

基于改进时间卷积网络的光伏发电功率预测

李桂兰^{1,2}, 杨杰^{1,2*}, 周满国¹

¹江西理工大学电气工程与自动化学院, 江西 赣州 341000;

²江西省磁悬浮技术重点实验室, 江西 赣州 341000

摘要 为进一步提升光伏发电功率预测的效率, 提出一种特征融合结合改进时间卷积网络(TCN)的方法进行光伏发电功率预测。用相关系数法对各时序特征进行分析, 确定有效输入进行特征融合; 改变 TCN 的膨胀参数和连接方式, 提高发电功率预测精度。在华南某地区两个不同发电厂的数据集上, 对所提方法与经典算法 LSTM、GRU、1D-CNN 和 TCN 进行对比, 并取不同天气样本进行测试。结果表明, 所提方法能够达到 0.982 的决定系数, 较其他算法有更好的拟合能力; 模型的训练时长仅 30 s, 预测效率有很大提升。

关键词 神经网络; 功率预测; 时间卷积网络; 特征融合; 深度学习; 序列预测

中图分类号 TK513.5

文献标志码 A

doi: 10.3788/LOP202259.0820001

Power Prediction of Photovoltaic Generation Based on Improved Temporal Convolutional Network

Li Guilán^{1,2}, Yang Jie^{1,2*}, Zhou Manguo¹

¹School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China;

²Jiangxi Key Laboratory of Magnetic Levitation Technology, Ganzhou, Jiangxi 341000, China

Abstract To improve the efficiency of photovoltaic (PV) power forecasting, the method of feature fusion combined with improved temporal convolutional network (TCN) is proposed. The correlation coefficient approach is utilized to examine the time series features, and the effective input for feature fusion is calculated. To increase the accuracy of generating power forecasting, the TCN expansion parameters and connection modes are adjusted. The proposed method is evaluated on two different power plant data sets in South China, and it is compared to the classical algorithms LSTM, GRU, 1D-CNN, and TCN, as well as diverse weather samples. The results reveal that the approach described in this paper achieves a decisive coefficient of 0.982 and outperforms other algorithms in terms of fitting ability. The training time of the model is only 30 s, and the prediction efficiency is greatly improved.

Key words neural network; power prediction; temporal convolutional network; feature fusion; deep learning; sequence prediction

1 引言

光伏发电一直是电网调度、资源配置和环境保

护的一项重要内容, 凭借转换效率高、产电量大和使用周期长等优势得以迅速发展^[1]。由于光伏发电本身具有间歇性、随机性和波动性等特点^[2-3], 易受

收稿日期: 2021-08-02; 修回日期: 2021-08-20; 录用日期: 2021-08-25

基金项目: 国家自然科学基金(61763016)、江西省 03 专项及 5G 项目(20204ABC03A15)

通信作者: *yangjieedu@163.com

太阳辐射、云量和气溶胶等多种因素影响^[4-5],大规模的光伏发电会给电网的正常运行、优化调度和并网质量带来挑战。针对此,及时并有效地预测光伏发电功率,能为电网调度和紧急预案工作提供反应时间,对电网工作的平稳运行^[6]具有重要意义。

预测光伏发电功率实际上是对非平稳数据流的预判,其精度往往取决于对时序特征的提取和处理方法。近年来,学者将光伏发电功率的预测方法分为学习法^[7-8]、物理模型法^[9-10]和统计法^[11-13]。随着机器学习与深度学习^[14]的不断发展,利用学习法进行光伏发电功率预测逐渐成为热门^[15-20],其中以深度学习算法为主流。孙志强等^[21]将模态分解和神经网络结合,提出了一种基于 EEMDHilbert 变换联合时频熵的神经网络光伏发电功率预测方法,在晴天、雨天、多云天气,短期光伏发电功率的预测精度达到 0.995、0.944、0.931,超短期光伏发电功率的预测精度达到 0.996、0.984、0.991。王晨阳等^[22]结合遗传算法、卷积神经网络和长短时记忆网络构建三者的混合预测模型,较单一网络,最高有 1.537% 的精度提升。学者们利用经典的循环神经网络(RNN)^[23]、长短期记忆网络(LSTM)^[24]和门控循环单元(GRU)^[25]等算法取得了大量可喜成果,这些预测模型能够有效提取深层次的数据特征,体现时间序列前后的关联性,预测精度高,是功率预测的首要选择。此外,乔颖等^[26]利用三维卷积提出了一种地域全覆盖的网格化分布式光伏电站群短期功率预测方法,该方法对分布式光伏电站群功率预测的准确性和鲁棒性都有一定提高,但速度较慢。

为进一步提升时序预测模型的预测效率,Bai 等^[27]提出了时间卷积网络(TCN),该网络能够达到与 RNN 系列算法持平的预测精度,且速度更快。此后,李滨等^[28]、Gan 等^[29]和 Lara-Benítez 等^[30]分别在负荷、风速和功耗等时序预测任务上进行实验,结果表明,TCN 结构在准确率和效率方面都具有一定优势。针对此,本文选用 TCN 结构为基础进行研究。

本文旨在用融合特征建立基于高效预测光伏发电功率的深度学习模型,以满足现有工业需求。首先,利用距离相关系数和最大互相关系数对数据样本进行分析,利用特征间互补性和特征与功率间强相关性的特点选出融合特征;其次,改进 TCN 结构并优化参数,建立融合后的特征与功率之间的高效模型,提升预测精度与速度;此外设计多组实验,利用评价指标分析,与经典算法进行对比,证明所

