018 年风力发电功率与影响因素各变量数据间进行 Spearman 相关性计算, 分析结果如表 1 所示。风力发电功率与轮毂高度风速具有最强相关性, Spearman 系数达到 0.91; 同测风塔 10 m 风速相关性次之, Spearman 系数是 0.90; 发电功率与温度相关程度最低为 -0.09, 所以发电功率与实测数据中的主要影响变量选择为发电功率、测风塔 10 m 高度风速、30 m 高度风速、50 m 高度风速、70 m 高度风速和轮毂高度风速。

表 1 风力发电功率与影响因子间 Spearman 分析结果
Tab.1 Results of Spearman analysis between wind power and influence factors

变量	测风塔 10 m 高 度风速	测风塔 30 m 高 度风速	测风塔 50 m 高 度风速	测风塔 70 m 高 度风速	轮毂高 度风速	风向	温度	气压	湿度	功率
发电功率	0.87	0.88	0.90	0.89	0.91	0.05	-0.09	-0.04	0.08	1

考虑风力发电功率不仅与前一时刻的影响因素有关, 在不同时刻下, 其影响程度高的因素可能还包含之前几个时刻的风力发电功率及其它影响因子, 预测模型输入数据选择为影响发电功率的多个时刻数据值时, 其预测准确性就可能比只输入前一时刻数据高。为此, 对表 1 中与发电功率影响程度高的影响因子进行分时刻的进一步分析。

对风力发电功率、测风塔 10 m 高度风速、30 m 高度风速、50 m 高度风速、70 m 高度风速和轮毂高度风速 6 个变量各个时刻数据进行 Spearman 相关性分析, 选择出与预测时刻发电功率具有强相关性的某一个或某几个时刻数据, 并以此为依据确定分时预测模型的输入数据。当前风力发电功率与历史风力发电功率部分时刻、发电功率与测风塔 10 m 高度风速部分时刻、发电功率与测风塔 30 m 高度风速部分时刻、发电功率与测风塔 50 m 高度风速部分时刻、发电功率与测风塔 70 m 高度风速部分时刻、发电功率与轮毂高度风速部分时刻的相关性分析结果分别如表 2~表 7 所示。

表 2 当前风力发电功率与历史风力发电功率部分时刻 Spearman 相关性分析结果
Tab.2 Spearman correlation analysis results between current wind power and historical wind power

发电功率当前时刻	发电功率历史时刻							
	5:00	5:15	5:30	5:45	6:00	6:15	6:30	6:45
5:00	1.00							
5:15	0.98	1.00						
5:30	0.96	0.98	1.00					
5:45	0.94	0.96	0.98	1.00				
6:00	0.92	0.94	0.96	0.98	1.00			
6:15	0.91	0.92	0.94	0.96	0.98	1.00		
6:30	0.90	0.91	0.93	0.95	0.97	0.98	1.00	
6:45	0.88	0.90	0.91	0.92	0.93	0.95	0.98	1.00

表 3 当前发电功率与测风塔 10 m 高度风速部分时刻 Spearman 相关性分析结果

Tab.3 Spearman correlation analysis results of current generation power and wind speed at the height of 10 m at some time

发电功率部分时刻	测风塔 10 m 高度风速部分时刻							
	5:00	5:15	5:30	5:45	6:00	6:15	6:30	6:45
5:00	0.92							
5:15	0.90	0.92						
5:30	0.89	0.90	0.92					
5:45	0.87	0.89	0.90	0.91				
6:00	0.85	0.87	0.89	0.90	0.93			
6:15	0.84	0.86	0.88	0.88	0.91	0.92		
6:30	0.83	0.85	0.86	0.87	0.89	0.91	0.93	
6:45	0.82	0.84	0.84	0.84	0.86	0.88	0.91	0.92

表 4 当前发电功率与测风塔 30 m 高度风速部分时刻 Spearman 相关性分析结果

Tab.4 Spearman correlation analysis results of current generation power and wind speed at the height of 30 m at some time

