

· 黄土高原区域研究 ·

引用格式:马越,郭哲卓,李尚明,等.黄土高原集中式光伏电站功率预测模型适用性评价[J].延安大学学报(自然科学版),2026,45(1):3-9.[MA Y, GUO Z Z, LI S M, et al. Evaluation of the applicability of power prediction models for centralized photovoltaic power stations in the Loess Plateau[J]. Journal of Yan'an University(Natural Science Edition), 2026, 45(1):3-9.] DOI: 10.13876/J.cnki.ydnse.250112

## 黄土高原集中式光伏电站功率预测模型适用性评价

马越<sup>1</sup>,郭哲卓<sup>1</sup>,李尚明<sup>2</sup>,白静<sup>1</sup>,许馨尹<sup>3</sup>,杨红霞<sup>1</sup>,杨丽平<sup>1\*</sup>

(1. 延安大学 建筑工程学院;2. 陕西延安电业有限责任公司,陕西 延安 716000;  
3. 苏州科技大学 电子与信息工程学院,江苏 苏州 215009)

**摘要:**针对黄土高原集中式光伏电站发电功率预测需求,本文基于陕西省延安市某集中式光伏电站2024年气象与光伏发电功率实测数据,系统对比了长短期记忆网络(LSTM)、门控循环单元(GRU)、卷积神经网络-长短期记忆网络混合模型(CNN-LSTM)、时间卷积网络(TCN)及时序融合Transformer(TFT)共5种深度学习模型的预测精度、稳定性、计算效率及适应性。结果表明,CNN-LSTM模型综合性能表现最优,其结合空间特征提取与时间依赖建模的混合架构更适用于该地区光伏功率预测;5种模型均表现出天气依赖性,晴天条件下LSTM模型表现最佳,阴天/多云天气下CNN-LSTM更具优势,雨天环境下GRU与TCN模型适应性更强。研究为黄土高原地区光伏功率预测的模型选择提供了实证参考。

**关键词:**黄土高原;光伏发电;功率预测;深度学习;CNN-LSTM

**中图分类号:**TK51 **文献标志码:**A **文章编号:**1004-602X(2026)01-0003-07

在“双碳”目标的持续引领下,光伏发电作为可再生能源体系的关键一环,装机容量正以显著速度扩张。然而光伏出力所固有的间歇性和随机性特征,也给电网系统的稳定运行带来了不小的挑战,特别是在地形复杂、气候多变的区域,电网面临更大的压力<sup>[1]</sup>。因此,提升光伏功率的预测精度,已成为强化电网调度能力、保障能源供应安全的关键技术手段。

黄土高原太阳辐射资源丰富,使得实现较高的光伏发电量成为可能<sup>[2]</sup>,在该区域发展集中式光伏电站有着显著的经济优势,还能起到一定生态修复作用<sup>[3]</sup>。黄土高原地处暖温带与中温带气候过渡区,再加上其沟壑纵横的地貌,造就了局地气象条

件复杂多变的局面,使得光伏发电功率最终呈现出显著的高波动性特征。传统功率预测方法在面对复杂环境下光伏出力响应规律时存在局限性,导致预测精度不佳<sup>[4]</sup>。

近年来,深度学习模型在光伏功率预测中展现出显著优势。长短期记忆网络(LSTM)<sup>[5]</sup>、门控循环单元(GRU)<sup>[6]</sup>等循环神经网络因其变体擅长处理时间依赖问题,被广泛应用于捕捉光伏功率的时序规律。单一的计算模型存在模型适用性低、预测误差高等问题,有学者提出将卷积神经网络(CNN)与长短期记忆网络相结合,构建CNN-LSTM混合结构以捕捉气象要素的空间关联与时间动态,在GHI预测

收稿日期:2025-10-02

基金项目:国家自然科学基金项目(52468029);延能集团-陕西延安电业有限责任公司《绿色能源-零碳建筑实验室》建设项目(206021030)

