

文章编号: 2096-1618(2022)02-0165-06

# 基于 PCC-CNN-GRU 的短期风电功率预测

杨 芮, 文 武, 徐 虹

(成都信息工程大学计算机学院, 四川 成都 610225)

**摘要:**可靠的风功率预测对于电力部门制定电力调度计划、维护电网的安全运行具有重要意义。这项任务极富挑战性,因为影响风功率预测准确率的因素较多,如地理因素、环境因素、人为因素等。将环境因素考虑在内,提出一种基于深度学习的组合预测模型 PCC-CNN-GRU 皮尔逊相关系数法(Pearson correlation coefficient)-卷积神经网络(convolutional neural networks)-门控循环单元(gate recurrent unit)。该模型首先使用皮尔逊相关系数法分析输入数据中不同因素与风功率之间的相关关系,剔除与功率无关的因素,重构新的输入数据并进行归一化处理,并使用一维卷积神经网络对数据的深层特征进行提取,最后将提取的特征送入 GRU 神经网络进行预测。实验使用新疆某地风场实地采集数据仿真,结果表明,该方法的预测误差最小,预测能力最强。

**关 键 词:**风功率预测;PCC;CNN;组合预测模型

**中图分类号:**TP301.6

**文献标志码:**A

**doi:**10.16836/j.cnki.jcuit.2022.02.009

## 0 引言

习近平总书记在 2020 年召开的联合国代表大会上提出了“双碳”目标(2030 年碳达峰,2060 年碳中和)<sup>[1]</sup>。“双碳”的明确提出,指明了电力行业向低碳无污染方向转变的目标。同时,“十四五”规划<sup>[2]</sup>也明确提出了要进一步扩大风电规模。因此,在政策的指导以及各部门的协同参与下,可以预见未来几年,大规模风电将会接入电网,直到清洁能源发电完全替换传统发电方式(燃烧化石燃料发电)。不过,风功率自身的波动性会对电网的安全运行构成威胁<sup>[3]</sup>,因此,较准确的功率预测尤为重要。

早期风功率预测研究始于国外,中国的研究则启动较晚。早期西方国家对风功率预测的方法主要采用物理模型,通过将数值天气预报(NWP)数据代入方程,通过大量计算,求得风功率预测值,代表性的例子是丹麦的 Prediktor 系统<sup>[4]</sup>和德国的 Previento 系统<sup>[5]</sup>。随着技术的发展,统计学方法也被应用于风功率预测,Sipreólico 系统是典型代表。最近几年,随着机器学习和深度学习的兴起,学者们将目光从物理方法和统计学方法转移到了机器学习和深度学习方法上。

文献[6]使用可能性 C 均值聚类算法对数据做预处理,剔除历史功率中的异常数据,接着用 RBF 网络预测,预测精度高于 BP 网络。文献[7]使用工具包 LIBSVM 中的回归模型函数 svmtrain 对训练集训练,找到 SVR 算法的最优参数(惩罚因子和 gamma),初始化

SVR 算法并进行预测,相较 BP 网络,预测精度有所提高。文献[8]使用 ARMA 模型对风功率进行预测,实验中预测准确率比较不错。上述单一模型预测方法在对风功率预测时,均取得较好的效果,但预测精度仍难以满足风电并网的需求。

组合模型如今备受学者们推崇,将在预测中表现较好的模型组合起来,发挥每个模型各自的优点,以此提高风功率预测精度。文献[9]使用 VMD 方法对电力负荷信号分解,得到一组信号,为每个信号建立 GRU 模型进行预测,最后叠加所有结果得到最终预测值。相较 VMD-LSTM、EMD-GRU 等方法,具有较高的预测精度。文献[10]首先提出改进萤火虫算法(IFA),接着提出 IFA-LSSVM 模型对短期风功率进行预测,相较 FA-LSSVM、PSO-LSSVM 模型,该模型预测精度最高。文献[11]提出了 ARMA-GARCH 模型,相较 ARMA 模型,新模型预测精度明显更高。上述组合模型各有各的优点,预测精度较单一模型都有显著提升,但也存在一些问题。对于与文献[9]类似的方法(先分解再预测),分解算法需要将训练集和测试集全部分解再进行预测,数据分解本身需要一些时间,若历史数据庞大,则分解时间不好估计。对于与文献[10]类似的方法(先对模型参数寻优再预测),若数据量庞大,计算量增加的同时算法寻优时间也会随之增加。上述方法只采用风功率历史数据或同时使用风功率和风速历史数据作为模型输入,未将其他影响因素作为模型输入,建模数据不够完善,预测精度会受到影响。

