

DOI: 10.19783/j.cnki.pspc.250237

物理特征扩展的 ASReLU-CNN-LSTM 短期光伏功率预测研究

刘伟^{1,2}, 李洋洋¹

(1. 东北石油大学电气信息工程学院, 黑龙江 大庆 163000; 2. 东北石油大学三亚海洋油气研究院, 海南 三亚 572000)

摘要: 为提高光伏发电系统在复杂多变气象条件下输出功率预测的精确性和稳定性, 基于物理-数据融合的驱动策略, 提出一种物理特征扩展的 ASReLU-CNN-LSTM 短期光伏功率预测方法。该方法首先通过改进太阳轨迹模型动态校正斜面辐照度, 使其更准确地反映组件实际受光强度, 接着结合光电转换模型与小型前馈网络扩展数据集的相对功率特征。其次, 构建自适应平滑修正线性单元(adaptively smooth rectifier linear unit, ASReLU), 通过参数自适应平滑修正优化卷积神经网络(convolutional neural network, CNN)的负特征提取能力。最后, 将物理特征扩展的数据集输入 ASReLU-CNN-LSTM 模型, 实现光伏功率的预测。在两个不同气候区数据集上的实验结果表明, 该预测方法具有较高的精确性和泛化能力。

关键词: 短期光伏功率预测; 太阳轨迹模型; 光电转换模型; 自适应平滑修正线性单元; CNN-LSTM 模型

Research on short-term photovoltaic power forecasting based on a physical feature expansion ASReLU-CNN-LSTM model

LIU Wei^{1,2}, LI Yangyang¹

(1. School of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163000, China;

2. NEPU Sanya Offshore Oil & Gas Research Institute, Sanya 572000, China)

Abstract: To enhance the accuracy and stability of photovoltaic (PV) power output forecasting under complex and highly variable meteorological conditions, a physics-data fusion-driven strategy is adopted, and a physical feature expansion ASReLU-CNN-LSTM method for short-term PV power forecasting is proposed. First, an improved solar trajectory model is used to dynamically correct the tilted surface irradiance so that it accurately reflects the actual irradiance received by PV modules. Subsequently, a PV conversion model and a lightweight feedforward network are employed to expand the dataset with relative power features. An adaptively smooth rectifier linear unit (ASReLU) is then designed, in which parameterized adaptive smoothing is introduced to enhance the negative-feature extraction capability of the convolutional neural network (CNN). Finally, the dataset augmented with physical features is fed into the ASReLU-CNN-LSTM model for PV power prediction. Experimental results on datasets from two distinct climatic regions demonstrate that the proposed method achieves high prediction accuracy and strong generalization capability.

This work is supported by the National Natural Science Foundation of China (No. 62473096).

Key words: short-term photovoltaic power forecasting; solar trajectory model; photovoltaic conversion model; adaptively smooth rectified linear unit; CNN-LSTM model

0 引言

随着“双碳”目标的推进, 光伏装机容量持续攀升, 光伏出力的间歇性波动给电网运行带来严峻挑战。光伏功率预测对保障系统安全、提高可再生能源利用至关重要^[1-5]。根据建模的方式不同, 常见

的短期光伏功率预测方法可分为物理驱动方法、数据驱动方法以及物理-数据融合驱动方法3种形式^[6-7]。

物理驱动方法通常基于光伏系统原理, 综合利用光伏电站的固有信息和气象预报的辐照度、温度等气象因子建立数学模型以计算光伏功率^[8]。例如, 文献[9]基于光电转换模型构建功率预测框架。文献[10]建立斜面辐照度计算模型, 引入了光谱响应校正因子、入射角余弦效应及积尘衰减系数, 为无历

基金项目: 国家自然科学基金项目资助(62473096)

史数据的新建电站提供可靠预测方案。以上物理驱动方法可解释性强,不依赖大量的历史数据,但模型参数需要人工标定,难以适配动态气象条件下的非线性响应特性^[11],局限性明显。数据驱动方法通过机器学习从历史功率与气象数据中学习映射关系^[12]。文献[13]利用极度随机树分类器(extra trees classifier, ETC)结合多种传统机器学习模型用于短期光伏功率预测,在多变天气条件下预测效果突出。近年来,深度学习方法在光伏预测领域中取得了显著进展。在众多的学习模型中,长短期记忆网络(long short-term memory, LSTM)因其在处理时序数据上的强大能力,已经成为短期光伏功率预测领域的重点研究方向,基于该模型^[14]及其改进模型^[15-16]的预测方法在不同地区的光伏数据集中均有着优秀的表现。然而,纯数据驱动的方法往往依赖海量数据,且对数据质量敏感,模型缺乏物理约束和物理可解释性。

相较于单一驱动方式,物理-数据融合驱动的预测方法能够根据物理机理设计数据预处理环节,或根据物理特性改造数据驱动模型,将典型场景下的光伏物理原理融入数据驱动模型之中,有助于提高模型的性能和物理可解释性^[17],逐渐成为当前研究的热点。现有的物理-数据融合驱动方法大致可以分为以下3类:基于集成学习的融合驱动方法、基于多源异构数据的融合方法以及组合物理模型与数据驱动模型的混合建模方法。文献[18]提出一种机理-数据融合的光伏预测方法,在Stacking集成框架中并行部署机理模型、LSTM和轻量级梯度提升机(light gradient boosting machine, LGBM),最后通过线性回归融合机器学习器输出。该方法通过引入机理模型对光伏出力的区间加以约束,提高了预测精度和结果的物理可解释性,但所使用的机理模型依赖参数标定,易受环境干扰,泛化能力不足。文献[19]提出一种基于多源异构气象数据的多源变量光伏功率预测模型(multi source variables photovoltaic power prediction model, MPPM),将云层的3维结构信息加入预测分析,融合2维卫星云图与3维气象要素特征,通过多源物理信息整合的方式增强了模型对于时间序列数据的理解和建模能力。然而,该方法的模型构建依赖于高质量的卫星云图以及天气研究与预报模型(weather research and forecasting model, WRF)数据,对数据获取与处理能力提出较高要求,因此不适用于外部数据匮乏的部分电站场景。文献[20]提出了一种基于斜面辐照度机理模型(tilted irradiance mechanism, TIM)的光伏功率组合预测模型。该模型通过TIM将全球水平总辐照度修正为光伏板上的斜面辐照度,提升了预处理环节辐照度数