提方法的优越性。

2 特征融合

考虑到功率预测对速度的需求,且影响光伏发电功率的因素具有多样性,单一特征或简单排列组合特征所建立的模型往往难以取得理想的性能。利用相关系数分析的方法筛选特征,采用前端融合方式,以期预测精度的大幅提升。

2.1 预选数据特征

影响光伏发电功率的因素有很多,文献[31]指出太阳辐射是光伏发电的主导因素,因此将太阳方位角和太阳入射角等天文参数纳入考虑。采集的预选特征有:大气温度、模块温度、太阳辐照度、电流、电压、湿度、云量、风速、太阳方位角和太阳入射角。

其中,太阳方位角的计算公式为

$$\cos \gamma = \frac{\sin \delta - \sin h \cdot \sin \phi}{\cos h \cdot \cos \phi} \quad (1)$$

太阳入射角的计算公式为

$$\cos \theta = \cos h \cdot \cos \gamma, \quad (2)$$

式中: h 为高度角; ϕ 为地理纬度; δ 为太阳赤纬度; γ 为壁面太阳方位角。

2.2 相关系数分析

前端融合的理想状态是选择的特征之间具有强互补性,特征与结果之间有强相关性。就光伏发电功率预测任务而言,特征与特征间的相关系数值在 $[-0.3, 0.3]$,特征与功率之间的相关系数值在 $[0.6, 1]$ 或 $[-1, -0.6]$,是理想的融合特征。

针对此,运用距离相关系数(DCC)和最大互信息系数(MIC)^[32]判断发电功率与各种特征变量之间的相关性,并以 Pearson 相关系数(PCC)系数^[33]作为参考值,从而获取较合适的融合特征。

3 基于时间卷积网络的模型结构

3.1 时间卷积网络(TCN)

用于时序预测任务的经典算法包括 RNN、LSTM、GRU 和 1D-CNN。其中 RNN 为最传统的序列模型,其神经元的输出可以在下一个时间段直接作用到自身,能够对时间序列上有变化的情况进行处理,但面临着梯度消失和梯度爆炸问题。针对这两个问题,LSTM 和 GRU 等变体逐渐被提出。LSTM 算法凭借门机制缓解了梯度消失现象,并利用 cell state 实现对长期记忆的控制,有效避免了短期记忆覆盖长期记忆的问题。GRU 算法也采用了门机制,并将遗忘门和输入门合成了一个单一的更

新门,以更小的参数达到了与 LSTM 类似的预测精度,具有收敛速度快的优势。从 RNN 到 LSTM 再到简化的 GRU,序列分析问题几乎与 RNN 相互依存,1D-CNN 算法由于精度普遍不敌其他算法,不适用于时序任务,而 TCN 的提出为使用卷积进行序列预测提供了一种新思路。

TCN 原始结构主要由因果卷积、膨胀卷积^[34]和

残差结构^[35]构成,如图 1 所示。图 1(a)残差结构能有效阻止梯度消失,保证模型的泛化能力;图 1(b)因果卷积将预测过程类比为马尔可夫模型任务,建立此刻数据与历史数据的因果联系;图 1(c)膨胀卷积致力于解决因果卷积带来的计算资源损耗问题,调节 dilation 参数从而改变感受野大小,用于提取更深层的序列信息。

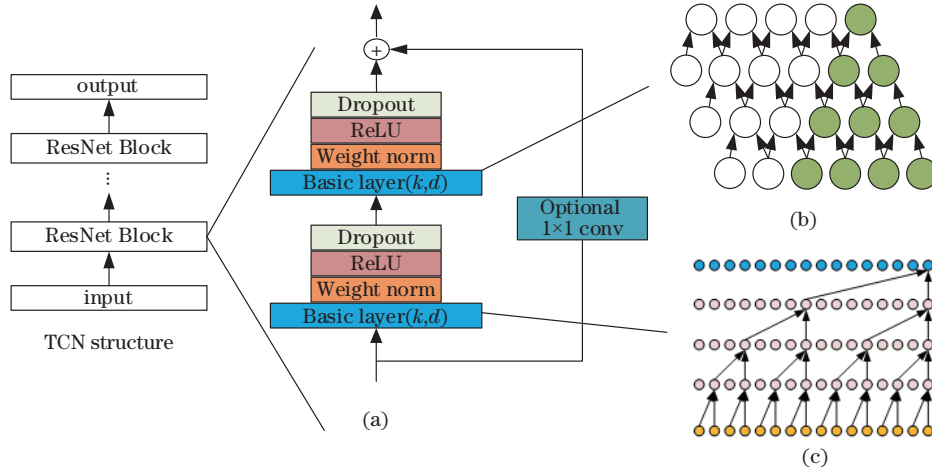


图 1 TCN 结构。(a)残差单元;(b)因果卷积;(c)膨胀卷积

Fig. 1 TCN structure. (a) ResNet unit; (b) causal convolution; (c) dilated convolution

图 1 中, Basic layer 是指因果卷积或膨胀卷积, k 是卷积核大小, d 是 dilation 参数。TCN 结构使用因果卷积或膨胀卷积替代残差结构中的标准卷积, 设置卷积核大小 $k=3, d=1$ 为初始值, 此后以 2 为倍数递增。当 $d=1$ 时, 是因果卷积, $d=2$ 或其他, 为膨胀卷积。