因此,在考虑风速及风功率的同时,将环境因素也



指代,权重矩阵由  $W$  指代, sigmoid 函数由符号  $\sigma$  指代,输出值由  $h$  指代。

1.3 皮尔逊相关系数

皮尔逊相关系数(Pearson correlation coefficient)多用于衡量向量之间相关程度<sup>[16]</sup>,计算公式如下:

$$r(X,Y)=\frac{\sum_{i=1}^n(X_i-\bar{X})(Y_i-\bar{Y})}{\sqrt{\sum_{i=1}^n(X_i-\bar{X})^2}\sqrt{\sum_{i=1}^n(Y_i-\bar{Y})^2}} \tag{5}$$

该算法的输出结果为  $[-1,1]$ ,输出值为负,则代表两个向量之间存在负相关关系;输出值为正,则代表两个向量之间存在正相关关系;若输出值绝对值为 1,则代表两个向量存在完全正相关或完全负相关关系。输出值绝对值越大,两个向量之间的相关性越大,具体相关程度等级划分见表 1。

表 1 变量相关程度等级表

相关程度	输出值为正	输出值为负
强	0.5 ~ 1.0	-1.0 ~ -0.5
中	0.3 ~ 0.5	-0.5 ~ -0.3
弱	0.1 ~ 0.3	-0.3 ~ -0.1
无	0.0 ~ 0.09	-0.09 ~ 0.0

2 基于 PCC-CNN-GRU 的短期风速预测模型

风场周围无论是地势还是环境都很复杂,使用单一(风功率历史数据)或唯二两个因素(风功率历史数据、风速历史数据)对风功率进行预测,易导致建模数据不完全,致使预测结果存在误差。因此,本文在考虑风功率和风速历史信息的同时,将天气因素考虑在内,使用皮尔逊相关系数法从输入量中剔除与风功率无关的因素,重构新的模型输入数据并进行归一化,而后使用一维卷积神经网络深度挖掘数据的深层信息,提取特征送入 GRU 网络,以此实现对风功率的短期预测。

2.1 预测模型及步骤

PCC-CNN-GRU 模型预测流程主要由数据处理和风功率预测两大模块组成,见图 5。数据预处理模块用于处理原始数据,皮尔逊相关系数法能够将与风功率无关的因素全部剔除,减少模型输入,归一化操作缩小了数据间的量纲差距,提高预测的准确率;风功率预测模块用于预测数据,CNN-GRU 网络能够提取数据深层特征并进行预测。

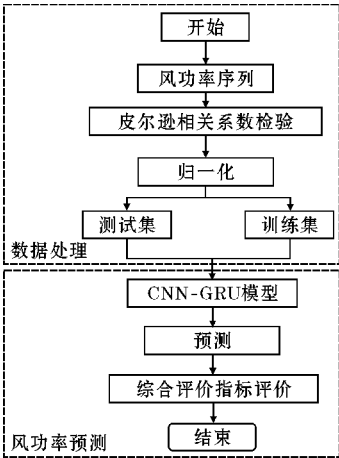


图 5 基于 PCC-CNN-GRU 的短期风电功率预测流程图

具体步骤如下:(1)从文件中读取原始风功率时间序列;(2)对风功率数据进行皮尔逊相关系数检验,去除与功率无关的因素;(3)对步骤(2)得到的新数据进行归一化处理;(4)按照 19 : 1 的占比,将步骤(3)得到的序列按照 19 : 1 的占比进行划分,前 $\frac{19}{20}$ 为训练集,后 $\frac{1}{20}$ 为测试集;(5)将训练集数据送入 CNN-GRU 网络进行训练;(6)将测试集数据送入 CNN-GRU 网络进行预测;(7)求得综合评价指标。

2.2 CNN-GRU 模型结构

提出的 CNN-GRU 模型网络结构见图 6。将皮尔逊相关系数法处理所得数据作为网络的输入,经由两层卷积一层池化挖掘出数据深层特征,将特征输入 GRU 层进行预测,输出预测结果。网络结构中的丢弃层能够在一定程度上减轻模型过拟合的程度,提高模型泛化能力。




图 6 CNN-GRU 网络结构图

第一层 Conv1D 中 filters 设置为 32, kernel\_size 设置为 3。第二层 Conv1D 中 filters 设置为 64, kernel\_size 设置为 3。激活层均采用 relu 函数。池化层选用最大池化, pool\_size 设置为 2。GRU 层神经元设置为 30。Dropout 参数设置为 0.2。

3 实验结果与对比分析

3.1 实验数据集及结果

实验使用中国某地风场 2017 年的风场实地采样



数据,以 15 分钟为间隔对数据采样,数据包含时间、风速、风向、气压、温度、湿度、功率。对原始数据进行皮尔逊相关系数检验,计算结果见表 2。

表 2 皮尔逊相关系数输出结果

	风速	风向	气压	温度	湿度	功率
风速	1.00	0.02	-0.16	0.10	-0.44	0.94
风向	0.02	1.00	0.05	-0.31	-0.06	0.05
气压	-0.16	0.05	1.00	0.11	0.18	-0.19
温度	0.10	-0.31	0.11	1.00	-0.14	0.08
湿度	-0.44	-0.06	0.18	-0.14	1.00	-0.44
功率	0.94	0.05	-0.19	0.08	-0.44	1.00