据的准确性和物理可解释性,再结合类别型梯度提升算法(category boosting, CatBoost)和具有多头注意力的双向门控循环单元网络(bidirectional gated recurrent unit with multi-head attention, BiGRUM),最终实现了预测精度的提升。然而,该方法在计算斜面辐照度时需实时调用中国气象局的系统数据,对外部数据接口的稳定性和时效性依赖度较高;同时,计算过程中引入了较多的经验参数(如晴空指数、地表反射率和多个校正系数),这些参数在真实环境中受动态气象因子的影响存在较明显的时变特性,固定的假设可能将经验误差传导至后续数据驱动模块,限制模型的泛化能力。

综上所述,目前用于短期光伏功率预测的物理-数据融合驱动方法主要存在以下局限性:首先,现有方法对高质量的外部数据仍存在明显依赖,融合驱动方法的实际应用范围被限制,泛化性有待提高;其次,现有方法在融合过程中未能很好地规避物理模型中经验参数带来的传导误差,在复杂天气场景下的鲁棒性有待提升。

针对以上问题,本文提出一种物理特征扩展的ASReLU-CNN-LSTM短期光伏功率预测方法。在数据预处理阶段,充分利用电站的固定参数和实测气象数据构建动态的太阳轨迹模型,校正原始斜面辐照度数据,使其更接近组件的实际受光强度,继而利用光电转换模型结合小型前馈神经网络对数据集进行相对功率特征扩展,为后续的数据驱动模型注入具有明确物理意义的特征基底。在数据驱动建模阶段,通过对传统的修正线性单元(rectified linear unit, ReLU)进行改进,提出自适应平滑修正线性单元(adaptively smooth rectifier linear unit, ASReLU)作为CNN层的激活函数,在保留ReLU优点的同时优化负特征的提取效果,增强CNN层的特征提取能力。最后利用LSTM的时序预测能力实现光伏功率的短期预测。为了验证所提方法的有效性,利用黑龙江某光伏电站的实测数据进行了对比实验和分析;为了进一步验证方法的泛化能力,利用澳大利亚DKASC项目的Alice springs数据集^[21]搭建典型干旱沙漠地区验证场景,在3种典型天气场景下设置多个对比模型进行了实验分析。

1 方法

1.1 基于改进太阳轨迹模型的斜面辐照度校正方法

辐照度指单位面积上所接收到的辐射通量,在光伏系统中用于描述太阳辐射能量的分布密度。光伏电站的实测数据集一般包含总辐照度、斜面辐照

度、直接辐照度和散射辐照度 4 种辐照度数据。总辐照度(global horizontal irradiance, GHI)是指单位时间内照射到水平面上的太阳总辐射, 斜面辐照度(titled irradiance, TI)指太阳辐射在光伏组件实际安装倾角上的投影辐照度, 是影响光伏发电功率的重要因素, 在光伏电站中通常由 GHI 和太阳高度角经过几何换算得到, 用 G_{TI} 表示。然而, 由于太阳高度角和方位角在日间持续变化, 固定倾角的光伏系统无法实时跟踪太阳轨迹, 导致由总辐照度计算得到的斜面辐照度数据与光伏面板的实际受光强度之间存在偏差, 进而影响功率预测的准确性。

本文通过改进的太阳轨迹模型计算电站内固定倾角光伏面板的有效入射角 θ_{eff} , 并在组件安装倾角 ξ (光伏面板与水平地面的夹角)的基础上对斜面辐照度进行比值校正, 得到更加贴近组件实际受光强度的斜面辐照度数据。该方法所需要的数据均为光伏电站的固定参数, 无需依赖外部的实时气象数据或大量经验性系数。校正方法的计算链如图 1 所示。

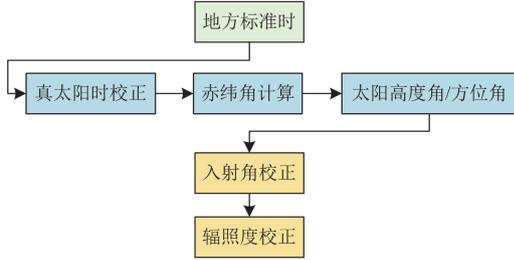


图 1 基于太阳轨迹的斜面辐照度校正方法计算链

Fig. 1 Calculation chain of the inclined irradiance correction method based on solar trajectory

1.1.1 天文参数实时计算

1) 真太阳时校正

真太阳时 T_s 是以太阳实际位置计算的计时方式, 与我国统一使用的北京时间存在差异。为保证太阳高度角和方位角的计算精度, 需对标准时间进行转换, 以获得站点的真太阳时。

真太阳时的校正公式为

$$T_s = T_l + \frac{\lambda}{15} + E_T \quad (1)$$

式中: T_l 表示当地标准时间; λ 为光伏电站所在位置的经度; E_T 为时差, 由日地轨道偏心率计算。

$$E_T = 9.87 \sin(2B) - 7.53 \cos(B) - 1.5 \sin(B) \quad (2)$$

$$B = \frac{2\pi(D-81)}{365} \quad (3)$$

式中: B 表示日角, 反映地球在公转轨道上的位置;