3.2 改进的 TCN 结构

原始的 TCN 结构使用膨胀卷积和因果卷积替代残差结构中的标准卷积, 并将 d 设置为 2 的 n 次方, 形如 $[1, 2, 4, 8, \dots]$, 且其中残差结构之间的特征传递为串联方式, 由于这种结构具有强对称性, 在一定程度上能够表征常规特征与功率之间的信息交互, 而难以学习有偏差或异常的输入。针对

此, 借鉴特征重用与分组卷积的思想, 将残差结构的串联模式改为并联分布, 设置 Part2 的参数 d 为 $[1, 3, 5, 7, \dots]$, 改进后的 TCN 结构如图 2 所示。

改进后的结构中, Part1 部分维持原有的 d 参数, 以 2 的 n 次方进行递增, 以每层固定的感受野进行学习, 能够较好表征较稳定数据与功率的信息交互, 构建出针对晴天、雨天等单一天气的功率关联模型; 而 Part2 部分修改 d 参数, 以不对称的步数控制模型, 获得不同尺寸的感受野, 借此获得不规则时长之间的关联模型, 能够捕获不同天气情况下的数据变化, 构建出针对多云转晴、小雨转多云等复杂天气的功率关联模型。对 Part1 和 Part2 这两个分支进行 concat 操作, 能够增强模型对不同情况的普




图 2 改进后的 TCN 结构

Fig. 2 Improved TCN structure

适性。此后,对 concat 操作后的特征进行重用,并输入到下一个残差单元,利用 ResNet 残差单元避免梯度消失情况的发生,并使用了 Dropout 防止模型过拟合,这些操作有利于构建复杂情况下的功率预测模型,提高光伏发电功率的预测精度。

3.3 评价指标

MAE 是指预测值与真实值之间的平均绝对误差,范围为 $[0, +\infty]$,当模型预测出来的光伏发电功率与真实值一致时,MAE 等于 0,代表该模型是理想模型。MAE 的表达式为

$$E_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3)$$

预测值与真实值之间的均方根误差(RMSE)的特点与 MAE 相近,表达式为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4)$$

真实值与预测值之间的平均绝对百分比误差(MAPE)是对每个点的误差进行归一化的指标,能有效降低个别异常值带来的绝对误差影响。但 MAPE 对实际值为 0 的点无效,本文已剔除值为 0 的点。该指标表达式为

$$E_{\text{MAPE}} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (5)$$

决定系数 r^2 表示原始离散程度与拟合模型的关系,该指标正常取值区间为 $[0, 1]$ 。该值越接近 1,表明功率预测值对真实值的解释能力越强,模型拟合得越好。就实际经验而言, r^2 只要大于 0.4,则模型拟合效果较好。其表达式为

$$r^2 = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (6)$$

式中: y_i 为实际值; \hat{y}_i 为预测值; \bar{y} 为平均值。

4 实验与结果

4.1 实验环境

搭建的实验平台:电脑配置为 i5-6500 CPU, 8G RAM, 64 位 Window 7 操作系统,服务器配置为 Tesla-P100,实验在算法框架 TensorFlow 上实现。

功率数据集源于华南某地区两个不同的光伏发电厂,数据采集时间为 2021 年 5 月 15 日至 2021 年 6 月 17 日。由于发电板的硬件差异可能导致随机事件的发生,对两个发电厂的光伏发电板进行随机采样,各选出 20 块进行实验。每块发电板的

最大功率均为 500 W,在数据采集时间内,设定采样间隔为 15 min,每天采集 96 个数据点。至 6 月 17 日,共采集 3168 个数据点,前 2496 个采样数据为训练集,后 672 个为测试集。

针对影响光伏发电功率的因素,气象数据来源于国家气象科学数据中心(<http://data.cma.cn/>),太阳辐照度的相关天文参数由 2.1 节中公式计算得出,其他硬件特征由控制器导出。采集后的原始数据有数量级不统一的特点,直接输入数据易影响模型对小数量级特征的敏感度,使预测模型无法做出正确的预测^[36],因此对输入的特征和预测目标均进行归一化处理,公式为

$$y = y_{\min} + \frac{x - x_{\min}}{x_{\max} - x_{\min}} (y_{\max} - y_{\min}), \quad (7)$$

式中: y_{\max} 和 y_{\min} 分别代表对目标值进行归一化的上界和下界,取值为 $[0, 1]$; x_{\max} 为归一化特征的最大值, x_{\min} 为相应的最小值。

再将预测结果等值加权后进行反归一化处理,计算式为

$$x_i = \frac{(x_i' + 1)(x_{\max} - x_{\min})}{2} + x_{\min} \quad (8)$$

4.2 融合特征的选择

在选择数据集的特征进行前端融合时,理想状态是特征间有互补性、特征与功率间有强相关性。因此,首先对影响光伏发电的众多预选因素进行距离相关系数计算,结果如图 3 所示。

图 3 中,大气温度、模块温度、太阳辐照度、电流、电压和云量的距离相关系数均在 0.6 以上,相关性较强,不适合作为前端融合的输入特征。因此,分析后决定保留湿度、太阳方位角、风速、太阳入射角作为备选融合特征。为进一步进行特征筛选,利用最大互信息系数判断相关性,结果如图 4 所示。

从图 4 可知,云量、太阳方位角和风速基本与其他特征无关,大气温度只和模块温度有强相关关系,而模块温度、太阳辐照度、电流和电压互为强相关。通过这些分析,决定将云量、太阳方位角、风速和大气温度列为备选融合特征,而其他强相关项只选其一即可。

