

文章编号:1673-9469(2026)01-0072-09

DOI:10.3969/j.issn.1673-9469.2026.01.010

基于 CNN-GRU-BiLSTM-AM 的超短期光伏功率预测

袁媛媛,陈继强*,王旭,马丽涛

(河北工程大学 数理科学与工程学院,河北 邯郸 056038)

摘要: 为提升超短期光伏功率预测精度,提出了一种基于卷积神经网络-门控循环单元-双向长短期记忆神经网络-注意力机制(CNN-GRU-BiLSTM-AM)的组合预测模型。首先,为提升数据质量,对数据的异常值进行处理,采用 Spearman 相关系数、灰色关联分析提取影响光伏功率的关键特征;其次,为获取光伏功率数据的时空特征,分别利用 CNN 和 GRU 提取空间和时间维度上的局部特征,利用 BiLSTM 捕捉时间序列中的长期依赖关系;再次,为获取关键历史时间点的重要信息,引入 AM,构建了 CNN-GRU-BiLSTM-AM 预测模型。最后,结合公开的光伏功率数据集进行对比实验。结果显示,构建的预测模型决定系数为 99.1%,均方根误差为 0.032 5,平均绝对误差为 0.026 6,表明该方法有效提高了光伏功率的预测精度。

关键词: 超短期光伏功率预测;卷积神经网络;门控循环网络;双向长短期记忆网络;注意力机制

中图分类号:TM615

文献标识码:A

Ultra-short-Term Photovoltaic Power Prediction Based on CNN-GRU-BiLSTM-AM

YUAN Yuanyuan, CHEN Jiqiang*, WANG Xu, MA Litao

(School of Mathematics and Physics, Hebei University of Engineering, Handan, Hebei 056038, China)

Abstract: To improve the ultra-short-term prediction accuracy of photovoltaic power, a hybrid prediction model based on CNN-GRU-BiLSTM-AM was proposed. First, to improve data quality, outliers were processed, and the Spearman's rank correlation coefficient and grey relational analysis were used to extract the key features affecting photovoltaic power. Second, to obtain the spatiotemporal features of photovoltaic power data, the local features in the spatial and temporal dimensions were respectively extracted by CNN and GRU, and the long-term dependence relationships in the time series were captured by BiLSTM. Third, to obtain the important information of key historical time points, the Attention Mechanism (AM) was introduced, and the CNN-GRU-BiLSTM-AM prediction model was constructed. Finally, comparative experiments were conducted using a publicly available photovoltaic power dataset. The results show that the prediction model constructed in this study has a coefficient of determination of 99.1%, a root mean square error (RMSE) of 0.032 5, and a mean absolute error (MAE) of 0.026 6, indicating that the method effectively improves the prediction accuracy of photovoltaic power.

Key words: ultra-short-term photovoltaic power prediction; convolutional neural networks; gated recurrent unit; bidirectional long short-term memory network; attention mechanism

光伏发电是指利用太阳能辐射直接转变成电能的发电方式,光伏发电作为一种清洁、可再生的绿色能源,对推动能源结构转型具有重要战略意

义。然而,光伏系统的发电功率受辐照度、温度、风速等天气因素的显著影响^[1-2],这些因素具有非线性、随机性和复杂性,导致发电功率难以精准预

收稿日期:2024-08-28

基金项目:国家自然科学基金资助项目(62006068);河北省高等学校科学研究项目(ZD2020185, QN2020188);中央引导地方科技发展资金资助项目(246Z1825G)

第一作者:袁媛媛(1999—),女,河南漯河人,硕士研究生,从事机器学习、人工智能理论在能源领域的应用研究。

*通信作者:陈继强(1982—),男,河北保定人,博士(后),教授,从事机器学习、人工智能理论及其在能源、水利等领域的应用研究。

测。此外,数据质量问题,包括数据缺失、异常数据等,也制约了预测的精准性。这一系列影响因素在降低光伏功率预测精度的同时,也给制定可靠的电力规划和运营策略带来了困难^[3]。

随着物联网和大数据技术的快速发展,光伏发电站可以实时监测和记录大量影响发电的环境参数。在光伏功率预测领域,超短期光伏功率预测(15 min~4 h)尤其具有实用价值^[4-5]。目前,国内外常用的浅层预测模型有极限学习机^[6]、支持向量机^[7]、自回归移动平均模型^[8],但这类模型在挖掘功率数据和其影响因素之间的潜在关系方面存在局限,而且算法收敛速度慢,训练时间长,难以满足实时预测需求。

为此,学者将卷积神经网络(Convolutional Neural Networks, CNN)^[9]、门控循环单元(Gated Recurrent Unit, GRU)^[10]等深度学习算法应用于光伏功率预测,验证了基于深度学习的预测模型比浅层预测模型更能挖掘影响因素与功率数据间的关系。例如,文献[11]针对负荷数据时序性的特点,提出了一种基于贝叶斯优化的 CNN-GRU 短期电力负荷预测模型,但在提取时间序列数据中的长期依赖关系方面仍有欠缺;在数据处理方面,只进行了缺失值处理,没有进行异常值处理,这会对预测精度造成一定的影响。文献[12]基于 GRU 和双向长短期记忆神经网络(Bidirectional Long Short-Term Memory Network, BiLSTM)建立了用于中长期光伏功率预测的混合模型,其预测效果优于单一模型和其他混合模型,但该模型未能提取光伏功率数据在空间维度上的局部特征,且上述模型都忽略了时间序列输入数据所隐藏的关键信息,会对预测精度产生影响。文献[13]首先结合 CNN 和 BiLSTM 提取光伏功率数据的时空特征,接着引入注意力机制(Attention Mechanism, AM)突出关键历史时间点的信息,提升了预测精度,但却增加了模型的训练参数和时间。文献[10]采用 GRU 模型对光伏功率进行预测,验证了 GRU 可以减少训练参数和训练时间,但在预测精度上还有待提升。