发电功率部分时刻	测风塔 30 m 高度风速部分时刻							
	5:00	5:15	5:30	5:45	6:00	6:15	6:30	6:45
5:00	0.92							
5:15	0.91	0.92						
5:30	0.90	0.90	0.92					
5:45	0.88	0.89	0.90	0.91				
6:00	0.86	0.87	0.89	0.90	0.93			
6:15	0.86	0.87	0.88	0.88	0.91	0.93		
6:30	0.85	0.86	0.87	0.87	0.89	0.91	0.93	
6:45	0.83	0.84	0.85	0.84	0.86	0.88	0.90	0.92

表 5 当前发电功率与测风塔 50 m 高度风速部分时刻 Spearman 相关性分析结果

Tab.5 Spearman correlation analysis results of current generation power and wind speed at the height of 50 m at some time

发电功率部分时刻	测风塔 50 m 高度风速部分时刻							
	5:00	5:15	5:30	5:45	6:00	6:15	6:30	6:45
5:00	0.94							
5:15	0.92	0.93						
5:30	0.91	0.92	0.93					
5:45	0.90	0.91	0.92	0.94				
6:00	0.88	0.89	0.91	0.93	0.95			
6:15	0.87	0.88	0.90	0.91	0.93	0.94		
6:30	0.86	0.87	0.88	0.90	0.91	0.93	0.95	
6:45	0.84	0.85	0.86	0.87	0.88	0.90	0.92	0.94

表6 当前发电功率与测风塔70 m高度风速部分时刻 Spearman 相关性分析结果

Tab.6 Spearman correlation analysis results of current generation power and wind speed at the height of 70 m at some time

发电功率部分时刻	测风塔 70 m 高度风速部分时刻							
	5:00	5:15	5:30	5:45	6:00	6:15	6:30	6:45
5:00	0.67							
5:15	0.67	0.68						
5:30	0.67	0.67	0.69					
5:45	0.66	0.67	0.68	0.70				
6:00	0.66	0.66	0.68	0.70	0.71			
6:15	0.65	0.66	0.67	0.69	0.70	0.71		
6:30	0.65	0.66	0.67	0.69	0.70	0.71	0.73	
6:45	0.65	0.65	0.66	0.67	0.68	0.69	0.71	0.72

表7 当前发电功率与轮毂高度风速部分时刻 Spearman 相关性分析结果

Tab.7 Spearman correlation analysis results of current generation power and wind speed at the height of hub at some time

发电功率部分时刻	轮毂高度风速部分时刻							
	5:00	5:15	5:30	5:45	6:00	6:15	6:30	6:45
5:00	0.94							
5:15	0.93	0.94		0.90				
5:30	0.91	0.93	0.94					
5:45	0.88	0.90	0.91	0.94				
6:00	0.86	0.89	0.91	0.93	0.95			
6:15	0.86	0.89	0.90	0.92	0.93	0.95		
6:30	0.85	0.88	0.89	0.90	0.90	0.93	0.96	
6:45	0.82	0.84	0.86	0.86	0.86	0.88	0.92	0.95

根据分析情况,选择出与预测时刻发电功率 Spearman 相关系数在 0.9 以上的时刻数据,并以此为依据确定风电功率网络模型的输入数据。例如,预测 6:45 时刻的发电功率,则输入数据为 5:15、5:30、5:45、6:00、6:15、6:30 时刻的发电功率,6:30 时刻的 10 m 高度风速,6:30 时刻的 30 m 高度风速,6:15、6:30 时刻的 50 m 高度风速及 6:30 时刻的轮毂高度风速。

2 CNN-LSTM 网络模型

2.1 CNN 模型

卷积神经网络源于 Hubel 和 Wiesel 对于猫脑感受野的探索,是将多层网络结构进行成功训练的学习算法^[14]。CNN 模型通过局部连接及共享权值的方式,交替使用卷积层和池化层以获取数据有效表征。