综合表 1 和表 2 可以看出,风速与功率具有强相关关系,湿度与功率具有中等强度相关关系,压强与功率具有弱相关关系,风向和温度与功率的相关性较微弱。因此,选用风速、压强、湿度、功率四项因素作为网络输入数据,输入数据一共 3072 条,PCC-CNN-GRU 模型预测结果见图 7。




图 7 PCC-CNN-GRU 模型预测结果

选用 CNN-LSTM、LSTM、GRU 模型作为对比模型,其中 CNN-LSTM 模型中的网络结构与 CNN-GRU 结构基本相同,卷积窗口同样设置为 8,不同之处是将 GRU 层换成 LSTM 层,3 种对比网络均与 CNN-GRU 网络的神经元一样设置为 30,Droupout 率均设置为 0.2,Epoch 均设置为 100,Batch\_Size 均设置为 64。同时,还选择了文献[17]的 CNN\_GRU 模型作为对比模型。从图 8 可以看出,这几种模型的预测曲线基本都能预测真实功率的变化趋势,但从图 9 可以明显看出在细节的把控和预测精度上 PCC-CNN-GRU 模型表现更好。




图 8 PCC-CNN-GRU 与其他模型预测结果对比




图 9 多种模型对比放大图

3.2 算法性能对比分析

选用 4 种常用评价指标对模型性能进行评测,分别是 RMSE (均方根误差)、MAE (平均绝对误差)、MAPE (平均绝对百分误差)、 $R^2$  (决定系数)<sup>[18]</sup>。其中,前 3 项数值越小代表模型拟合误差越小, $R^2$  越接近于 1 模型拟合效果越好。4 项指标计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{true}(i) - y_{pred}(i))^2}$$
 (6)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{true}(i) - y_{pred}(i)|$$
 (7)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{true} - y_{pred}}{y_{true}} \right|$$
 (8)

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{true}(i) - y_{pred}(i))^2}{\sum_{i=1}^n (y_{true}(i) - \bar{y})^2}$$
 (9)

由表 3 可知,PCC-CNN-GRU 模型的 RMSE、MAPE、MAE 值均小于其他方法, $R^2$  均大于其他方法,更接近于 1。由此表明,在输入条件完全一样的情况下,相比于其他 4 种方法,本文提出的 PCC-CNN-GRU 方法在预测能力和预测精度上表现得更好。

表 3 PCC-CNN-GRU 模型与其他模型效果对比

方法	RMSE	MAPE	$R^2$	MAE
PCC-CNN-GRU	0.7351	0.1336	0.9933	0.4949
CNN-LSTM	0.8435	0.1438	0.9912	0.6809
LSTM	0.8752	0.1975	0.9905	0.6900
GRU	0.8580	0.1800	0.9909	0.6641
CNN_GRU	1.2331	0.1726	0.9811	1.0295

PCC-CNN-GRU 模型相比于 CNN-LSTM 模型, RMSE、MAPE、MAE 3 种指标分别降低了 12.85%、7.1%、27.32%,相比于 LSTM 模型,3 种指标分别降低了 16%、32.35%、28.28%,相比于 GRU 模型,3 种指

标分别降低了 14.32%、25.78%、25.48%，相比于 CNN-GRU 模型，3 种指标分别降低了 40.39%、22.6%、51.93%。PCC-CNN-GRU 模型相对其他模型误差降低百分比，见图 10。误差降低百分比计算公式如下

$$R=\frac{X-Y}{X}\times100\%$$
 (10)

式中  $R$  代表误差降低百分比， $X$  代表对比模型评价指标值(CNN-LSTM 或 LSTM 或 GRU 或 CNN-GRU)， $Y$  代表本文提出的 PCC-CNN-GRU 模型评价指标值。




图 10 PCC-CNN-GRU 模型相对其他模型误差降低百分比图

4 结论

在对风功率预测时，不仅考虑了风速和风功率两种因素，同时将天气因素考虑在内，使建模数据更完善。为充分发掘影响风功率预测的因素，对采样数据进行皮尔逊相关系数法分析，将与风功率无关因素剔除，剩下的数据输入到 CNN-GRU 网络中，深度挖掘数据内部信息，以此实现短期风电功率预测，并采用实地采集的数据进行预测，得出以下结论：(1) 组合模型预测能力明显优于单一模型。(2) 在预测前使用皮尔逊相关系数法对数据进行筛选，能够有效减少计算量，提高模型预测效率。(3) 通过与 CNN-LSTM、LSTM、GRU、GRU\_CNN、CNN-GRU 模型进行比较，证明了本文提出的 PCC-CNN-GRU 组合模型预测精度更高，在时间序列预测上具有更大优势。

参考文献：

[1] 谭显东,刘俊,徐志成,等.“双碳”目标下“十四五”电力供需形势[J/OL]. 中国电力:<http://kns.cnki.net/kcms/detail/11.3265.TM.20210408.1657.006.html>,2021.