D 表示计算日的天数序号。

2) 改进的太阳赤纬角计算

太阳赤纬角 δ 是指太阳在地球上的纬度角度, 它表示太阳在地球上的位置相对于赤道面的夹角, 变化范围为 $-23.45^\circ \sim +23.45^\circ$ 。中高纬度地区冬季的太阳高度角相对于其他季节会有明显的下降, 为了消除地球公转引起的太阳直射点纬度变化的影响, 需要对年周期内的太阳赤纬角进行计算, 通常采用 Cooper 公式, 如式(4)所示。

$$\delta = 23.45^\circ \times \sin\left(360^\circ \times \frac{284 + D}{365}\right) \quad (4)$$

式中: $(284 + D)$ 为相位项。

由于本研究涉及到的计算期为一年, 无法考虑闰年误差, 为了减少年内计算的累积误差, 将分母项改为更接近地球公转真实周期的 365.25 天; 考虑到相位项与赤纬角的对齐关系, 将其调整为 $(D-80)$ 来更精准地对齐 $\delta = 0^\circ$ 的天文节点, 另外采用弧度制计算便于计算链的连接, 改进后的计算公式为

$$\delta = 23.45^\circ \times \sin\left(\frac{2\pi(D-80)}{365.25}\right) \quad (5)$$

依据式(5)计算得到的年周期误差小于 0.12° 。

3) 太阳高度角与方位角

太阳高度角 α 指太阳光线的入射方向与地平面的夹角, 它决定了太阳辐射穿过大气层时的路径长度, 直接影响到达地面的太阳辐射强度。在冬天太阳高度角较低时, 太阳辐射的大气衰减会显著增加; 太阳方位角 A_z 指太阳光线在水平面上的投影与正北方向的夹角, 它表示太阳在天空中的方位, 决定了太阳在水平面的投影方向。太阳方位角的变化会影响固定倾角组件的有效受光面积^[22]。

太阳高度角和方位角的计算公式分别如式(6)和式(7)所示。

$$\sin \alpha = \sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega \quad (6)$$

$$A_z = \arctan\left(\frac{\sin \omega}{\sin \phi \cos \omega - \cos \phi \tan \delta}\right) \quad (7)$$

式中: ϕ 表示光伏电站所在的地理纬度, 北纬为正, 南纬为负, $-90^\circ \leq \phi \leq 90^\circ$; ω 表示太阳时角, 计算公式为

$$\omega = 15^\circ \times (T_s - 12) \quad (8)$$

1.1.2 入射角动态修正

1) 有效入射角计算

有效入射角 θ_{eff} 是太阳光线与光伏组件法线之间的实际夹角, 表征太阳光线与光伏板之间的空间几何关系, 直接影响组件表面实际接收的辐照强度,

光伏电站内大量的固定倾角光伏板无法跟踪太阳轨迹,其标称倾角仅在特定时段(如正午)与太阳入射角匹配,晨昏时段因太阳高度角 α 变化和方位角 A_2 偏移导致入射角发生显著变化,如图2所示。因此需要在当地的光伏最佳安装角度基础上进行有效入射角修正以适应晨昏时段的光照特点。

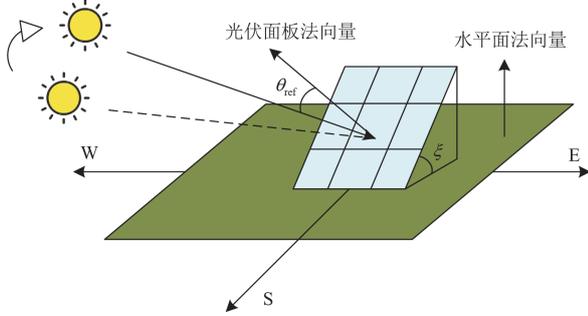


图2 光线入射角随太阳高度变化示意图

Fig. 2 Schematic diagram of the variation of the angle of incidence of light with solar altitude

有效入射角的计算公式为

$$\theta_{\text{eff}} = \arccos[\cos \alpha \cos(A_2 - \gamma) \sin \xi + \sin \alpha \cos \xi] \quad (9)$$

式中: ξ 为组件安装倾角,取当地最佳安装角度; γ 为组件方位角,是指光伏组件安装方向与正南方向(以北半球为例)之间的水平夹角。

2) 斜面辐照度动态校正

在得到太阳的有效入射角后,利用式(10)对原数据集里的斜面辐照度进行动态比值校正,将校正后的斜面辐照度用 G_{eff} 表示,它将更真实地反映光伏组件的受光强度。

$$G_{\text{eff}} = G_{\text{T1}} \times \frac{\cos \theta_{\text{eff}}}{\cos \xi} \quad (10)$$

1.2 基于光电转换模型的物理特征扩展

1.2.1 光电转换物理模型

光伏系统的输出功率特性受光照强度、环境温度及半导体材料属性的综合影响,其核心机理是光电转换效率的动态响应特性。传统静态模型虽能表征基础功率输出,但未充分考虑温度对材料本征效率的影响。针对上述问题,本文提出一种基于特征解耦与温度修正的光电转换特征扩展方法。

所采用的基础光伏电池原理模型如式(11)所示。

$$P = A\eta G \quad (11)$$

式中: A 为有效面积; η 为光电转换效率; G 为辐照度。

由于面积 A 在所有数据样本中保持一致,其影响可以通过归一化处理忽略,因此利用转换效率与辐照度的乘积即可表征光伏系统的相对功率特征,

如式(12)所示。

$$P_r = \eta G \quad (12)$$

式中: P_r 为扩展得到的相对功率特征,它可以反映不同辐照度下光伏输出的变化情况。

对于式(12)中的光电转换效率,考虑温度对光电转换效率的影响,采用光伏行业内常用的估算公式计算其理论值,形式为

$$\eta = \eta_s [1 - \rho(T - 25 \text{ }^\circ\text{C})] \quad (13)$$

式中: η_s 为材料的本征效率; T 为背板温度; ρ 为温度系数,取值在 $0.003 \text{ }^\circ\text{C}^{-1} \sim 0.005 \text{ }^\circ\text{C}^{-1}$ 。