综上所述, CNN、GRU、BiLSTM 等深度学习算法在光伏功率预测中得到了较好的应用。然而,深度学习的组合模型在光伏功率预测中的应用大多没有深度挖掘数据中隐含的信息,尤其难以应对实际中超短期光伏功率预测易受辐照度、温度、风速等多种天气条件影响的问题,使得预测精度

仍难以满足实际需求。本文为了提高超短期光伏功率的预测精度,更全面地提取数据的时空特征和关键历史信息,首先利用四分位法处理数据的异常值,接着采用 Spearman 相关系数和灰色关联分析筛选关键特征。其次,利用 CNN 提取光伏功率数据在空间维度上的局部特征,GRU 提取时间维度上的关联信息,BiLSTM 捕捉时间序列数据中的长期依赖关系。再次,为获取关键历史时间点的重要信息,引入注意力机制,构建了 CNN-GRU-BiLSTM-AM 预测模型。最后,在公开的光伏功率数据集上进行对比实验验证模型的有效性,从而为电网制定可靠的电力规划和运营策略提供借鉴和参考。

1 模型理论

1.1 卷积神经网络

卷积神经网络作为一种特殊的前馈神经网络,主要由卷积层、池化层和全连接层构成,其中卷积层扮演着核心和关键的角色^[14]。本文重点利用卷积层中的卷积核,对光伏功率数据进行有效的非线性局部特征提取。CNN 模型如图 1 所示。根据特征数和时间步长确定 CNN 模型的输入,通过一维卷积层 Conv1D 在光伏功率数据上应用卷积操作,提取空间维度上的局部特征。




图 1 CNN 模型
Fig. 1 CNN model

1.2 门控循环单元

门控循环单元 GRU 通过引入更新门和重置门两个门控向量来确定将哪些信息作为输出传递到下一时刻。相比其他门控机制,GRU 可以很好地保留长时间序列信息,不会受时间推移影响,也不会因为和预测不相关被删除^[15]。GRU 结构如图 2 所示。其中 x_t 为第 t 个时间步的输入向量, h_{t-1} 是前一个时间步 $t-1$ 的隐含状态。更新门 Z_t 用来控制信息的流入,重置门 r_t 用来确定所要保留与遗忘的信息, h_t 为当前时间步 GRU 的隐含输出状态, h_t 作为最终 GRU 的输出^[16]。

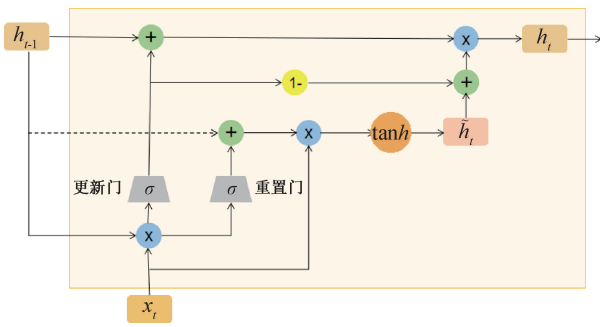


图2 GRU 结构

Fig. 2 Structure diagram of GRU

1.3 双向长短期记忆神经网络

双向长短期记忆网络^[17] (BiLSTM) 结合长短期记忆神经网络 (Long Short-Term Memory Network, LSTM) 的优点, 能够同时处理正向和反向的输入顺序。这种双向结构使得网络可以同时考虑过去和未来的信息, 从而更全面地捕捉时间序列中的长期依赖关系。BiLSTM 结构如图 3 所示。首先, 从正向序列出发, 将正向层中的数据传输给正向层, 正向层存储各时刻的数据。在此基础上, 逆序被输入到反向层, 在此过程中, 每一次的输出都被保存下来。最后, 将正向与反向层的对应输出组合起来, 就可以获得最终的结果^[18]。




图3 BiLSTM 结构图

Fig. 3 Structure diagram of BiLSTM

1.4 注意力机制

注意力机制 (AM) 的主要思想来自于人类视觉注意, 人类视觉可以快速找到关键区域, 并在关键区域添加注意焦点, 以获得所需的详细信息。

类似地, 对于时序数据, AM 会记录每个隐藏状态并生成一个序列, 它会将最终输出与该序列相关联, 并根据与不同隐藏状态之间的相关性, 进行有选择地学习^[17]。AM 的计算过程一般分为三个阶段:

(1) 输出特征和输入特征之间相似性或相关性的计算如式(1)所示:

$$s_t = \tanh(W_h \cdot h_t + b_h) \quad (1)$$

式中: W_h —AM 的权重; b_h —AM 的偏置项; h_t —输入向量。 W_h 和 b_h 在每一层中共享权重。

(2) 对第一步的分数进行归一化, 并使用 softmax 函数进行转换, 如式(2)所示:

$$a_t = \frac{\exp(s_t^T v)}{\sum_i \exp(s_i^T v)} \quad (2)$$

式中: v —注意力值。

(3) 根据注意力权重系数, 通过注意力权重加权求和之后获得综合注意力值 s , 如式(3)所示:

$$s = \sum_i a_i h_i \quad (3)$$

2 光伏功率数据来源及处理

2.1 数据来源

光伏功率输出数据集 (Photovoltaic Power Output Dataset, PVOD)^[19] 记录了河北省 10 座光伏电站的历史发电信息。本文以发电站 ID 为 station00、装机容量为 6 600 kW、铺设光伏板总数为 26 000 个的光伏发电站历史数据为例, 记录时间区间为 2018 年 8 月 15 日—2019 年 6 月 13 日, 时间分辨率为 15 min, 共计 28 896 条数据。数据集特征及含义如表 1 所示。

2.2 数据预处理

光伏组件工作异常、定期维护以及数据采集装置故障会导致数据缺失或异常, 使得原始数据

表 1 原始数据集变量说明

Tab. 1 Description of variables of the original dataset

变量	描述	变量	描述
power	发电站的光伏输出	nwp_pressure	NWP 的气压
nwp_globalirrad	NWP 的全球辐照度	lmd_totalirrad	LMD 的全球辐照度
nwp_directirrad	NWP 的直接辐照度	lmd_diffuseirrad	LMD 的散射辐照度
nwp_temperature	NWP 的 10 m 干球温度	lmd_temperature	LMD 的温度
nwp_humidity	NWP 的 10 m 相对湿度	lmd_pressure	LMD 的气压
nwp_windspeed	NWP 的 10 m 风速	lmd_winddirection	LMD 的风向
nwp_winddirection	NWP 的 10 m 风向	lmd_windspeed	LMD 的风速

注: 数据名称中 NWP 表示数值天气预报, LMD 表示本地测量数据。

中出现缺失值或异常值,为避免这些不良数据对模型预测带来的不利影响,进行了以下数据处理工作:(1)对原始数据表中的数据进行缺失值检测,经检测数据中不存在缺失值,故不再进行缺失值的处理;(2)采用四分位法对数据进行异常值检测,并查看异常值的个数,具体数量见表 2,将检测出的异常值删除后进行填补以补全数据集,考虑到数据之间存在时序关系,使用上一个有效值代替异常值的方法进行修正。

表 2 异常数据数量

Tab. 2 Number of outliers

特征	数量
nwp_humidity	424
nwp_windspeed	573
lmd_diffuseirrad	874
lmd_pressure	61
lmd_windspeed	590

根据四分位法的步骤,将数据集从小到大排序,然后四等分,确定第一四分位数(Q1)、第三四分位数(Q3)和中间的四分位数即中位数(Q2)。Q1与Q3之间的范围称为四分位距(IQR)。将小于Q1-1.5×IQR或大于Q3+1.5×IQR的数据点定义为异常值。该方法不受极端值的显著影响,具有较高的鲁棒性。由于光伏功率数据通常随时间、天气等因素波动,分布形态不稳定,而该方法定义的异常值标准基于数据的中位数和四分位距,适用于非对称分布,可以有效识别光伏功率数据中的偏离点而不依赖特定的分布假设,故本文采用该方法进行异常值检测。

观察 PVOD 中发电站光伏输出的分布情况,发现其存在周期性变化。选择 2018 年 8 月 16 日 18:00 至 2018 年 8 月 17 日 18:00 的光伏功率并对其进行可视化,如图 4 所示。从图中可以得出,光伏功率稳定输出的时间段为 22:00—11:00。




图 4 光伏功率变化图

Fig. 4 Diagram of photovoltaic power variation

2.3 特征选择

2.3.1 Spearman 相关性分析

由于光伏系统发电功率受多种因素的影响,因此,在对其进行输入前,先对其进行特征筛选,可以有效提取与光伏功率变化密切相关的特征,减少输入特征的维度,从而降低计算的复杂度和模型训练的时间,提高模型预测精度。因此,使用相关性分析对原始数据集中的特征进行初步筛选。由于 Spearman 相关系数可用于任何长度相同的两组数据的相关性分析^[20],故本文选择使用 Spearman 相关系数进行相关性分析,计算公式为

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \quad (4)$$

式中: ρ 为相关系数,取值范围为-1~1。 ρ 的绝对值表示两个变量之间的相关性程度,绝对值越接近1说明相关性越强。对 PVOD 中的 13 个变量与目标变量功率 power 之间计算得到的 Spearman 相关系数绘制热力图,如图 5 所示。其中 nwp_wind-direction 和 power、lmd_winddirection 和 power 的相关系数最小,分别为 0.046 和 0.057,相关程度非常低,故不作为输入特征。剩余的 11 个特征都有不同程度的相关性,将其作为初步输入特征。另外, nwp_globalirrad、nwp_directirrad、lmd_totalirrad 和 lmd_diffuseirrad 与 power 的相关系数都达到了 0.9 以上,说明这 4 个特征与功率的相关性极高,对光伏功率的影响较大,对后续的模型预测有重要影响。

2.3.2 灰色关联分析

Spearman 相关性分析可以识别变量之间的单调关系。灰色关联分析可以发现隐藏的关联性,提取更多的特征信息,提高模型对数据的拟合能力。因此,基于上述结果,进一步使用灰色关联分析对选取的输入特征进行特征提取。灰色关联分析分为以下几个步骤:

(1)对数据进行无量纲化处理

在特征选择的基础上,采用 z-score 标准化的方法,将原始数据归一化,转化为[0,1]范围内的数据集。

$$z = \frac{x - \mu}{\sigma} \quad (5)$$

式中: x —原始数据; μ —均值; σ —标准差; z —标准化后的数据。

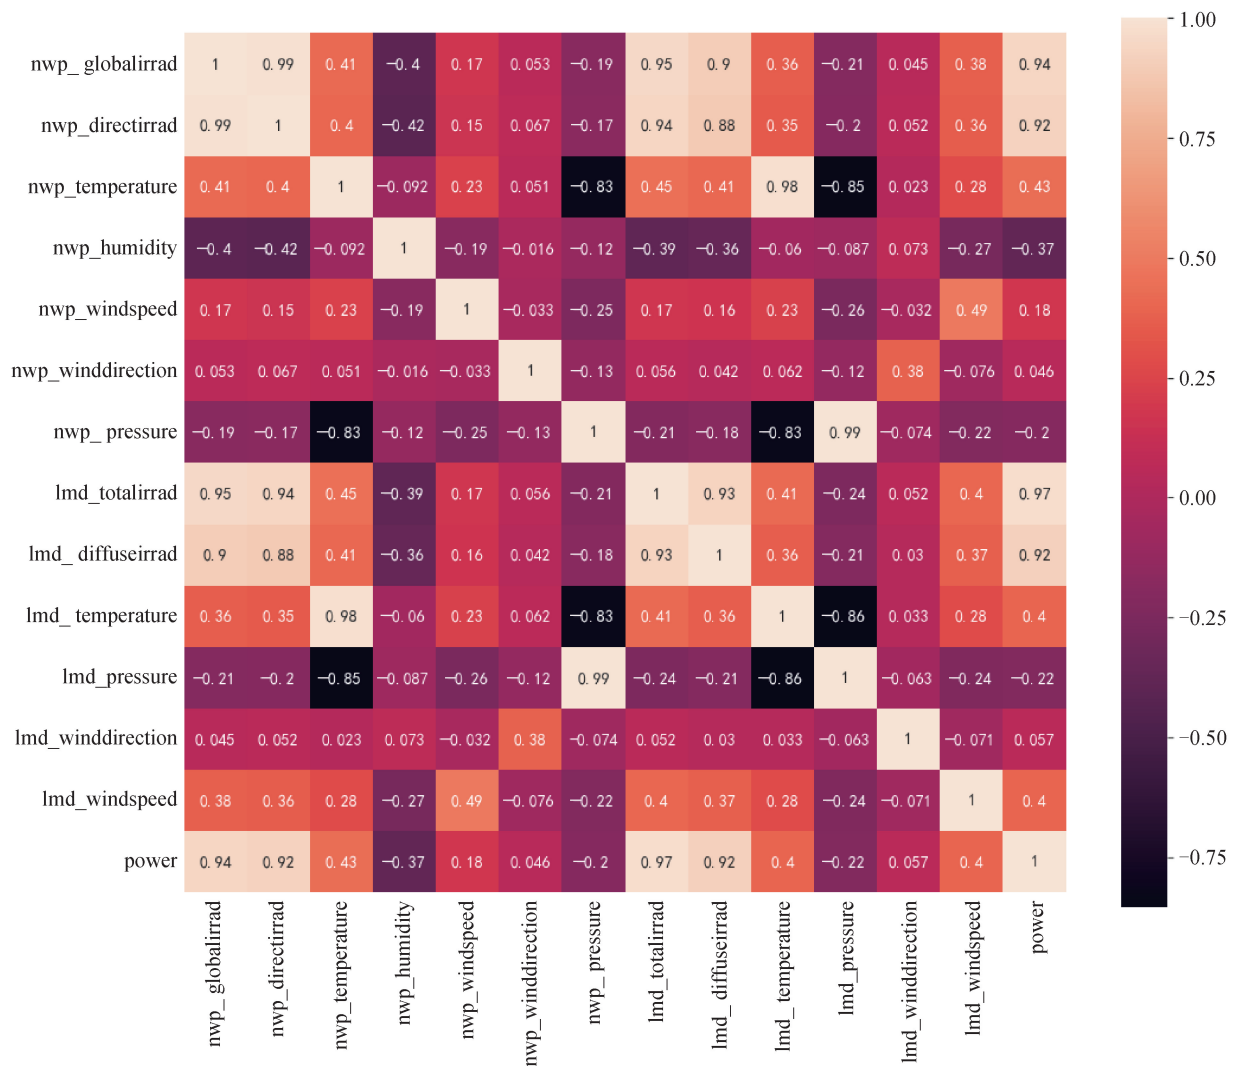


图5 Spearman 相关系数矩阵热力图

Fig. 5 Spearman's rank correlation coefficient matrix heatmap

(2) 确定分析数列

在光伏功率预测问题中,光伏功率反映了该系统的行为特征,因此选择光伏发电功率为参考序列,其余特征是影响光伏发电系统的因素,因此为比较序列。

(3) 计算比较序列中各指标与参考序列的关联系数

文献[21]将各指标的关联系数定义为灰色系数:

$$y(x_0(k), x_i(k)) = \frac{a + \rho'b}{|x_0(k) - x_i(k)| + \rho'b} \quad (i = 1, 2, \dots, m; k = 1, 2, \dots, n) \quad (6)$$