综合 DCC、MIC 值,湿度、太阳方位角、风速、太阳入射角、云量和大气温度均具有强互补性。而针对强相关特征如模块温度、太阳辐照度、电流和电压等,选用 PCC 进行进一步的筛选,结果如图 5 所示。图 5 中,强相关项中太阳辐照度的 PCC 值稍小于模块温度、电压和电流的 PCC 值,因此选用太阳辐照度

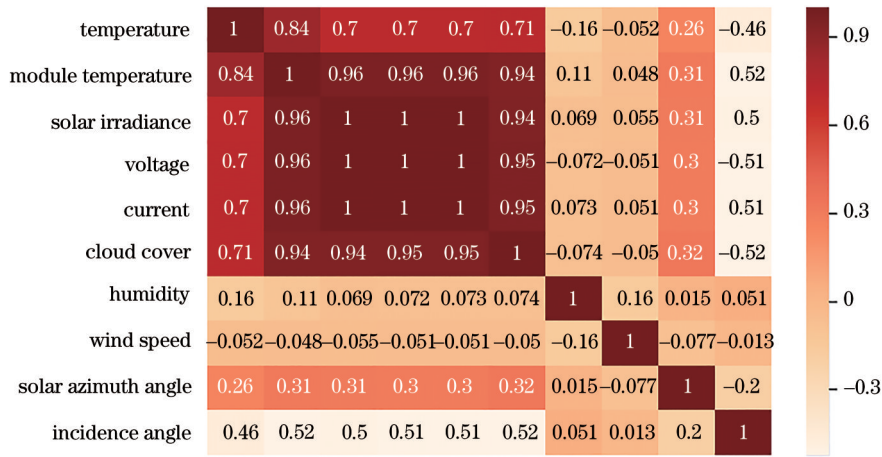


图 3 距离相关系数

Fig. 3 Distance correlation coefficient

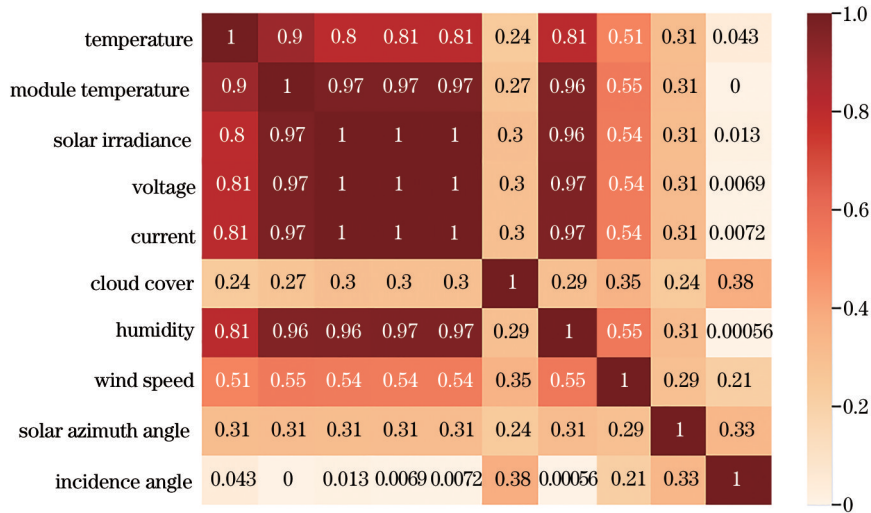


图 4 最大互信息系数

Fig. 4 Maximum mutual information coefficient




图 5 Pearson 相关系数

Fig. 5 Pearson correlation coefficient

作为强相关项的代表进行特征融合。

通过对 DCC、MIC 和 PCC 值的分析,满足融合的互补性特征有湿度、太阳方位角、风速、太阳入射角、云量、大气温度和太阳辐照度。此后,对各影响

因素与功率之间的相关性进行分析,对影响光伏发电的预选因素与功率进行距离相关系数的计算,结果如表 1 所示。

表 1 光伏发电功率与其他特征的相关性分析

Table 1 Analysis of the correlation between photovoltaic power generation and other characteristics

Parameter	Temperature	Module temperature	Solar irradiance	Voltage	Current	Cloud cover	Humidity	Wind speed	Solar azimuth angle	Incidence angle
PCC	0.3925	0.4610	0.4726	0.4725	0.4725	0.4592	-0.0488	-0.0158	0.1593	-0.2899
DCC	0.6042	0.6687	0.6515	0.6513	0.6571	0.3115	0.6415	0.4527	0.4342	0.4537
MIC	0.5304	0.8579	0.9915	0.9843	0.9894	0.8941	0.9745	0.1477	0.9204	0.9742

以 DCC 值分析,与功率强相关的有模块温度、电流、太阳辐照度、电压和大气温度;以 MIC 值分析,与功率强相关的有太阳辐照度、电流、电压、湿度、太阳入射角、太阳方位角和模块温度。汇总来看,模块温度、电流、太阳辐照度、电压、大气温度、湿度、太阳入射角和太阳方位角均为强相关。以 PCC 值分析,强相关特征中太阳辐照度相关系数最高。因此,满足与功率强相关的有太阳辐照度、大气温度、湿度、太阳入射角和太阳方位角。