作者简介:马越(1988—),男,副教授,博士,主要从事结构工程和新能源基础设施方面的研究。

\*通信作者 E-mail:yangliping@yau.edu.cn

中取得了优异精度,同时降低了约30%的计算复杂度<sup>[7]</sup>。也有学者将时间卷积网络(TCN)引入膨胀卷积与因果结构,以增强长序列建模的稳定性,较于传统序列模型误差降低了28.3%<sup>[8]</sup>。基于自注意力机制的时序融合Transformer(TFT)能够自适应地对关键特征和时间步进行加权,将其用于风电预测时误差降低达60%<sup>[9]</sup>。然而,现有研究多集中于一般场景或模型本身的改进<sup>[10]</sup>,针对黄土高原这类高波动地理气候区的系统化模型对比与机理解析仍相对缺乏。因此,针对黄土高原区域的功率预测模型进行适用性评价,具有重要的理论意义与工程价值。

本研究选取陕西省延安市某集中式光伏电站作为研究对象,如图1所示。基于该电站2024年气象与光伏发电功率的实测数据,通过构建统一评估框架,对LSTM、GRU、CNN-LSTM、TCN及TFT五种深度学习模型进行了系统性的对比分析,评估维度涵盖预测精度、模型稳定性、计算效率及环境适应性,研究揭示了不同模型对高波动数据的适应机制,旨在为黄土高原区域集中式光伏电站的功率预测模型选择提供实证参考与决策依据。



图1 黄土高原某集中式光伏电站

## 1 发电功率预测模型

### 1.1 LSTM模型

在循环神经网络(RNN)的演进历程中,LSTM无疑是一类重要的变体模型。其核心在于设计了由输入门、遗忘门和输出门组成的精巧结构,克服了传统RNN在处理长序列数据时遇到的梯度信号消失或爆炸的缺陷。LSTM之所以能够捕捉时间序列中的长期依赖关系,根源在于被独特设计的单元状态。这一结构配合着门控机制,使得信息能够在序列传递过程中保持相对的稳定,而门控机制的作

用,也正是通过控制信息的流入、更新与输出来保障这一过程的实现<sup>[11]</sup>。基于上述特性,本研究将LSTM选为基准模型,意在从经典递归网络的视角出发,考察其在高波动光伏功率预测任务中的基础性表现,为后续不同复杂度模型的对比分析提供一个相对稳定的参照基准。

### 1.2 CNN-LSTM模型

图2展示的是本研究所采用的CNN-LSTM混合架构<sup>[12]</sup>。这一架构的设计思路在于将问题分解为空间特征提取与时间依赖建模两个环节,并分别交由对应的网络模块进行处理。具体指:经预处理的标准化多特征气象时序数据首先流入CNN模块的隐含层,该隐含层由交替堆叠的卷积层与池化层构成,作用是通过局部感知与降维的操作从辐照度、温度、风速等多个并行特征序列中提取关键的局部空间交互信息。这些提取出的高层空间特征随后被展开开,并按照时间步输入至LSTM模块,然后凭借内部的门控机制与细胞状态,进一步学习上述空间特征在时间维度上的动态演化规律与长期依赖关系。最后,把LSTM层的输出由全连接层进行整合再经反归一化处理,在输出端得到最终的功率预测值。本研究采用这一混合架构,目的是验证时空特征融合机制在本地区光伏预测场景中的有效性,即让CNN先行梳理气象要素间的空间关联,再由LSTM捕捉功率输出的时间依赖特性,得到二者协同运作是否能够较好地契合黄土高原区域光伏功率预测的实际需求。