1.2.2 小型前馈网络非线性修正

在得到理论转换效率后,本文引入了一个小型前馈神经网络来对理论效率进行修正,使其符合当下气象条件特征。为了保留物理模型引入的强物理特性,此网络不对转换效率的绝对值进行拟合,而是通过引入残差连接让网络学习转换效率的增量修正 $\Delta\eta$, 具体结构为包含3层隐藏层(神经元数与输入通道数一致)的小型网络,输入为理论转换效率和环境特征,输出为加入残差校正后的理论效率 η' 。该网络的整体结构如图3所示。

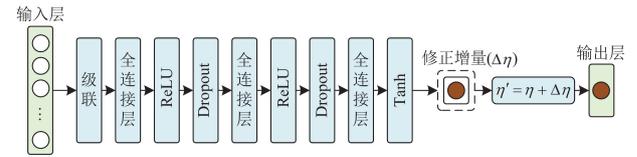


图3 小型前馈网络非线性修正

Fig. 3 A small feedforward network for nonlinear correction

该网络利用3个全连接层来捕捉环境特征,2个ReLU层引入分段线性的非线性激活机制。为了防止过大的修正扰乱原有的物理一致性,在网络的第三个全连接层后使用缩放Tanh函数,确保将生成的增量修正控制在 $[-0.1, 0.1]$ 范围内。最后将修正后的转换效率与对应的辐照度数据相乘,得到相对功率特征。利用光电转换模型强化特征与功率结果之间的关联性,可以为后续的模型训练提供高适用性和高物理一致性的优质扩展数据。

1.3 自适应平滑修正线性单元

1.3.1 激活函数需求分析

对于光伏功率预测任务,激活函数的选取需兼顾以下两个方面:其一,不同物理特征与输出功率之间存在差异化的非线性关联,多特征之间的共同调制作用也具有区域性和天气差异;其二,功率序列自身具有时间连续性和光照上下限约束,因此模型输出曲线需要一定的平滑性。

在传统的CNN-LSTM模型中,为了增强模型的非线性表达能力,往往在卷积层和池化层之间插

入激活函数进行特征映射，所使用的激活函数一般为 ReLU 函数，其数学表达式为

$$\text{ReLU}(x) = \max(x, 0) \quad (14)$$

式中： x 表示经卷积处理后的特征值，当 $x > 0$ 时，函数的输出就是 x 本身；当 $x \leq 0$ 时，输出为 0，这意味着该函数会将所有负特征直接置 0。然而，负特征中可能包含对功率预测具有一定意义的非线性物理信息，简单地将其置 0 可能会抑制模型对这部分特征的学习与表达能力，从而影响预测性能。

针对上述问题，已有研究提出了 Leaky ReLU^[23] (下称 LReLU)、PReLU(Parametric ReLU)^[24] 和 ELU (exponential linear unit)^[25] 等基于 ReLU 的变体形式，它们的数学公式分别为

$$\text{LReLU}(x) = \max(x, 0) + k \cdot \min(x, 0) \quad (15)$$

$$\text{PReLU}(x) = \max(x, 0) + J \cdot \min(x, 0) \quad (16)$$

$$\text{ELU}(x) = \max(x, 0) + J \cdot \min((e^x - 1), 0) \quad (17)$$

式中： k 为固定系数，需要手动赋值； J 为可调节参数，通过梯度反向传播来训练； e^x 表示指数函数。LReLU 通过对负特征赋予固定系数的方式将其引入非线性变换；在此基础上，PReLU 引入可训练的参数 J ，使模型能够自动调整负特征的响应强度。然而，上述两种改进忽略了不同特征之间的差异性；ELU 虽提供了平滑性，但在所有特征上统一使用指数衰减，同样不具备差异化调节能力。

1.3.2 ASReLU

基于上述分析，本文设计了一种改进于 ReLU 的激活函数模块——ASReLU，该函数在正半轴保持与 ReLU 相同的响应形式，在负半轴引入一个修正函数 $s(x) = \frac{\min(x, 0)}{1 + \beta \cdot |\min(x, 0)|}$ 用于平滑度调节，

ASReLU 函数的数学表达式为

$$\text{ASReLU}(x) = \max(x, 0) + a \left(\frac{\min(x, 0)}{1 + \beta \cdot |\min(x, 0)|} \right) \quad (18)$$

式中： a 为自适应参数，其通过反向传播训练获得，它可以使网络根据负特征是否重要来确定其压缩比例。例如，在以晴天或噪声为主导的场景中，负特征所包含的信息较少，对预测结果的贡献有限，网络会通过减小 a 值来压缩负特征；而在阴天或光照不足等情况下，负特征对预测结果的贡献明显，网络则会相应增大 a 值，从而保留更多有用信息； β 为平滑参数，控制负半轴的非线性幅度， β 较大时响应更平滑， β 较小时模型对负特征更敏感。 a 和 β 的共同调节作用使得 ASReLU 能为负特征提供“柔性激活”能力，更适合光伏功率预测任务中的弱辐照、低温等非理想输入情况。图 4 展示了激活函数在 $a = 0.1$ 条件下的可视化曲线。