综合特征互补性和与功率的强相关性,最终选用湿度、太阳方位角、太阳入射角、云量、大气温度和太阳辐照度进行前端融合,形成一维数据作为模型的输入。

4.3 模型训练

使用选出的融合特征进行模型训练。设置训练参数:总迭代次数为 100,初始学习率为 0.0003,学习率全程采用恒值,使用 MSE 损失,利用 Adam 优化策略。分别保存经典算法 LSTM、GRU、1D-CNN、TCN 和所提算法训练时的损失值,训练结束后调用日志文件进行损失动态趋势展示,如图 6 所示。

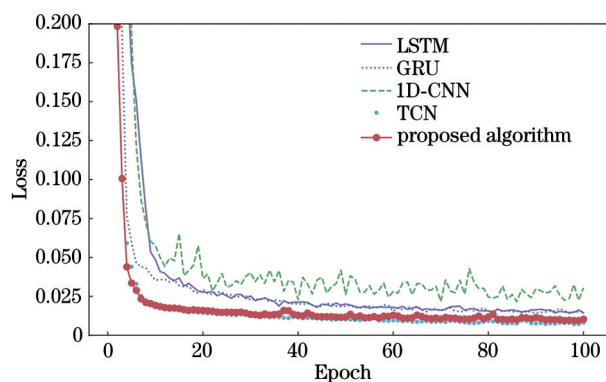


图 6 不同神经网络模型的迭代损失过程

Fig. 6 Iterative loss process of different neural network models

由图 6 可知,相比其他经典算法,所提算法能在更早的时间收敛,更快达到稳定值。稳定收敛后的损失值比经典算法的损失值更小,这表明所提算法具有更好的拟合效果,训练时在精度上具有一定优势。

4.4 模型测试

为验证所提算法的有效性,使用经典算法 LSTM、GRU、1D-CNN、TCN 和所提算法进行测试,分别选择多云、晴、晴转多云和小雨转多云天气的日期进行光伏发电功率预测,预测结果如图 7 所示。

观察曲线可知,所提算法的预测值与功率实际值十分接近,在不同天气下该模型能很好地拟合功率变化,尤其在峰值部分,能很好地跟随功率的阶跃变化。随机选择某一多云、晴、晴转多云和小雨转多云天气的日期,计算不同误差值,结果如表 2 所示。

从表 2 可知:在四种天气下,所提算法的决定系数明显高于其他算法,且误差值最小,具有较高的拟合度和泛化能力;在晴天和多云较稳定天气状况下,不同算法的决定系数 r^2 的变化值较小,基本看不出太大差距,而在晴转多云和小雨转多云不稳定天气下,决定系数差距明显,所提算法依然保持在最高水平,且误差值也最小。这表明,所提算法在极端天气情况下精度不稳问题上具有一定的适用性。

4.5 对比实验

为体现所提算法的有效性,对经典算法 LSTM、GRU、1D-CNN、TCN 和所提算法分别进行两种对比实验:特征融合前后的效果对比和经典算法的误差值对比,用于验证特征融合和网络改进的效果。

针对所选的融合特征,对经典算法进行融合前后的效果对比,结果如表 3 所示。其中,LSTM-R 指

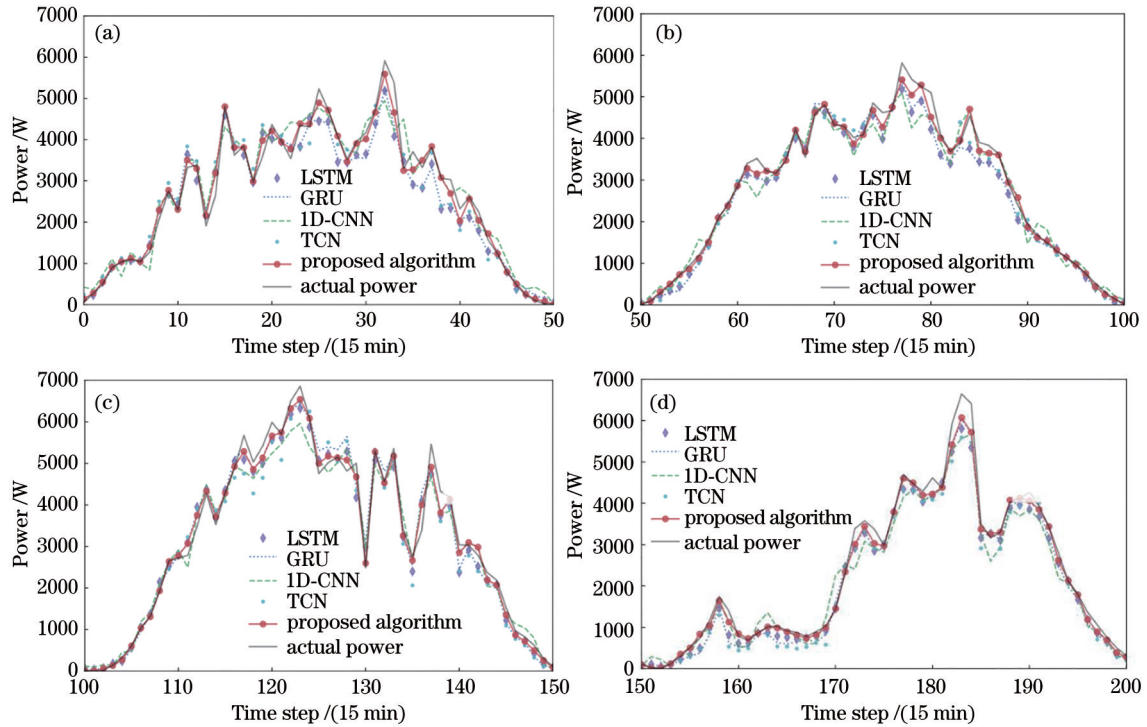


图 7 不同天气下的模型预测。(a)多云;(b)晴;(c)晴转多云;(d)小雨转多云

Fig. 7 Model prediction under different weather. (a) Cloudy; (b) sunny; (c) sunny to cloudy; (d) light rain to cloudy