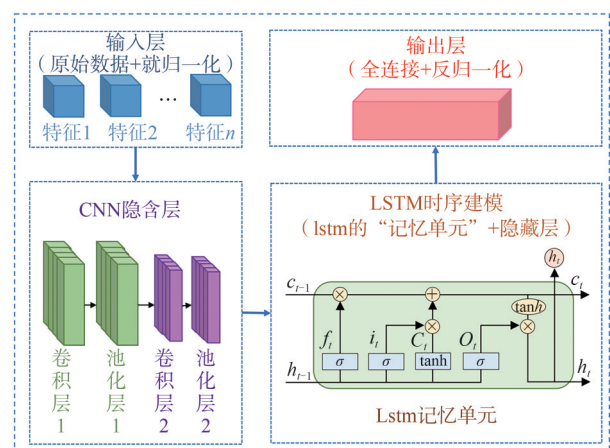


图2 CNN-LSTM模型结构图

### 1.3 TCN模型

基于膨胀因果卷积的TCN模型提供了一种不同于递归网络的时序建模思路<sup>[13]</sup>。其显著特点在

于采用并行化计算架构,可一次性的处理整个序列,训练效率比传统递归结构高。通过叠加膨胀卷积层,TCN能有效扩展感受野以捕捉长期依赖,同时无循环连接的架构设计也确保了梯度传播的稳定性,优化了训练收敛性能。基于上述的特性,本研究将其纳入实验框架,以评估全卷积架构在光伏功率预测中的实际表现。

#### 1.4 GRU模型

作为LSTM的一种轻量化变体,GRU在结构上进行了精简<sup>[14]</sup>。GRU通过将输入门与遗忘门合并为更新门,并省略了细胞状态,从而能够以相对精简的结构实现对中长期依赖关系的有效建模。得益于这一结构简化,其在参数规模和计算复杂度上相较于LSTM有着一定优势,训练速度上也有明显提升。基于上述特点,本研究引入GRU模型,旨在系统性地对比分析模型精简对预测性能与计算效率所带来的实际影响,并进一步评估此类轻量级架构在波动性强、特征复杂区域背景下的实际应用潜力。

#### 1.5 TFT模型

作为一种基于Transformer架构思想、专为多步时序预测任务而设计的先进模型<sup>[15]</sup>,TFT模型采用了Transformer的核心机制,通过多头注意力机制能够自适应地对输入序列中的不同时间步及特征变量进行权重分配,实现了模型在重要气象因子的感知与利用效率提升。然而,与Transformer主要用于处理完整序列的做法有所不同,TFT在结构设计层面进行了多项改进,以更好地适应预测任务场景。具体体现在两个方面:一是引入了静态协变量编码器,用以处理那些不随时间变化的静态站点信息。二是设计了序列到序列的解码器结构,来执行最终的多步预测任务<sup>[16]</sup>。本研究选择引入TFT模型,旨在检验其在特殊地域场景下的泛化能力与模型解释性,并进一步探索其对关键气象特征自适应捕捉的潜在能力。

## 2 数据处理与模型评价指标

### 2.1 数据预处理

本文所用实验样本数据来自陕西省延安市某光伏电站2024年1月1日至2024年12月30日的实测数据,时间分辨率为15 min。原始数据共包含34 488条记录,数据缺失率低于0.3%。对存在的少量缺失值采用前向填充法进行处理,最终得到用于实验的连

续时间序列数据共计34 560条,每条数据包包含总辐照度、直辐照度、散辐照度、风速、风向、温度、湿度、气压及实际功率9个变量,共31.1万个数据构成完整数据集。

在对完整连续数据集进行预处理时,首先基于8个气象特征与功率变量构建初始数据集,并明确特征与目标变量。为捕捉光伏功率的时序动态特性,采用滑动窗口法将时间序列重构为监督学习样本<sup>[17]</sup>。图3为滑动窗口示意图,设定窗口长度为12,每个样本由连续12个时间点的气象与功率数据构成,用于预测下一个时间点的功率值,随后窗口沿时间轴滑动,依次生成后续样本。之后按时间顺序将数据集划分为80%训练集与20%测试集。为消除量纲差异,采用最小-最大归一化将各变量缩放至0到1之间,其归一化参数严格依据训练集计算,并同步应用于测试集,以避免数据泄漏。最终将数据转换为PyTorch可处理的DataLoader格式,训练集在每个Epoch内进行随机打乱,完成数据预处理全过程。