2.2 LSTM 网络模型

LSTM 的记忆单元结构如图 1^[15],记忆单元是记忆模块的核心,表示时刻的细胞状态。LSTM 门结构的作用是增删细胞状态信息,选择性地使信息通过。

各变量之间的计算公式如下

$$i_t = \sigma(W_{xi}X_t + W_{hi}H_{t-1} + W_{ci}C_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(W_{xf}X_t + W_{hf}H_{t-1} + W_{cf}C_{t-1} + b_f) \quad (3)$$

$$C_t = f_t C_{t-1} + i_t \tanh(W_{xc}X_t + W_{hc}H_{t-1} + b_c) \quad (4)$$

$$o_t = \sigma(W_{xo}X_t + W_{ho}H_{t-1} + W_{co}C_{t-1} + b_o) \quad (5)$$

$$H_t = o_t \tanh(C_t) \quad (6)$$

式中: i_t, f_t, o_t, C_t 分别为输入门、遗忘门、输出门、记忆细胞状态的向量; $W_{xi}, W_{xf}, W_{xc}, W_{xo}$ 为连接输入信号 X_t 的权重矩阵; $W_{hi}, W_{hf}, W_{hc}, W_{ho}$ 为连接输出信号 H_t 的权重矩阵; W_{ci}, W_{cf}, W_{co} 为连接矢量 C_t 和门函数权重矩阵; b_i, b_c, b_f, b_o 为偏置向量; σ 为激活函数, 通常为或函数。

2.3 CNN-LSTM 网络模型

CNN-LSTM 网络模型的输入数据结构是时间序列特征图。风力发电功率历史数据、历史时刻风速数据等数据为各自独立的时间序列。为耦合影响功率的特征信息, 将某时刻的历史发电功率和相关的特征表示成向量并联合, 成为新的时间序列数据。如图 2 所示, T 时刻的历史功率与相应影响因素耦合构成时刻的特征图, 下个时刻的特征图利用滑动窗口的方式滑动一个时间间隔而成。按顺序把输入的时间序列形成特征图。 n 指时间步数, t 代表特征图以时间为尺度。

CNN-LSTM 网络模型的构成分为两部分, CNN 部分主要进行数据特征提取, LSTM 网络则主要进行功率预测。经实验发现, 通过增加 CNN 层数能够提高提取特征的能力, 模型精度会变得更, 但是当增加到一定层数之后, 模型的拟合精度趋向稳定, 因此最后将卷积层(Conv2D)数定为 4。卷积层通过将特征映射到池化层(Maxpooling2D), 减少了输出维数, 实现特征提取。然后使用 Flatten 层进行扁平化操作, 再采用全连接层(Dense)输出向量, 即归一化后的风电功率预测结果。

3 算例分析

3.1 实验评价指标

评估模型预测值与训练值拟合程度采用均方误差(MSE)作为损失函数, 若损失函数值越小, 说明模型拟合的越好, 则预测更精确。计算公式为式(7)。以平均绝对误差(MAE)为指标对预测结果的进行评价, 计算公式为式(8)。

$$MSE = \frac{1}{N} \sum_{i=1}^N (p_i - P_i)^2 \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |p_i - P_i| \quad (8)$$

式中: N 为样本个数; p_i 为发电功率预测值; P_i 为发电功率实际值。

3.2 实验结果分析

采用国内某风电场 2018 年 4 月 6 日至 2018 年 4 月 10 日采集的数据进行实验, 分别应用 BP、LSTM 和 CNN-LSTM 预测发电功率, 可得到如图 3 所示的预测结果对比曲线, 以及图 4 所示的对应各时刻的相对误