表 2 不同天气下的模型指标

Table 2 Model indicators under different weather conditions

Weather	Model	MAE	RMSE	MAPE	r^2
Cloudy	LSTM	384.335	642.671	20.192	0.905
	GRU	345.204	600.387	18.907	0.917
	1D-CNN	457.634	595.407	6.113	0.918
	TCN	290.931	431.454	9.643	0.957
	Proposed	200.885	310.366	4.318	0.979
Sunny	LSTM	302.201	497.337	17.201	0.943
	GRU	277.025	478.866	13.126	0.947
	1D-CNN	314.923	472.902	11.843	0.948
	TCN	232.694	351.677	5.683	0.971
	Proposed	192.175	326.938	3.751	0.976
Sunny to cloudy	LSTM	423.528	714.623	23.112	0.883
	GRU	416.409	642.681	17.058	0.905
	1D-CNN	432.407	714.425	19.201	0.883
	TCN	360.379	602.137	19.091	0.917
	Proposed	338.439	535.395	14.918	0.934
Light rain to cloudy	LSTM	372.363	613.397	20.194	0.913
	GRU	366.87	574.832	15.933	0.924
	1D-CNN	584.657	945.496	27.932	0.795
	TCN	334.873	516.787	10.691	0.939
	Proposed	298.706	479.917	11.999	0.947

经特征融合后的模型,以此类推,对 GRU、1D-CNN、TCN 和 Proposed 依次命名。

由表 3 可见,融合操作后,各算法的误差指标 MAE、RMSE 和 MAPE 值明显减小。各算法融合

表 3 不同模型融合前后对比

Table 3 Comparison of different models before and after fusion

Model	MAE	RMSE	MAPE	r^2	Time /s
LSTM	301.361	618.115	14.952	0.868	150
LSTM-R	180.943	292.308	3.935	0.979	79
GRU	298.494	595.763	14.751	0.876	114.4
GRU-R	178.457	300.641	3.099	0.98	72.4
1D-CNN	325.815	614.318	16.334	0.866	77.2
1D-CNN-R	265.65	375.654	5.413	0.967	55
TCN	306.436	591.91	14.131	0.878	47.6
TCN-R	164.049	287.174	2.505	0.981	34
Proposed	298.865	585.988	13.985	0.880	42.4
Proposed-R	160.496	277.396	2.402	0.982	30

后决定系数 r^2 均提升近 0.10, 其中 Proposed-R 的决定系数最高, 达 0.982, 这表明所提算法在预测精度上具有优势。由于融合后的输入特征较原始特征量小, 预测时间的缩短是必然现象。经过特征融合后, 各算法的训练时间均有减少, 时间缩减 13.4%~47.3%, 其中 Proposed-R 时间花费最少, 训练时间只需花费 30 s, 这表明所提算法在预测效率上具有优势。

为显示所提算法的先进性与有效性, 选择 LSTM、GRU、1D-CNN 和 TCN 进行误差对比, 利用模型预测值与实际功率值的差距大小直观体现模型的鲁棒性能, 误差结果如图 8 所示。

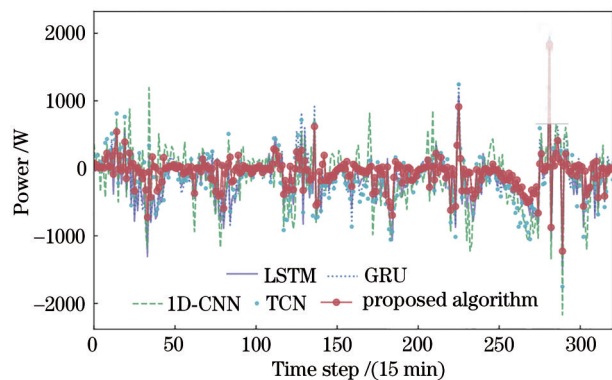


图 8 经典算法的误差对比

Fig. 8 Error comparison of classical algorithms

所提算法对应的模型在误差分析图中的波动幅度最小, 尤其是在波峰和波谷处。这表明, 相对于其他经典算法, 所提算法具有更强的稳定性和鲁棒性。从数值上看, 所提算法对应的模型在 0 水平线上的频次明显高于其他经典算法, 且最高和最低的幅值都比其他算法小。这表明, 所提算法的预测

精度明显更高。

5 结 论

针对光伏发电功率预测任务, 提出一种结合特征融合和改进 TCN 的方法, 得到了预测精度为 0.982、训练时间为 30 s 的优秀模型, 该模型对电网调度、资源配置和环境保护等工作做出了一定贡献。经特征融合结合改进的 TCN 模型在时序特征的预测任务中的预测精度比循环神经网络系列模型更高, 且用时更短。特征融合能够对循环神经网络系列算法、一维卷积和 TCN 进行精度和速度上的提升, 预测任务中, 融合后的经典算法相比融合前在决定系数上提升最高达 0.116, 训练时间上最多减少 47.3%。在大容量的数据分析中, 所提算法繁杂的工作有时也会造成不够准确和遗漏的结果, 针对此, 使用注意力机制或者自学习模型或有所成效, 接下来的工作将致力于更加精确的数据处理。