图3 滑动窗口构造示意图

### 2.2 模型评价

为全面评估光伏功率预测模型的性能,本研究采用均方误差(MSE)、平均绝对误差(MAE)和决定系数( $R^2$ )作为评价指标<sup>[12]</sup>,各指标计算如式(1)、(2)和(3)所示。

$$\delta_{\text{MSE}} = \frac{1}{m} \sum_{i=1}^m (y_i - y_{i_{\text{pred}}})^2 \quad (1)$$

$$\delta_{\text{MAE}} = \frac{1}{m} \sum_{i=1}^m |y_i - y_{i_{\text{pred}}}| \quad (2)$$

$$R^2 = 1 - \frac{\sum_i (y_{i_{\text{pred}}} - y_i)^2}{\sum_i (\bar{y} - y_i)^2} \quad (3)$$

其中,  $m$  为样本数量,  $y_i, y_{i\_pred}$  为  $i$  时刻的实测功率和预测功率,  $\bar{y}$  为  $m$  个实测功率均值。

### 2.3 实验设置

本研究基于 PyTorch 深度学习框架构建所有预测模型, 采用 Adam 优化器进行参数优化, 学习率设置为 0.001, 并以均方误差作为模型训练的损失函数。在模型架构方面, LSTM 与 GRU 采用标准的递归神经网络结构; CNN-LSTM 通过卷积层提取空间特征并结合 LSTM 捕捉时序依赖; TCN 基于膨胀卷积机制构建时序建模能力; TFT 则利用自注意力机制实现多变量时序融合。训练过程中设置最大迭代轮次为 50, 并采用早停策略监控, 保存最优模型权重用于最终测试评估。

## 3 结果与分析

### 3.1 综合预测性能对比

各模型在统一测试集上的整体性能对比结果汇总于表 1, 评估指标包括 MSE、MAE 和  $R^2$ 。从表中呈现的结果来看, CNN-LSTM 的综合预测表现最为突出, 其  $R^2$  值最高, MSE 最低, 这说明将空间特征提取与时间依赖建模相结合的思路, 能够较好地应对黄土高原地区光伏功率的高波动特性。TFT 模型则在预测稳定性上展现出一定优势, 其 MAE 值最低。相比较之下, TCN 在本研究场景中的表现并不十分理想, 推测是膨胀卷积结构难以适配气象要素的剧烈波动。LSTM 作为基准模型表现稳定, 而结构更为轻量的 GRU 在保持较高训练效率的同时预测精度略有下降。

表 1 各模型在测试集上的性能指标对比

模型	$\delta_{MSE}$	$\delta_{MAE}$	$R^2$
CNN-LSTM	16.742 9	1.580 9	0.816 3
LSTM	19.236 2	1.617 2	0.788 9
TFT	19.723 2	1.441 6	0.783 6
GRU	20.258 8	1.658 7	0.777 7
TCN	20.616 9	1.578 2	0.773 8

### 3.2 不同天气条件下的预测结果分析

为评估模型在黄土高原不同天气场景下的适应性, 本研究基于总辐照度、湿度与温度等多种气象参数构建了天气分类方法。其中, 晴天指日最高总辐照度大于  $800 \text{ W/m}^2$  的情况; 阴天或多云天气为日最高总辐照度介于  $400\sim 800 \text{ W/m}^2$  之间; 雨天则通过辐照度、湿度与温度等特征综合判定, 当日最高总辐照度低于  $300 \text{ W/m}^2$ 、平均湿度高于 80% 且低辐照度持续时间超过 4 h 的情况下予以识别。从全年数据中筛选出晴天、阴天/多云、雨天三种典型天气各 10 d, 覆盖春、夏、秋、冬四季, 提取每日 06:00—18:00 时段的 48 个时间点的功率数据, 进而分析各模型在不同天气条件下的平均预测性能<sup>[18]</sup>。基于这 480 个样本点得到各模型决定系数如表 2 所示, 三种典型天气下不同模型预测的发电功率随时间变化如图 4 所示。