式中: a —两极最小差; b —两极最大差; ρ' —分辨系数(根据文献[22],一般取值为0.5)。

(4) 计算灰色关联度,并得出结论

对关联系数矩阵每列求均值得到灰色关联度 $y(x_0, x_i)$, 公式如下:

$$y(x_0, x_i) = \frac{1}{n} \sum_{k=1}^n y(x_0(k), x_i(k)) \quad (7)$$

得出上述所选取的11个变量和目标变量发电功率之间的灰色关联度并进行排序,结果如表3所示。

表3 各特征和发电功率之间的灰色关联度
Tab. 3 Grey correlation degree between each feature and power

特征	功率	特征	功率
lmd_totalirrad	0.929 4	lmd_temperature	0.678 6
nwp_directirrad	0.869 8	nwp_windspeed	0.678 0
nwp_globalirrad	0.864 4	nwp_humidity	0.661 1
lmd_diffuseirrad	0.846 8	nwp_pressure	0.658 7
lmd_windspeed	0.709 6	lmd_pressure	0.646 5
nwp_temperature	0.683 8		

关联度越高,表示该特征与目标变量的关联性越强。表3列出的特征与光伏功率 power 之间的关联性依次降低,对功率的影响也依次降低,参

照文献[23],设定关联度阈值为 0.7,即关联度在 0.7 以上的特征对光伏功率的影响较大。筛选出关联度高于该阈值的特征,分别为 lmd_totalirrad、nwp_globalirrad、nwp_directirrad、lmd_diffuseirrad 和 lmd_windspeed,这些特征被认为是关键因素,对光伏功率预测具有较大影响,因此选取上述 5 个特征作为最终的输入特征。

3 基于 CNN-GRU-BiLSTM-AM 的光伏功率预测模型

3.1 模型构建

基于上述 CNN、GRU、BiLSTM 和 AM 模型优势,提出一种基于 CNN-GRU-BiLSTM-AM 的超短期光伏功率预测模型,以提高光伏发电预测精度。CNN-GRU-BiLSTM-AM 预测模型工作过程示意图如图 6 所示。

构建步骤如下:

(1) 首先将预处理的光伏功率数据按照时间

先后顺序以 8 : 2 比例划分为训练集和测试集;

(2) 为提取光伏功率数据空间维度上的局部特征,将数据通过输入层传递到 CNN 卷积层,利用卷积操作和激活函数,有效提取数据中的局部特征;

(3) 通过 GRU 网络获取发电功率数据在时间维度上的关联信息。利用 GRU 的重置门和更新门机制保留光伏功率数据中的时间信息;

(4) 为获取时序数据的长期依赖关系,将提取完局部特征和时间信息的数据输入双向长短期记忆神经网络;

(5) 为突出关键历史时间点重要信息,将 BiLSTM 的输出作为 AM 层输入,通过 AM 第一、二阶段计算出光伏功率影响因素的注意力权重,权重值越大说明该特征在该时间点携带的信息越重要;