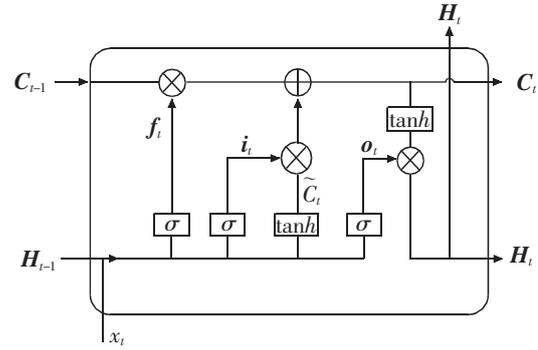


图 1 LSTM 单元结构
Fig.1 LSTM unit

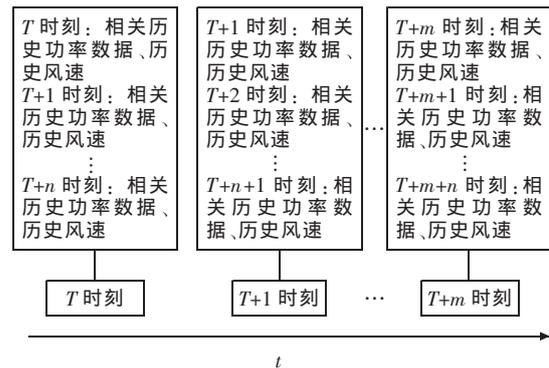


图 2 CNN-LSTM 网络模型输入数据结构
Fig.2 Structure of input data in CNN-LSTM network model

差情况。可见 CNN-LSTM 的预测结果与实际值最接近。

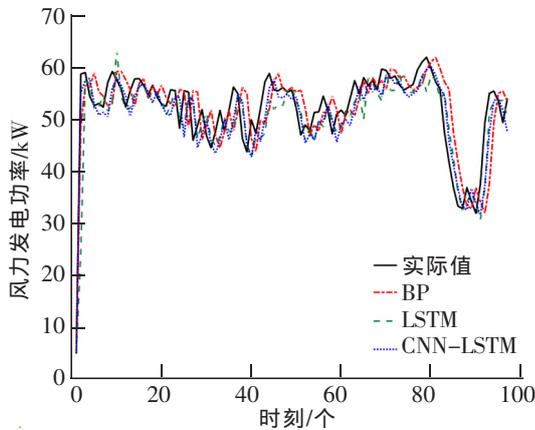


图3 4月9日预测结果对比图

Fig.3 Comparison chart of forecast results on April 9th

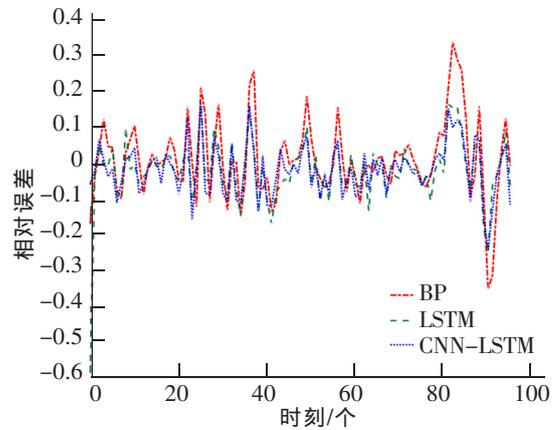


图4 4月9日预测相对误差曲线

Fig.4 The relative error curve of prediction on April 9th

表8 预测结果误差对比

Tab.8 Error comparison of prediction results

预测日	BP 神经网络模型 MAE	LSTM 网络模型 MAE	CNN-LSTM 网络模型 MAE
4月6日	2.76	2.18	1.68
4月7日	3.38	2.25	2.17
4月8日	4.19	2.97	2.79
4月9日	3.91	3.33	3.02
4月10日	4.43	3.17	2.80

从表8可看出,本文提出的 CNN-LSTM 预测方法得到风电场 2018 年 4 月 6 日至 2018 年 4 月 10 日期间的 e_{MAE} 明显小于 BP 和 LSTM 网络模型得到的 e_{MAE} , 说明利用 CNN-LSTM 模型可提高预测精度。

4 结论

针对提升预测精度的要求,本文提出一种基于 CNN-LSTM 网络的风电功率预测方法,并经过实验验证了其有效性。算例表明:

1) 采用 Spearman 分析不同变量间的相关性,可以对预测模型的多变量输入进行筛选,从而降低数据规模,减少非有效信息给模型精度带来的影响。

2) 基于 CNN-LSTM 网络构建的预测模型,不仅具有 CNN 适于提取数据特征的优点,又包含了 LSTM 处理时间序列的能力,实验结果验证文中预测方法能够提高风电功率的预测精度。