表 2 不同天气类型下的  $R^2$  值

天气类型	LSTM	GRU	CNN-LSTM	TCN	TFT
晴天	0.949 1	0.932 3	0.921 7	0.940 7	0.935 7
多云/阴天	0.709 2	0.690 6	0.760 8	0.743 7	0.745 2
雨天	0.602 4	0.887 0	0.602 5	0.867 9	0.838 0




图 4 不同天气条件下的发电功率预测结果

由表 2 和图 4 可知, 晴天工况下 5 个模型均表现出优异的预测性能,  $R^2$  均高于 0.92。  $R^2$  衡量的是预测值对实际值波动的解释程度, 其值越接近 1, 代表模型捕捉数据趋势的能力越强。正因如此, 图 4 中显示各模型预测曲线与实际功率曲线高度吻合、

均能精准捕捉平滑“单峰”形态的现象, 是其高  $R^2$  值的直观体现。在此高度一致的性能基础上, LSTM 模型表现最佳,  $R^2$  达到 0.949 1, 显示出对稳定辐照条件下功率输出的最佳跟踪能力。在剧烈波动的阴天/多云天, CNN-LSTM 模型凭借其时空特征融合机

制,展现出最优的波动捕捉能力, $R^2$ 为0.760 8,能够快速响应功率突变。相比之下,LSTM与GRU模型由于结构限制,出现明显的预测滞后现象, $R^2$ 分别为0.709 2和0.690 6。在雨天场景下,GRU与TCN模型表现更为突出, $R^2$ 分别为0.887 0和0.867 9,说明结构相对简洁、参数更新机制灵活的模型更能适应低功率、复杂波动场景。而LSTM与CNN-LSTM模型由于对输入序列的长时依赖处理能力不足,适应性较差, $R^2$ 仅为0.602 4和0.602 5。

上述性能差异实质上源于模型内在机理与气象条件波动带来的数据特征变化之间的复杂相互作用。在晴天条件下,功率曲线相对平滑且规律性也较强,呈现出明显的长期依赖特征,这是因为LSTM本来就擅长通过门控机制去捕捉和传递时序上的长期依赖。在情况复杂的阴天或多云天气下,云层快速移动带来的不只是功率的剧烈波动,还伴随着多气象因子的瞬时联动及其后续演变,这里面既有空间上的局部相关性,又有时间上的演化性,属于典型的时空耦合问题。而CNN-LSTM的混合架构恰好能先通过CNN模块提取多气象变量的空间关联模式,再交由LSTM模块对其时间演变进行建模,从而在应对此类复杂时空波动时展现出独特优势。在雨天环境下,此时功率输出水平本身偏低且信号噪声大、波动模式不规则。面对这种低信噪比的场景,模型太复杂反而效果不佳,更关键的是要简洁,能快速更新参数,还得抵抗噪声干扰。结构精简的GRU模型和有并行因果卷积机制的TCN模型,反而在应对这类突变时显得更灵活一些。

综上,光伏功率预测模型的性能具有显著的天气依赖性,不存在适用于所有天气场景的最优模型。针对黄土高原地区多变的气候特点,实际应用中可以根据天气条件来动态选择预测模型。在晴天采用LSTM模型,阴天或多云选用CNN-LSTM模型,雨天则更适合GRU或TCN模型。这种按天气适配的方式,可以提升预测的准确性与实用性。