(6) 将上一步骤输出数据通过 Flatten 层连接全连接层输出得到预测结果。

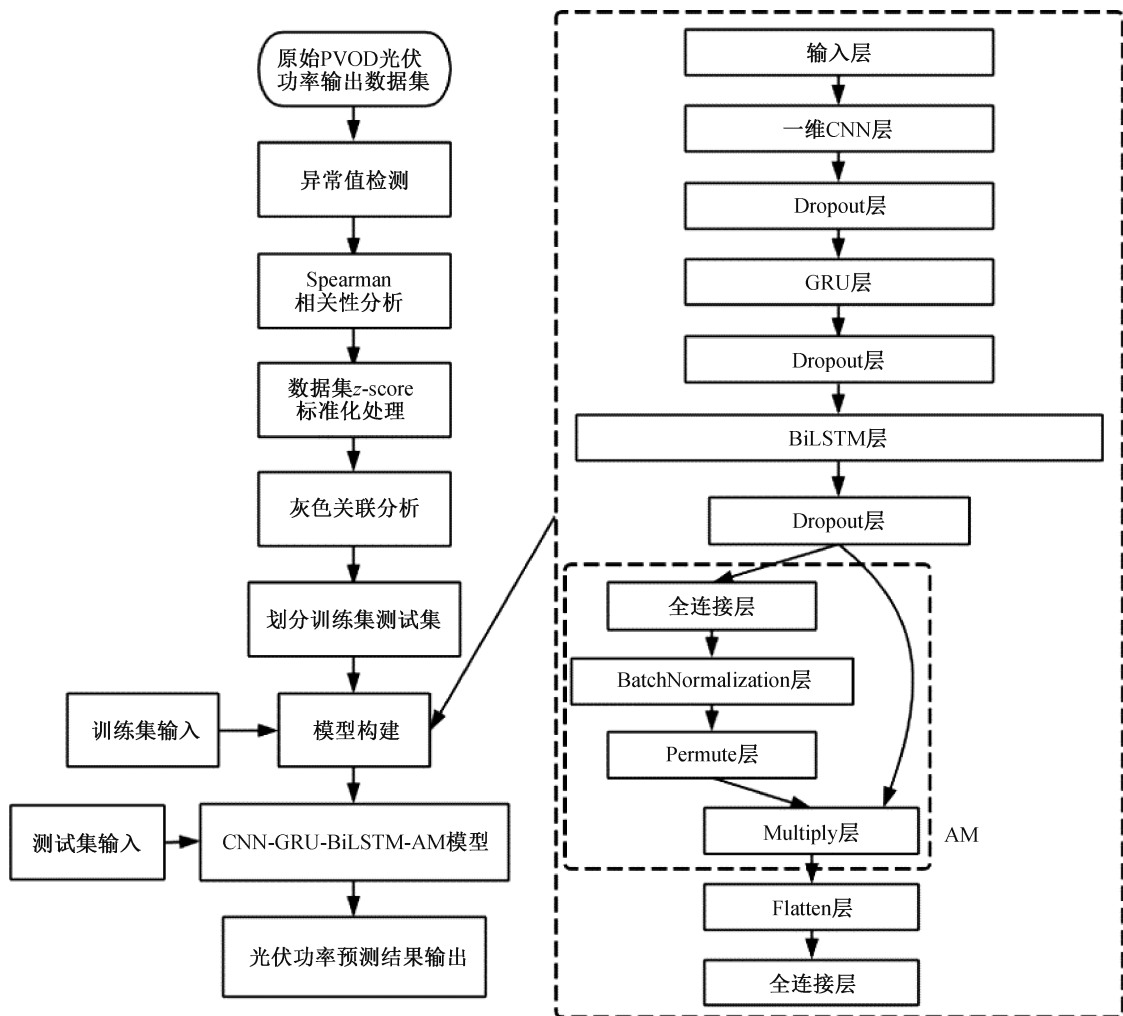


图 6 CNN-GRU-BiLSTM-AM 预测模型工作过程示意图

Fig. 6 Diagram of the working process of the CNN-GRU-BiLSTM-AM prediction model

3.2 评价指标

为了衡量 CNN-GRU-BiLSTM-AM 模型对光伏功率的预测效果,实验选取预测问题常用的决定系数 R^2 、均方根误差(RMSE)和平均绝对误差(MAE)为评价指标^[24]。 R^2 值和模型的预测准确率成正比, RMSE 值、MAE 值和模型的预测准确率成反比。

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2} \quad (8)$$

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

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

式中: y_i —第 i 时刻光伏功率的真实值; \hat{y}_i —第 i 时刻光伏功率的预测值; \bar{y} —光伏功率的平均值; n —光伏功率的总数据量。

4 实证分析

4.1 参数设置

以 2.1 中河北省某光伏电站功率数据为例,选择 22:00—11:00 时间段的光伏功率数据,对上述构建的 CNN-GRU-BiLSTM-AM 模型进行实证分析。为防止出现过拟合现象,分别在 CNN 层、GRU 层和 BiLSTM 层增加 Dropout 层。实验以 Python 语言为基础,采用 Tensorflow 框架对 CNN-GRU-BiLSTM-AM 模型进行训练,参数设置如表 4 所示。

表 4 参数设置

Tab. 4 Parameter settings

超参数	设置	超参数	设置
CNN 层输出通道数	32	学习率	0.001
CNN 层卷积核大小	3	随机失活概率	0.2
BiLSTM CNN 层填充方式	same	批量大小	32
CNN 层激活函数	relu	损失函数	MAE
GRU 层神经元个数	64	训练轮次	20
BiLSTM 层输出通道数	64	优化器	Adam

4.2 实验结果

为验证所构建模型的有效性,将其与 CNN-GRU-LSTM-AM 模型、CNN-BiLSTM-AM^[13]模型、CNN-GRU^[11]模型、GRU-BiLSTM-AM^[25]模型以及 Transformer 模型进行对比,预测结果见表 5。在

Pytorch 框架下,将 Transformer 模型的训练周期设置为 30 轮,学习率为 0.000 1,批量大小为 64,预测长度为 4 步,注意力头数为 4,编码层数为 3。由表 5 可知,相对其他 5 个模型,所构建模型在决定系数 R^2 上分别提高了 0.38%、8.89%、0.19%、0.29%和 10.18%,在 RMSE 上分别降低了 0.006 4、0.070 5、0.003 3、0.005 0 和 0.456 8,在 MAE 上分别降低了 0.003 4、0.060 6、0.002 9、0.005 2 和 0.310 0,进一步说明 BiLSTM 较单向 LSTM 能提取更多的时序信息,GRU 突出光伏功率数据在时间维度上的关联信息,AM 强调历史时间点信息的重要性,以及 CNN 对空间维度上局部特征的提取,它们都对预测精度的提高发挥了重要作用。

表 5 不同模型的光伏功率预测结果

Tab. 5 Photovoltaic power prediction results of different models

模型	R^2	RMSE	MAE
CNN-GRU-BiLSTM-AM	0.991 0	0.032 5	0.026 6
CNN-GRU-LSTM-AM	0.987 2	0.038 9	0.030 0
CNN-BiLSTM-AM	0.910 1	0.103 0	0.087 2
CNN-GRU	0.989 1	0.035 8	0.029 5
GRU-BiLSTM-AM	0.988 1	0.037 5	0.031 8
Transformer	0.889 2	0.489 3	0.327 6

4.3 结果分析

为对上述实验结果进行统计分析,将实验结果进行配对样本的 Wilcoxon 符号秩检验^[26]。该检验是一种非参数检验,目的是推断配对的两个模型预测结果之间是否存在差异。该检验的原假设是基准预测模型,具有与本文提出的预测模型相同或更好的性能。当实验结果进行配对的差值数据不服从正态分布时,可以采用该检验。当检验结果拒绝原假设时,认为本文所提出的模型预测性能更好。