参 考 文 献

- [1] Zhang W D, Liu Z M, Wang Z Z, et al. Economic comparison among multiple schemes of photovoltaic flexible grid-connection based on annual irradiance data[J]. Electric Power Automation Equipment, 2014, 34(9): 123-129, 136.
张卫东, 刘祖明, 王振洲, 等. 基于全年辐照数据的多路径光伏柔性并网的经济性对比[J]. 电力自动化设备, 2014, 34(9): 123-129, 136.
- [2] Law E W, Prasad A A, de Kay M, et al. Direct normal irradiance forecasting and its application to concentrated solar thermal output forecasting-a review [J]. Solar Energy, 2014, 108: 287-307.
- [3] Benmouiza K, Cheknane A. Small-scale solar radiation forecasting using ARMA and nonlinear autoregressive neural network models[J]. Theoretical and Applied Climatology, 2016, 124(3/4): 945-958.
- [4] Bai Q F, Lin Y J, Yang K, et al. Photovoltaic power prediction considering the influence of atmospheric particles on irradiance[J/OL]. China Measurement & Test: 1-8[2021-12-19]. <http://kns.cnki.net/kcms/detail/51.1714.TB.20211201.1532.020.html>.
白青飞, 林永君, 杨凯, 等. 考虑大气颗粒物对辐照度影响的光伏功率预测[J/OL]. 中国测试: 1-8[2021-12-19]. <http://kns.cnki.net/kcms/detail/51.1714.TB.20211201.1532.020.html>.
- [5] Jiang Y J. Modeling of photovoltaic cells and its application in energy prediction[D]. Wuhan:

- Huazhong University of Science and Technology, 2011.
蒋亚娟. 光伏电池建模及其在光伏发电预测中的应用[D]. 武汉: 华中科技大学, 2011.
- [6] Zhao W J, Zhang N, Kang C Q, et al. A method of probabilistic distribution estimation of conditional forecast error for photovoltaic power generation[J]. Automation of Electric Power Systems, 2015, 39(16): 8-15.
赵唯嘉, 张宁, 康重庆, 等. 光伏发电出力的条件预测误差概率分布估计方法[J]. 电力系统自动化, 2015, 39(16): 8-15.
- [7] Li C L, Zhu H M, Jing M D, et al. Discussion on power prediction method of grid-connected PV power station[J]. Electric Engineering, 2010(12): 27-28.
李春来, 朱慧敏, 景满德, 等. 并网型光伏电站功率预测方法探讨[J]. 电工技术, 2010(12): 27-28.
- [8] Yadav H K, Pal Y, Tripathi M M. Photovoltaic power forecasting methods in smart power grid[C]// 2015 Annual IEEE India Conference (INDICON), December 17-20, 2015, New Delhi, India. New York: IEEE Press, 2015: 15888335.
- [9] Cheng W Y Y, Liu Y B, Bourgeois A J, et al. Short-term wind forecast of a data assimilation/weather forecasting system with wind turbine anemometer measurement assimilation[J]. Renewable Energy, 2017, 107: 340-351.
- [10] Ma T, Yang H X, Lu L. Solar photovoltaic system modeling and performance prediction[J]. Renewable and Sustainable Energy Reviews, 2014, 36: 304-315.
- [11] Masseran N, Razali A M, Ibrahim K, et al. Fitting a mixture of von Mises distributions in order to model data on wind direction in Peninsular Malaysia[J]. Energy Conversion and Management, 2013, 72: 94-102.
- [12] Guan L, Zhao Q, Zhou B R, et al. Multi-scale clustering analysis based modeling of photovoltaic power characteristics and its application in prediction [J]. Automation of Electric Power Systems, 2018, 42(15): 24-30.
管霖, 赵琦, 周保荣, 等. 基于多尺度聚类分析的光伏功率特性建模及预测应用[J]. 电力系统自动化, 2018, 42(15): 24-30.
- [13] Zhou J Y, Shi J, Li G. Fine tuning support vector machines for short-term wind speed forecasting[J]. Energy Conversion and Management, 2011, 52(4): 1990-1998.
- [14] Goodfellow I, Bengio Y, Courville A. Deep learning [M]. Cambridge: The MIT Press, 2016.
- [15] Wang Y F, Fu Y C, Sun L, et al. Ultra-short term prediction model of photovoltaic output power based on chaos-RBF neural network[J]. Power System Technology, 2018, 42(4): 1110-1116.
王育飞, 付玉超, 孙路, 等. 基于混沌-RBF神经网络的光伏发电功率超短期预测模型[J]. 电网技术, 2018, 42(4): 1110-1116.
- [16] Yao H M, Du X H, Qin W P. PV power forecasting approach based on density peaks clustering and general regression neural network[J]. Acta Energetica Solaris Sinica, 2020, 41(9): 184-190.
姚宏民, 杜欣慧, 秦文萍. 基于密度峰值聚类及GRNN神经网络的光伏发电功率预测方法[J]. 太阳能学报, 2020, 41(9): 184-190.
- [17] Zhang Q, Ma Y, Li G L, et al. Applications of frequency domain decomposition and deep learning algorithms in short-term load and photovoltaic power forecasting[J]. Proceedings of the CSEE, 2019, 39(8): 2221-2230.
张倩, 马愿, 李国丽, 等. 频域分解和深度学习算法在短期负荷及光伏功率预测中的应用[J]. 中国电机工程学报, 2019, 39(8): 2221-2230.
- [18] Cao S Q, Hao W J, Wang H, et al. Prediction of effective wind speed at hub of wind turbine based on lidar-Armax[J]. Laser & Optoelectronics Progress, 2020, 57(17): 171407.
曹松青, 郝万君, 王昊, 等. 基于激光雷达-Armax的风机轮毂处有效风速预测[J]. 激光与光电子学进展, 2020, 57(17): 171407.
- [19] Gao X D, Hu C H, Zhang J X, et al. Adaptive prediction of remaining useful life for optoelectronic equipment based on nonlinear fractional Brownian motion[J]. Acta Optica Sinica, 2020, 40(24): 2423001.
高旭东, 胡昌华, 张建勋, 等. 基于非线性分数布朗运动的光电设备剩余寿命自适应预测[J]. 光学学报, 2020, 40(24): 2423001.
- [20] Guo H M, Wu B J, Jiang X R, et al. Research on detection method of modal power using photonic lantern[J]. Acta Optica Sinica, 2022, 42(1): 0106003.
郭浩森, 武保剑, 江歆睿, 等. 基于光子灯笼的模式功率检测方法研究[J]. 光学学报, 2022, 42(1): 0106003.
- [21] Sun Z Q, Li D Y. Prediction model of photovoltaic power generation based on time-frequency entropy and neural network[J]. Journal of Central South University (Science and Technology), 2020, 51(1): 221-230.
孙志强, 李东阳. 基于时频熵和神经网络的光伏发电