### 3.3 模型计算效率对比分析

各模型在统一实验环境下的训练时间与推理时间对比如图5所示,相关结果基于训练集与测试集分别统计得出。从计算结果来看,CNN-LSTM在计算效率方面表现最为突出,其平均每轮训练耗时为1.58 s,在各模型中用时最短;推理延迟也低至0.009 s,同样优于其他对比模型。这表明该模型在

预测精度与计算成本之间取得了较好的平衡。进一步分析其结构设计,CNN-LSTM之所以能够实现较高的计算效率,与其混合架构中两个模块的功能划分有着密切关系。CNN模块通过局部卷积操作提取气象特征的空间关联信息,同时降低了输入序列的特征维度与数据复杂度,而简化后的时序特征随后交由LSTM模块处理,二者协同运作有效减少了整体的计算负载。TCN与LSTM同样也具备计算优势,平均每轮训练耗时分别为1.90 s和1.96 s,对应推理时间分别为0.02 s与0.01 s。TCN的计算效率得益于全卷积结构与膨胀卷积机制,使其不但能够并行处理长序列,而且避免了递归网络固有的顺序计算瓶颈。LSTM则是凭借门控机制实现了较为稳定且高效的时序建模。

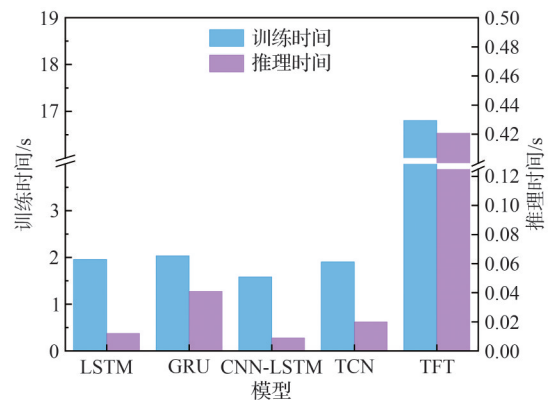


图5 模型训练与推理时间对比

与上述模型相比,TFT模型的计算成本则处于较高水平,训练耗时达到了16.80 s每轮,推理时间也达到了0.42 s。这种现象很大程度上可以归因于其核心的自注意力机制。该机制需要对所有时间步之间的关联进行计算,这使得计算复杂度会随着序列长度的增加而呈现出二次方级别的增长,同时模型的整体参数量也相对较大。另外对比GRU和LSTM,GRU模型虽然较LSTM更为轻量,但从本次实验的实际表现来看,其训练效率仅为每轮2.04 s,这一结果并没有显著优于LSTM,而其推理时间也达到了0.04 s,相对偏长。这一现象背后所反映出的问题是:当面对本研究所涉及的高波动、强非线性光伏功率序列时,GRU所采用的简化门控机制,可能需要在训练过程中进行更为频繁的梯度调整以适应复杂的数据模式,导致性能不佳。总之,在黄土高原光伏功率预测任务中,一个模型的计算效率表现实际上是其底层架构设计、并行化程度与特定数据波动模式这三者因素共同作用形成的结果。

### 3.4 气象特征与发电功率相关性分析

为系统识别影响光伏发电功率的关键驱动因子,本研究基于皮尔逊相关系数<sup>[19]</sup>量化了黄土高原地区各气象要素与功率输出的线性关联强度,相关系数矩阵热力图如图6所示。由图6可知,不同气象因子对功率预测的重要性呈现明显层次化特征:辐照度参数(总、直、散辐照度)与功率输出呈现极强的正相关性,是该地区日照充足的特点;湿度与功率呈弱负相关性,这与半干旱气候下湿度较低但对辐射仍有微弱衰减的规律相符;温度虽呈正相关但系数较弱,体现了其对光伏效率的双重影响;风相关参数(风速、风向、气压)相关性极弱,这与黄土高原沟壑地貌下局地湍流复杂、风速风向波动性强的区域气候特征有关,其线性贡献因此相对有限。