在 SPSS 分析软件中,Shapiro-Wilk 检验适用于 $3 \leq n \leq 5000$ 的小样本数据,由于本文构建模型的预测数据量为 2 613,故选择 Shapiro-Wilk 检验。SPSS 检验结果见表 6,由表 6 可知,5 组差值的显著性 p 值均小于 0.05,故拒绝原假设,认为差值数据不符合正态分布,可以采用配对样本的 Wilcoxon 符号秩检验,结果见表 7。由表 7 可以看出,原假设在 5% 的显著性水平下被拒绝,即本文提出的 CNN-BiLSTM-GRU-AM 模型与其他 5 个对比模型的实验结果均存在显著性差异。这表明本文提出的模型性能优于其他 5 个模型。

表 6 正态性检验 (Shapiro-Wilk 检验)

Tab. 6 Normality test (Shapiro-Wilk test)

	统计	自由度	显著性
差值 1	0.724	2 613	0.000
差值 2	0.971	2 613	0.000
差值 3	0.911	2 613	0.000
差值 4	0.818	2 613	0.000
差值 5	0.991	2 613	0.000

表 7 配对样本的 Wilcoxon 符号秩检验

Tab. 7 Wilcoxon signed-rank test for paired samples

	统计量	显著性	结果
CNN-GRU-BiLSTM-AM vs CNN-GRU-LSTM-AM	360 949	4.42×10^{-267}	存在显著性差异
CNN-GRU-BiLSTM-AM vs CNN-BiLSTM-AM	927 928	7.28×10^{-91}	存在显著性差异
CNN-GRU-BiLSTM-AM vs CNN-GRU	748 242	1.44×10^{-136}	存在显著性差异
CNN-GRU-BiLSTM-AM vs GRU-BiLSTM-AM	248 547	0.00	存在显著性差异
CNN-GRU-BiLSTM-AM vs Transformer	1 817 461	0.004 392	存在显著性差异

5 结论

本文构建了一种基于 CNN-GRU-BiLSTM-AM 的超短期光伏功率预测方法。该方法增强了模型对数据的感知能力,可有效提取光伏功率数据在空间维度上的局部特征,对识别光伏功率的即时波动具有显著作用,能更好地理解光伏功率数据中的长期依赖关系,能自适应地聚焦于历史数据中的关键时间点,这不仅增强了模型对关键特征的感知能力,还提高了对光伏功率变化的响应速度和预测精度。

实验结果表明,与其他五种模型(CNN-GRU-LSTM-AM、CNN-BiLSTM-AM、CNN-GRU、GRU-BiLSTM-AM 和 Transformer)相比,该模型在时间序列预测的准确率最高达到了 0.991,且其在 Wilcoxon 符号秩检验下与其他 5 种模型的对比 p 值均小于 0.05,存在显著性差异,说明该方法在稳定性和泛化能力方面均表现出显著优势。这不仅验证了该模型设计的合理性和有效性,而且为光伏发电管理和电网调度提供了有力的技术支持。

参考文献:

[1] WANG X Y, SUN Y L, LUO D, et al. Comparative study of machine learning approaches for predicting short-term

photovoltaic power output based on weather type classification[J]. Energy, 2022, 240: 122733.

[2] 石磊,张福生,石军显,等. 小型光伏的风险评估方法与模型[J]. 华北理工大学学报(自然科学版), 2020, 42(2): 94-100.

SHI L, ZHANG F S, SHI J X, et al. Risk assessment method and model for small photovoltaics[J]. Journal of North China University of Science and Technology (Natural Science Edition), 2020, 42(2): 94-100.

[3] 朱明. 基于数据处理和深度学习的光伏发电预测模型[J]. 河南科学, 2023, 41(7): 970-977.

ZHU M. Photovoltaic power generation prediction model based on data processing and deep learning[J]. Henan Science, 2023, 41(7): 970-977.

[4] WANG F, LU X X, MEI S W, et al. A satellite image data based ultra-short-term solar PV power forecasting method considering cloud information from neighboring plant[J]. Energy, 2022, 238: 121946.

[5] YANG M, SHI C Y, LIU H Y. Day-ahead wind power forecasting based on the clustering of equivalent power curves[J]. Energy, 2021, 218: 119515.

[6] 何之倬,张颖,郑刚,等. 基于极限学习机模型参数优化的光伏功率区间预测技术[J]. 上海交通大学学报, 2024, 58(3): 285-294.

HE Z Z, ZHANG Y, ZHENG G, et al. Interval prediction technology of photovoltaic power based on parameter optimization of extreme learning machine[J]. Journal of Shanghai Jiaotong University, 2024, 58(3): 285-294.

[7] 徐萌. 基于 MA-SVM 方法的短期光伏功率预测[J]. 电机与控制应用, 2022, 49(7): 104-111.

XU M. Short-term photovoltaic power prediction based on MA-SVM method[J]. Electric Machines & Control Application, 2022, 49(7): 104-111.

[8] 赵滨滨,王莹,王彬,等. 基于 ARIMA 时间序列的分布式光伏系统输出功率预测方法研究[J]. 可再生能源, 2019, 37(6): 820-823.

ZHAO B B, WANG Y, WANG B, et al. Photovoltaic power prediction in distribution network based on ARIMA model time series[J]. Renewable Energy Resources, 2019, 37(6): 820-823.

[9] 常建芳. 基于集成学习和卷积神经网络的太阳能辐照度预测方法[D]. 天津:天津大学, 2018.