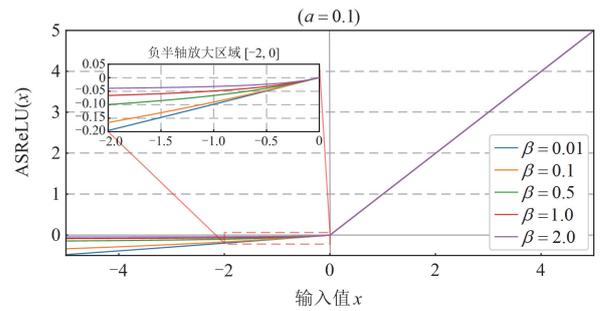


图 4 ASReLU 函数(以 $a = 0.1$ 为例)

Fig. 4 ASReLU function ($a = 0.1$ as an example)

ASReLU 集成了一个特殊设计的子网络^[26]用于生成模型所需的 a 和 β 参数，其整体结构如图 5 所示。

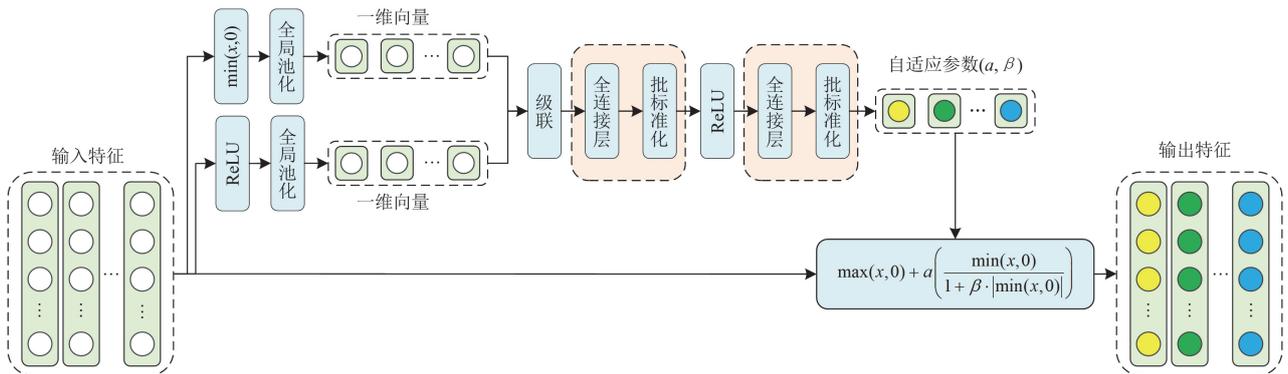


图 5 ASReLU 结构示意图

Fig. 5 Schematic diagram of ASReLU structure

首先，输入特征分别通过 ReLU 函数和 $\min(x, 0)$ 函数，经全局池化后，生成对应的一维向量来表示正、负特征的全局信息。随后，将这两个一维向量

拼接并输入至计算通道，该通道由两个全连接层组成，每层神经元数等于输入特征的通道数，中间嵌入 ReLU 函数用于非线性转换。在获得一组最优的

自适应参数后, 利用 ASReLU 函数完成最终的非线性映射, 将映射结果的形状和格式转换为与输入特征完全相同, 得到最终的输出特征。

1.4 ASReLU-CNN-LSTM 模型

在传统的 CNN-LSTM 模型中引入 ASReLU, 构建 ASReLU-CNN-LSTM 模型, 其整体结构如图 6 所示。图中: h_t 表示 LSTM 单元输出的隐藏状态;

y_t 为输出的预测值; N 为样本数量。模型输入为经斜面辐照度校正及光电转换模型扩展后的特征数据集; 在 CNN 层中, 用 ASReLU 函数替换原有的 ReLU 函数, 由于 ASReLU 的输出特征与输入特征形状一致, 因此可直接替换而无需对网络结构进行额外调整^[26]。