图6 气象特征与光伏功率的皮尔逊相关系数热力图

## 4 结论

1)在黄土高原高波动性气候背景下,CNN-LSTM模型在预测精度与计算效率上均表现最优。其混合架构融合了CNN的空间特征提取能力与LSTM的时序建模优势,能有效协同捕捉气象要素间的局部关联和动态演变规律,因而在该区域集中式光伏电站的功率预测场景中有较好的适用性。

2)不同天气条件下,各模型的预测性能存在显著差异。晴天工况下,太阳辐照稳定、规律性强,LSTM在此类场景中表现最佳;阴天或多云工况下,天气波动剧烈且涉及多因子交互,CNN-LSTM的优势较为突出;而在雨天工况下,结构简洁的GRU与并行化的TCN更具适应性与鲁棒性。

3)从计算效率来看,不同模型的表现与其内在架构复杂度及外部数据特征密切相关。CNN-LSTM通过模块化分工有效优化了计算负载,在效率与精度之间取得了较好平衡;而TCN则凭借并行卷积结构在处理长序列时展现出显著优势。TFT虽然预测能力突出,但其自注意力机制所带来的二次计算复杂度,导致计算效率成为主要瓶颈。另外,GRU在本研究中并未充分体现出其结构精简带来的轻量化优势,可能与数据的高波动特性有关。

4)气象因子对光伏功率的影响呈现明显的层级差异。辐照度起决定性作用,湿度与温度通过影响组件效率及大气透射率间接调节发电水平,风速等参数在本区域特定地形与气候条件下贡献度相对有限。

5)从工程应用的角度来看,“场景适配”的动态模型选择策略是较为合理的思路。在日常预测中追求综合性能最优,CNN-LSTM是最佳选择;若对长序列预测的稳定性有较高要求,TCN则更有优势;在计算资源相对受限的环境中,GRU因其效率优势会更实用。后续研究中,将尝试把实时天气识别与空间关联信息引入模型调度机制,从而进一步提升预测系统对区域复杂条件的适应性。

### 参考文献:

- [1]吕清泉,张珍珍,马彦宏,等.区域光伏发电出力特性分析研究[J].发电技术,2022,43(3):413-420.
- [2]杨红霞,何春燕,郑海.屋顶光伏与幕墙光伏在陕北地区建筑中的应用研究[J].延安大学学报(自然科学版),2025,44(1):14-19+28.
- [3]XIA Z L,LI Y J,GUO S C, et al. Remote sensing reveals the impact of photovoltaic plant deployment on vegetation dynamics and drought sensitivity in vegetation water deficit regions[J]. Catena, 2025, 259: 109354.
- [4]张莉娅,王毅荣.中国黄土高原近地面气候环境演变趋势[J].中国农学通报,2014,30(2):286-294.
- [5]林文婷,李培强,荆志宇,等.基于多级特征提取的BiLSTM短期光伏出力预测[J].太阳能学报,2024,45(10):284-297.
- [6]LYU J J, ZHU G H, HE C. Data-driven short-term photovoltaic power forecasting under extreme weather conditions using GRU-KAN model[J]. Renewable Energy, 2026, 257:124756.
- [7]KHAN A W, DUAN J D, NAWAZ F, et al. Novel hybrid BiLSTM-BiGRU and CNN-LSTM architectures for enhanced solar irradiance forecasting in semi-arid climates [J]. International Journal of Electrical Power & Energy Systems, 2025, 172:111380.