- 功率预测模型[J]. 中南大学学报(自然科学版), 2020, 51(1): 221-230.
- [22] Wang C Y, Duan Q Q, Zhou K, et al. A hybrid model for photovoltaic power prediction of both convolutional and long short-term memory neural networks optimized by genetic algorithm[J]. *Acta Physica Sinica*, 2020, 69(10): 20191935.
王晨阳, 段倩倩, 周凯, 等. 基于遗传算法优化卷积长短记忆混合神经网络模型的光伏发电功率预测[J]. *物理学报*, 2020, 69(10): 20191935.
- [23] Zaremba W, Sutskever I, Vinyals O. Recurrent neural network regularization[EB/OL]. (2014-09-08) [2019-07-21]. <https://arxiv.org/abs/1409.2329v5>.
- [24] Niu Z W, Yu Z Y, Li B, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. *Electric Power Automation Equipment*, 2018, 38(5): 36-42.
牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. *电力自动化设备*, 2018, 38(5): 36-42.
- [25] Cho K, van Merriënboer B, Bahdanau D, et al. On the properties of neural machine translation: encoder-decoder approaches[C]//*Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation*, October 25, 2014, Doha, Qatar. Stroudsburg: Association for Computational Linguistics, 2014: 103-111.
- [26] Qiao Y, Sun R F, Ding R, et al. Distributed photovoltaic station cluster short-term power forecasting part II: gridding prediction[J]. *Power System Technology*, 2021, 45(6): 2210-2218.
乔颖, 孙荣富, 丁然, 等. 基于数据增强的分布式光伏电站群短期功率预测(二): 网格化预测[J]. *电网技术*, 2021, 45(6): 2210-2218.
- [27] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. (2018-04-19)[2019-07-21]. <https://arxiv.org/abs/1803.01271>.
- [28] Li B, Lu M Z. Short-term load forecasting modeling of regional power grid considering real-time meteorological coupling effect[J]. *Automation of Electric Power Systems*, 2020, 44(17): 60-68.
李滨, 陆明珍. 考虑实时气象耦合作用的地区电网短期负荷预测建模[J]. *电力系统自动化*, 2020, 44(17): 60-68.
- [29] Gan Z H, Li C S, Zhou J Z, et al. Temporal convolutional networks interval prediction model for wind speed forecasting[J]. *Electric Power Systems Research*, 2021, 191: 106865.
- [30] Lara-Benítez P, Carranza-García M, Luna-Romera J M, et al. Temporal convolutional networks applied to energy-related time series forecasting[J]. *Applied Sciences*, 2020, 10(7): 2322.
- [31] Li K, Li X Y, Chen S, et al. Analysis oneability of damping HVDC-induced sub synchronous oscillation by photovoltaic grid-connection [J]. *Electric Power Automation Equipment*, 2015, 35(3): 41-46.
李宽, 李兴源, 陈实, 等. 光伏并网抑制由直流输电引起的次同步振荡的可行性分析[J]. *电力自动化设备*, 2015, 35(3): 41-46.
- [32] Reshef D N, Reshef Y A, Finucane H K, et al. Detecting novel associations in large data sets[J]. *Science*, 2011, 334(6062): 1518-1524.
- [33] Székely G J, Rizzo M L, Bakirov N K. Measuring and testing dependence by correlation of distances[J]. *The Annals of Statistics*, 2007, 35(6): 2769-2794.
- [34] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB/OL]. (2015-11-23)[2019-07-21]. <http://arxiv.org/abs/1511.07122v1>.
- [35] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//*2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [36] Kalogirou S A. Artificial neural networks in renewable energy systems applications: a review[J]. *Renewable and Sustainable Energy Reviews*, 2001, 5(4): 373-401.