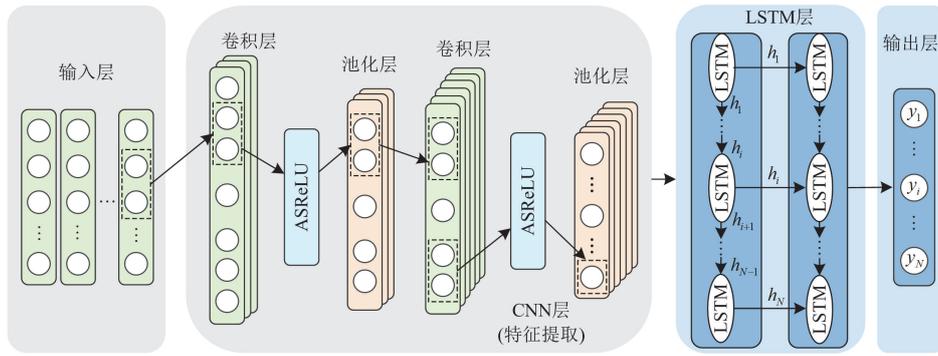


图 6 ASReLU-CNN-LSTM 模型

Fig. 6 ASReLU-CNN-LSTM model

所述方法的流程图如图 7 所示。

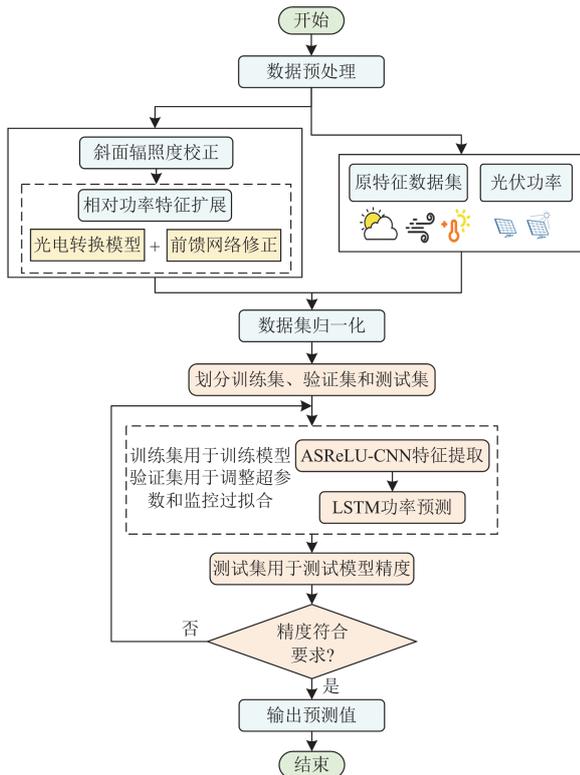


图 7 物理特征扩展的 ASReLU-CNN-LSTM 短期光伏功率预测方法流程图

Fig. 7 Flow chart of ASReLU-CNN-LSTM short-term PV forecasting method based on physical features augmentation

图 7 所示具体流程如下: 1) 对原始数据集进行缺失填补和异常替换; 2) 对数据集进行斜面辐照度校正和相对功率扩展; 3) 对数据集进行归一化后划分为训练集、验证集和测试集; 4) 初始化模型参数, 将训练集放入 ASReLU-CNN-LSTM 模型进行训练, 利用验证集调整超参数和监控过拟合, 利用测试集进行测试; 5) 输出符合精度要求的预测结果。

2 算例分析

2.1 算例设置

实验所依托的硬件平台为: Intel(R) Core(TM) i7-12700H 处理器、NVIDIA GeForce RTX4060 显卡、16.0 GB RAM, 操作系统为 Windows 11。软件开发与运行环境基于 Python 3.9。

2.1.1 数据来源

本文所使用的数据分别来源于黑龙江省某光伏实验基地(II-1 区, 装机容量为 20 MW)与澳大利亚 DAKSC 项目, 分别代表中温带和干旱沙漠地区的典型场景。黑龙江数据集为 2022 年全年数据集, 包含从逆变器采集的电气数据和从电站气象系统采集的数值天气预报(numerical weather prediction, NWP)数据, 采样间隔为 15 min; 澳大利亚数据集为 2024 年全年数据集, 包含有效发电数据及对应气象变量, 采样间隔为 5 min。两个数据集均满足开展短期光伏功率预测的基本要求。

对于异常数据的处理,采用四分位距法识别异常数据点,考虑到光伏功率具有时间相关性,异常数据点通过其前后两个采样时刻的值计算平均值,并以该平均值进行替代。

2.1.2 参数设置

为保证模型训练的一致性,统一设定各模型参数如下:在 CNN 部分,设置 3 层卷积结构,卷积核大小均为 3×1 ,卷积核数量依次为 32、32、64;在 ASReLU 中,参数 a 由其内部子网络通过反向传播自动学习获得,由子网络给出,在设定平滑参数 β 的初值时,为了避免在初期训练时激活值波动过大,导致训练不稳定,将 β 的初始值设置为 0.1;在 LSTM 部分,设置训练轮数为 100,批大小为 32,优化器选用 Adam,初始学习率设置为 0.0001,损失函数采用均方误差(mean squared error, MSE)。

2.1.3 评价指标

考虑到光伏发电功率有量级变化,且这种量级变化可能体现在归一化均方根误差(root mean square error, RMSE)、归一化平均绝对误差(mean absolute error, MAE)的量级上^[27]。为排除尺度影响,实验同时引入归一化均方根误差、归一化平均绝对误差和决定系数 R^2 作为模型性能评估指标。上述评价指标的计算公式如下所示。

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (19)$$

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (20)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (21)$$

式中: e_{RMSE} 、 e_{MAE} 分别为归一化均方根误差和归一化平均绝对误差; y_i 为真实值; \hat{y}_i 为预测值; \bar{y} 为样本的平均值; n 为样本数量。

2.2 斜面辐照度校正结果分析

为验证所提出的斜面辐照度校正方法的有效性,分别选取晴天、雨天与多云 3 种典型天气情景,并以 2022 年 4 月 16 日、8 月 8 日、10 月 29 日和 12 月 10 日分别作为春、夏、秋、冬四季代表日期,进行全天候、多季节的实证分析。校正结果如图 8 和图 9 所示。

从图 8 可以观察到,校正后的斜面辐照度曲线更符合光伏功率的变化趋势,特别是在晴天天气下,校正后的曲线大大减小了晨昏高估误差,并在峰值时段展现出更优的跟随能力。

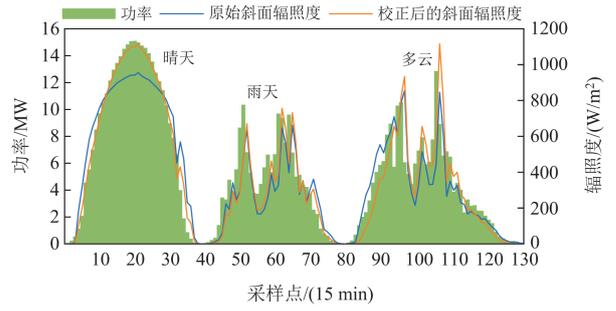


图 8 不同天气下的斜面辐照度校正效果对比

Fig. 8 Comparison of inclined irradiance correction effects under different weather conditions

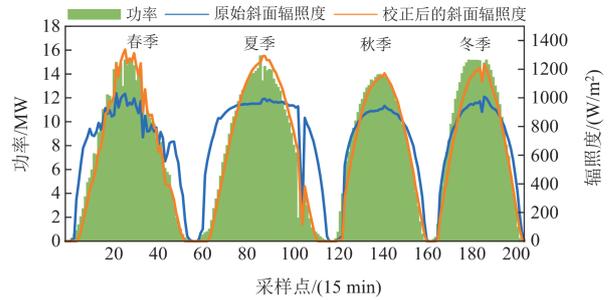


图 9 不同季节的斜面辐照度校正效果对比

Fig. 9 Comparison of inclined irradiance correction effects across different seasons