- [8] SONG E Z, ZHANG X Y, GE Y W, et al. Parallel TCN-BiGRU architecture with dynamic attention for ship energy consumption prediction under variable navigation conditions [J]. *Energy*, 2025, 337: 138601.
- [9] MICHALAKOPOULOS V, ZAKYNTHINOS A, SARMAS E, et al. Hybrid short-term wind power forecasting model using theoretical power curves and temporal fusion transformers [J]. *Renewable Energy*, 2026, 256: 124008.
- [10] 赖昌伟, 黎静华, 陈博, 等. 光伏发电出力预测技术研究综述[J]. *电工技术学报*, 2019, 34(6): 1201-1217.
- [11] 王智, 毛雪飞, 冯英, 等. 基于CNN-LSTM的断路器合成试验短路电流零点预测技术[J]. *高压电器*, 2025, 61(9): 35-42+49.
- [12] 蔡祯杨, 李科, 吴定会, 等. 基于哈里斯鹰优化的CNN-BiGRU短期光伏功率预测研究[J/OL]. *控制工程*, 1-9[2025-11-27]. <https://doi.org/10.14107/j.cnki.kzgc.20250324>.
- [13] 殷钰朋, 匡洪海, 李星宇, 等. 基于TCN-SENet-Transformer的新型超短期风电功率组合预测方法[J]. *太阳能学报*, 2025, 46(12): 735-741.
- [14] 夏鹏, 黄磊, 徐浩, 等. 基于注意力机制的TCN-GRU的光伏功率预测应用[J]. *无线互联科技*, 2025, 22(11): 79-84.
- [15] 沈炳华, 曾智, 陈清泉, 等. 基于时域卷积融合注意力机制的光伏功率预测方法[J]. *兵工自动化*, 2025, 44(5): 94-100.
- [16] 米郝, 高新宇, 袁慧, 等. SE-TransNet: 一种结合SENet的新型Transformer网络入侵检测方法[J]. *延安大学学报(自然科学版)*, 2025, 44(2): 29-36.
- [17] 郑涵. 基于改进的ELO模型和机器学习方法的NBA赛事预测[D]. 上海: 上海师范大学, 2024.
- [18] 徐崇斌, 陈前, 孙晓敏, 等. 长三角区域光伏发电功率预测模型适用性评估: 以浙江省金华市为例[J]. *太阳能学报*, 2025, 46(8): 293-298.
- [19] 丁钦钦. 分布式光伏系统中多源异构数据融合算法研究[D]. 南京: 东南大学, 2023.

[责任编辑 张 香]

## Evaluation of the applicability of power prediction models for centralized photovoltaic power stations in the Loess Plateau

MA Yue<sup>1</sup>, GUO Zhezhuo<sup>1</sup>, LI Shangming<sup>2</sup>, BAI Jing<sup>1</sup>, XU Xinyin<sup>3</sup>,  
YANG Hongxia<sup>1</sup>, YANG Liping<sup>1\*</sup>

(1. School of Architecture and Civil Engineering, Yan'an University; 2. Yan'an Power Utility, Yan'an 716000;  
3. School of Electronic and Information Engineering, Suzhou University of Science and Technology,  
Suzhou 215009, China)

**Abstract:** To meet the power prediction requirements of centralized photovoltaic power stations in the Loess Plateau, this paper systematically compares the prediction accuracy, stability, computational efficiency, and adaptability of five deep learning models, namely Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM) hybrid model, Temporal Convolutional Network (TCN), and Temporal Fusion Transformer (TFT), based on the measured meteorological and photovoltaic power generation data of a centralized photovoltaic power station in Yan'an City, Shaanxi Province in 2024. The results show that the CNN-LSTM model has the best overall performance, and its hybrid architecture combining spatial feature extraction and temporal dependency modeling is more suitable for photovoltaic power prediction in this region. All five models exhibit weather dependence, with the LSTM model performing best under clear weather conditions, the CNN-LSTM model having an advantage under cloudy and overcast conditions, and the GRU and TCN models showing stronger adaptability under rainy conditions. This study provides empirical references for the selection of power prediction models for photovoltaic power stations in the Loess Plateau region.

**Key words:** Loess Plateau; photovoltaic power generation; power forecasting; deep learning; CNN-LSTM