CHANG J F. Solar irradiance prediction method based on ensemble learning and convolutional neural network[D]. Tianjin: Tianjin University, 2018.

[10] 田剑刚. 基于 GRU 深度学习的光伏发电超短期功率预测研究[D]. 南昌:华东交通大学, 2021.

TIAN J G. Ultra short-term forecast of photovoltaic generation based on GRU of deep learning algorithm[D].

- Nanchang: East China Jiaotong University, 2021.
- [11] 吴永洪,张智斌. 基于贝叶斯优化的 CNN-GRU 短期电力负荷预测[J]. 现代电子技术, 2023, 46(20): 125-129.
WU Y H, ZHANG Z B. CNN-GRU short-term power load forecasting based on Bayesian optimization [J]. Modern Electronics Technique, 2023, 46(20): 125-129.
- [12] 邵玉琢,汪紫情,计芯蕊,等. 基于 GRU-BiLSTM 的光伏发电中长期功率预测[J]. 自动化应用, 2023, 64(15): 63-66.
SHAO Y Z, WANG Z Q, JI X R, et al. Medium and long-term power prediction of photovoltaic power generation based on GRU-BiLSTM [J]. Automation Application, 2023, 64(15): 63-66.
- [13] 任建吉,位慧慧,邹卓霖,等. 基于 CNN-BiLSTM-Attention 的超短期电力负荷预测[J]. 电力系统保护与控制, 2022, 50(8): 108-116.
REN J J, WEI H H, ZOU Z L, et al. Ultra-short-term power load forecasting based on CNN-BiLSTM-Attention [J]. Power System Protection and Control, 2022, 50(8): 108-116.
- [14] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
ZHOU F Y, JIN L P, DONG J. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [15] 冯晓钰. 加强层级时序记忆算法在税收预测模型中的应用研究[D]. 镇江:江苏科技大学, 2021.
FENG X Y. Strengthen the application research of hierarchical sequential memory algorithm in tax forecast model [D]. Zhenjiang: Jiangsu University of Science and Technology, 2021.
- [16] 陈建华,高虎,苏治俭,等. 一种基于深度学习的数据无损压缩方法及在测井大规模数据存储中的应用[J]. 电子测量技术, 2021, 44(5): 87-93.
CHEN J H, GAO H, SU Z J, et al. A data lossless compression method based on deep learning and application in storing of large well logging data [J]. Electronic Measurement Technology, 2021, 44(5): 87-93.
- [17] LU W J, LI J Z, WANG J Y, et al. A CNN-BiLSTM-AM method for stock price prediction [J]. Neural Computing and Applications, 2021, 33(10): 4741-4753.
- [18] 缪凯. 基于贝叶斯优化算法的长短期记忆网络短期负荷预测[D]. 北京:华北电力大学, 2021.
MIAO K. Short-term load forecasting based on long short-term memory network and Bayesian optimization [D]. Beijing: North China Electric Power University, 2021.
- [19] YAO T C, WANG J, WU H Y, et al. A photovoltaic power output dataset: multi-source photovoltaic power output dataset with Python toolkit [J]. Solar Energy, 2021, 230: 122-130.
- [20] 吴珺玥,赵二刚,郭增良,等. 基于 Spearman 系数和 TCN 的光伏出力超短期多步预测[J]. 太阳能学报, 2023, 44(9): 180-186.
WU J Y, ZHAO E G, GUO Z L, et al. Ultra-short-term photovoltaic power multi-step prediction based on Spearman coefficient and TCN [J]. Acta Energetica Solaris Sinica, 2023, 44(9): 180-186.
- [21] PAN R L, YANG T S, CAO J H, et al. Missing data imputation by K nearest neighbours based on grey relational structure and mutual information [J]. Applied Intelligence, 2015, 43: 614-632.
- [22] HUANG C C, LEE H M. A grey-based nearest neighbor approach for missing attribute value prediction [J]. Applied Intelligence, 2004, 20(3): 239-252.
- [23] 徐恒山,莫汝乔,薛飞,等. 基于时间戳特征提取和 CatBoost-LSTM 模型的光伏短期发电功率预测[J]. 太阳能学报, 2024, 45(5): 565-575.
XU H S, MO R Q, XUE F, et al. Short-term photovoltaic power prediction based on timestamp feature extraction and CatBoost-LSTM model [J]. Acta Energetica Solaris Sinica, 2024, 45(5): 565-575.
- [24] 李荣. 基于 EBS-Attention 优化 LSTM 算法实现短期光伏发电功率预测[D]. 南昌:江西财经大学, 2023.
LI R. Optimization of LSTM algorithm based on EBS-Attention to realize short-term light forecast of volt power generation [D]. Nanchang: Jiangxi University of Finance and Economics, 2023.
- [25] 高凯悦,牟莉,张英博. PCC-BiLSTM-GRU-Attention 组合模型预测方法[J]. 计算机系统应用, 2022, 31(7): 365-371.
GAO K Y, MOU L, ZHANG Y B. Prediction method of PCC-BiLSTM-GRU-Attention combined model [J]. Computer Systems and Applications, 2022, 31(7): 365-371.
- [26] HAO J, KIM Y, KIM T K, et al. PASNet: pathway-associated sparse deep neural network for prognosis prediction from high-throughput data [J]. BMC Bioinformatics, 2018, 19(1): 510.

(责任编辑 唐彦彦)