[2] 郭敏晓,杨宏伟. 围绕“碳中和”愿景能源与环境领域将呈现六方面的变化趋势“十三五”能源与环境形势及“十四五”展望[J/OL]. 中国能源:<http://kns.cnki.net/kcms/detail/11.2587.TK.20210329.2130.008.html>,2021-04-14.

[3] 马吉科,石星煜,王黎明,等. 融合多源信息的短期风电功率预测方法研究[J]. 计算机仿真,2020,37(7):137-143.

[4] Landberg L. Prediktor: An on-line prediction system[A]. Wind Power for the 21st Century, EU-WEC Special Topic Conference[C], Kassel,2000.

[5] Lange M U, Focken D. Heinemann previento—regional wind power prediction with risk control[C]. Proceedings of the World Wind Energy Conference, Berlin,2002.

[6] 王瑶,杨培宏,李忠. 基于 RBF 算法短期风功率预测[J]. 绿色科技,2020(6):256-257.

[7] 陈岩,周晨,侯群. SVM 算法在风力发电机功率预测中的应用研究[J]. 电子世界,2021(4):100-102.

[8] 刘军涛,欧阳孜. 基于 ARMA 模型的短期风功率预测研究[J]. 西北水电,2017(6):100-104.

[9] 黄冬梅,唐振,胡安铎,等. 基于 VMD-GRU 的电力短期负荷预测方法[J]. 物联网技术,2021,11(4):67-70.

[10] 谭彦聪,王海云,王江江. 基于 IFA-LSSVM 的短期风功率预测[J]. 水力发电,2021,47(4):112-116.

[11] 田波,朴在林,郭丹,等. 基于 ARMA-GARCH 模型的超短期风功率预测研究[J]. 电测与仪表,2016,53(17):12-17.

[12] 周盛山,汤占军,王金轩,等. EEMD 和 CNN-XGBoost 在风电功率短期预测的应用研究[J]. 电子测量技术,2020,43(22):55-61.

[13] 张爱枫,段新宇,何泉峰. 基于 CNN 和 LightGBM 的新型风电功率预测模型[J]. 电测与仪表,2021.

[14] X R Zu, R X Song. Short-term Wind Power Prediction Method Based on Wavelet Packet Decomposition and Improved GRU[J]. Journal of Physics:Conference Series,2018,1087(2).

[15] Meng X, Wang R, Zhang X, et al. Hybrid Neural Network Based on GRU with Uncertain Factors for Forecasting Ultra-short-term Wind Power[C]. 2020 2nd International Conference on Industrial Artificial Intelligence(IAI). 2020.

[16]   元晓燕,刘恒杰,侯秋华,等.融合 LSTM 和 SVM 的钢铁企业电力负荷短期预测[J]. 山东大学学报(工学版),2021(4):91-98.

[17]   薛阳,王琳,王舒,等.一种结合 CNN 和 GRU 网络的超短期风电预测模型[J]. 可再生能源,2019,37(3):456-462.

[18]   胡汉. 风电场风电功率概率预测研究[D]. 南京:东南大学,2016.

Short-term Wind Power Prediction based on PCC-CNN-GRU

YANG Rui,  WEN Wu,  XU Hong

( College of Computer Science ,Chengdu University of Information Technology ,Chengdu 610225 ,China)

**Abstract:**Reliable wind power prediction is of great significance for the power sector to make power dispatching plans and maintain the safe operation of the power grid. This task is very challenging, because the accuracy of wind power prediction is affected by many factors, such as geographical factors, environmental factors, human factors and so on. In this paper, a combination forecasting model PCC-CNN-GRU (Pearson correlation coefficient-convolutional neural networks-gate recurrent unit) based on deep learning is proposed, taking environmental factors into account. Firstly, the model uses the Pearson Correlation Coefficient method to analyze the correlation between different factors and wind power in the input data, eliminate the factors not related to the wind power, and reconstruct the new input data and carry out normalization processing. Then the deep features of the data are extracted by using one-dimensional convolutional neural network, and finally the extracted features are sent to GRU neural network for prediction. The experimental results show that the method has the least prediction error and the strongest prediction ability.

**Keywords:**wind speed prediction;PCC;CNN;combined forecasting model