从图 9 可以观察到,在春、夏、秋、冬各季节中,校正后的曲线均与实际光伏功率趋势保持更好的一致性。具体而言,在春夏季,原始斜面辐照度曲线于晨昏时段表现出显著的高估,而在正午时段则存在低估现象,经校正后,该误差得到显著修正;在秋冬季,校正方法在改善正午与黄昏时段的辐照度方面表现尤为明显。值得指出的是,在进入秋冬季后,原始斜面辐照度曲线于清晨时段在部分情况下与功率曲线的拟合程度更优。分析认为,这可能源于太阳高度角的降低使得太阳辐射在穿越大气层时路径延长,而东北地区在秋冬季节空气质量普遍较差,增强的大气衰减效应在一定程度上弥补了辐照度估计的高偏差。尽管如此,校正后的曲线在整体趋势上仍然更加符合光伏输出功率的变化趋势。

以上分析表明,所提出的斜面辐照度校正方法可在全年范围内有效消除光伏系统在日周期内的几何失配误差,增强数据的物理一致性。

2.3 特征扩展前后的对比实验分析

利用原始的 CNN-LSTM 模型对提出的特征扩展方法进行对比实验分析。原始数据集和扩展后的数据集均选取 05:30—18:30 时间段的样本点,按照 6:3:1 的比例划分训练集、验证集和测试集,扩

展前后的预测效果对比如图 10 所示。由图可知, 扩展后的数据集在预测精度和预测稳定性方面均有所提升, 验证了本文提出的特征扩展方法的有效性。

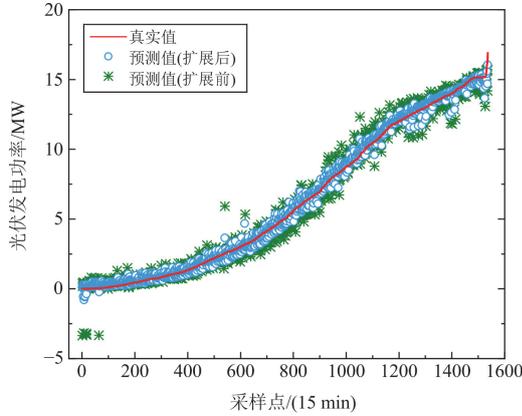


图 10 特征扩展前后的预测结果

Fig. 10 Forecast results before and after feature expansion

2.4 平滑参数 β 的敏感性分析

为研究平滑参数 β 对预测性能的影响, 在保持其他参数不变的条件下, 设置 $a = 0.1$, $\beta \in \{0.01, 0.05, 0.1, 0.5, 1.0\}$, 在黑龙江数据集晴天场景下训练 ASReLU-CNN-LSTM 模型。以预测曲线一阶差分的均方值(mean squared error of differences, MSED)表征预测曲线的波动度, 该指标计算公式为

$$e_{\text{MSED}} = \frac{1}{L-1} \sum_{t=2}^L (\Delta y_t)^2 = \frac{1}{L-1} \sum_{t=2}^L (y_t - y_{t-1})^2 \quad (22)$$

式中: L 表示采样序列的总长度; Δy_t 表示第 t 个采样点的一阶差分; y_t 表示第 t 个采样点的预测值。通过对比 β 不同取值下模型的预测误差指标和波动度来评价 β 对模型性能的影响。实验结果如图 11 所示, 误差指标和波动度信息如表 1 所示。

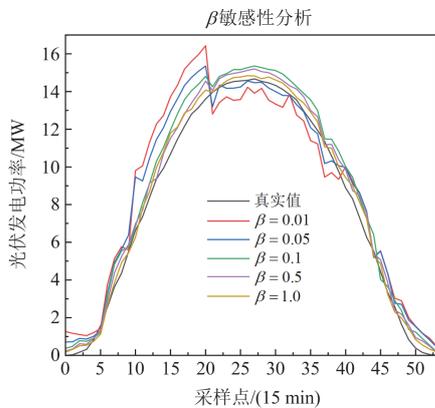


图 11 不同 β 取值下模型的预测结果对比

Fig. 11 Comparison of the prediction results of the model under different β values

表 1 不同 β 取值下的指标对比

Table 1 Comparison of indicators with different smoothing

parameter β configurations				
β 的取值	$e_{\text{RMSE}}/\text{MW}$	e_{MAE}/MW	R^2	$e_{\text{MSED}}/\text{MW}^2$
0.01	1.57	1.29	0.87	1.22
0.05	1.16	0.90	0.89	0.86
0.1	0.82	0.75	0.94	0.43
0.5	0.59	0.53	0.95	0.38
1.0	0.44	0.37	0.97	0.29

由图 11 和表 1 可以看出, β 值较小时, ASReLU 引入了较多的负特征信息, 造成预测曲线波动剧烈。随着 β 值的增大, 模型输出曲线的波动度逐渐降低, 预测精度也有所提升。这表明, 在辐照稳定的晴天条件下, 输入特征中负值信息相对较少, 适度压缩负半轴响应有助于提升预测曲线的平滑性并抑制不必要的噪声, 从而提升整体预测效果。因此, 控制负特征在网络中的参与度, 在准确性与平滑性之间实现平衡, 是优化模型性能的关键。