当风力发电功率出现持续性突变时,深度学习算法的跟踪性能需进一步加强。下一步的研究可结合优化算法来提升其预测效果。

参考文献:

- [1] 钱政,裴岩,曹利宵,等. 风电功率预测方法综述[J]. 高电压技术, 2016, 42(4): 1047-1060.
- [2] 徐龙博,王伟,张滔,等. 基于神经网络平均影响值的超短期风电功率预测[J]. 电力系统自动化, 2017, 41(21): 40-45.
- [3] 岳晓宇,彭显刚,林俐. 鲸鱼优化支持向量机的短期风电功率预测[J/OL]. 电力系统及其自动化学报. <https://doi.org/10.19635/j.cnki.csu-epsa.000249>.
- [4] MOHAMMAD AMIN CHITSAZAN, M SAMI FADALI, ANDRZEJ M TRZYNADLOWSKI. Wind speed and wind direction forecasting using echo state network with nonlinear functions[J]. Renewable Energy, 2019, 131: 879-889.

- [5] 丁明, 缪乐颖, 车建峰, 等. 基于波动过程匹配技术的短期风电功率预测[J]. 电网技术, 2018, 42(11): 3652-3659.
- [6] 李昌林. 基于循环神经网络的风电场功率超短期和短期预测[D]. 重庆: 重庆大学, 2017: 1-63.
- [7] 朱乔木, 李弘毅, 王子琪, 等. 基于长短期记忆神经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.
- [8] WEIGEND A S. Time series prediction: Forecasting the future and understanding the past[M]. [S.l.]: Routledge, 2018.
- [9] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [10] FAN C, XIAO F, ZHAO Y. A short-term building cooling load prediction method using deep learning algorithms[J]. Applied Energy, 2017, 195: 222-233.
- [11] LAI G, CHANG W C, YANG Y, et al. Modeling long and short-term temporal patterns with deep neural networks[C]//Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval, 2018: 95-104.
- [12] 库向阳, 王邵鹏. 基于卷积-LSTM 网络的广告点击率预测模型研究[J]. 计算机工程与应用, 2019, 55(2): 193-197.
- [13] 丁晓冀, 鲁丽萍, 刘娟. 基于 IEC 61400-25 的风电远程集中控制系统[J]. 电力信息与通信技术, 2016, 14(8): 82-86.
- [14] JIN K H, MCCANN M T, FROUSTEY E, et al. Deep convolutional neural network for inverse problems in imaging[J]. IEEE Transactions on Image Processing, 2017, 26(9): 4509-4522.
- [15] 刘云鹏, 许自强, 董王英, 等. 基于经验模态分解和长短期记忆神经网络的变压器油中溶解气体浓度预测方法[J]. 中国电机工程学报, 2019, 39(12): 3998-4007.

Short Term Wind Power Prediction Based on CNN-LSTM Network Model

Li Yan^{1,2}, Peng Chunhua¹, Fu Yu², Sun Huijuan¹

(1. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China;
2. Ganzhou Power Supply Branch of State Grid Jiangxi Electric Power Co., Ltd., Ganzhou 341000, China)

Abstract: Wind power forecasting is vital to the stable operation and economic dispatch of power system. In order to fully mine the effective information in historical data to improve the accuracy of short-term wind power prediction, a short-term wind power prediction method based on convolution neural network (CNN) and long short-term memory network model (LSTM) is proposed. The effective information was extracted by CNN sequence feature extraction ability, and the data was input to LSTM network after other information was removed. The problem of gradient dispersion could be solved by keeping longer effective memory information, which made up for the lack of instability and gradient disappearance when the LSTM network model was faced with a long sequence. The results show that the method proposed is more accurate than the back propagation neural network and LSTM network.

Key words: wind power prediction; convolutional neural network (CNN); long short-term memory network (LSTM); CNN-LSTM network model