2.5 ASReLU-CNN-LSTM 模型预测结果分析

为了验证本文所提出的 ASReLU 激活函数的有效性, 根据历史天气预报和数据特征选取黑龙江地区典型的晴天、多云、雨天和雪天 4 类天气, 设置 CNN-LSTM、LSTM 和 CNN 3 种模型进行对比实验。每种天气类型下选取 10 天数据, 经预处理和特征扩展后, 按照 6:3:1 的比例划分为训练集、验证集和测试集, 输入至模型中进行预测。本文模型的预测结果用红色曲线表示。

2.5.1 不同天气场景下的预测结果对比

不同天气场景下的预测曲线图分别如图 12—图 15 所示。

由图 12—图 15 可知, 相较于其他模型, 本文所提出的 ASReLU-CNN-LSTM 模型在各类天气条件下的预测曲线都更接近真实值曲线; 进一步求取各模型的 RMSE、MAE 以及 R^2 指标, 结果见表 2。

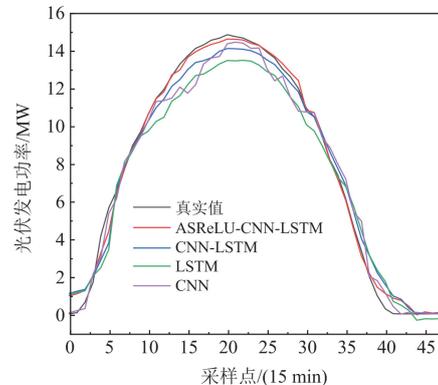


图 12 不同模型晴天时预测曲线

Fig. 12 Prediction curves of different models on a sunny day

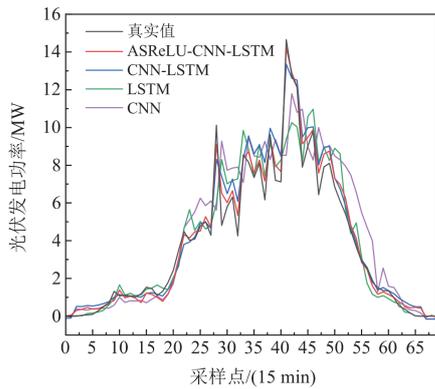


图 13 不同模型多云时预测曲线

Fig. 13 Prediction curves of different models on a cloudy day

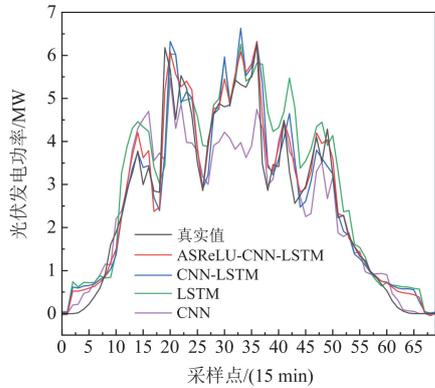


图 14 不同模型雨天时预测曲线

Fig. 14 Prediction curves of different models on a rainy day

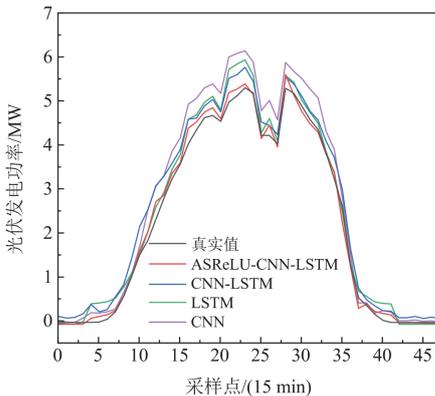


图 15 不同模型雪天时预测曲线

Fig. 15 Prediction curves of different models on a snowy day

由表 2 可知，相较于传统 CNN-LSTM 模型，ASReLU-CNN-LSTM 模型在各类天气下的 RMSE 与 MAE 均显著降低， R^2 均有所提高。在晴天时，本文方法在测试集上的 RMSE、MAE 以及 R^2 值分别为 0.17 MW、0.13 MW 以及 0.99，两个误差指标

分别下降 43.33% 和 43.47%， R^2 提升 0.01；雨天条件下，3 项指标分别为 0.40 MW、0.30 MW 以及 0.96，两个误差指标分别下降 33.33% 和 23.07%， R^2 提升 0.06。上述结果表明，ASReLU 激活函数显著增强了模型在不同天气场景下的特征提取能力，从而提高了模型的预测精度与鲁棒性。

表 2 不同天气下各个模型误差对比表

Table 2 Error comparison of different models in different weather conditions

天气	模型	e_{RMSE}/MW	e_{MAE}/MW	R^2
晴天	ASReLU-CNN-LSTM	0.17	0.13	0.99
	CNN-LSTM	0.30	0.23	0.98
	LSTM	0.34	0.29	0.98
	CNN	0.51	0.40	0.96
多云	ASReLU-CNN-LSTM	0.49	0.37	0.98
	CNN-LSTM	0.79	0.54	0.95
	LSTM	1.26	0.74	0.88
	CNN	1.73	1.20	0.77
雨天	ASReLU-CNN-LSTM	0.40	0.30	0.96
	CNN-LSTM	0.60	0.39	0.90
	LSTM	0.76	0.52	0.85
	CNN	0.85	0.61	0.81
雪天	ASReLU-CNN-LSTM	0.41	0.28	0.99
	CNN-LSTM	0.69	0.56	0.98
	LSTM	0.76	0.57	0.97
	CNN	1.05	0.92	0.94

2.5.2 不同气候区的泛化性验证

为评估所提方法的泛化能力，选取澳大利亚数据作为典型干旱沙漠气候场景的验证对象。由于该地区全年未出现降雪，故仅设置晴天、多云和雨天 3 种典型的天气场景进行试验。

除 CNN-LSTM 模型外，为增强对比的全面性，进一步引入 CNN-BiGRU、TCN-Attention 及 XGBoost 模型作为对比模型。3 类天气下的预测结果分别如图 16—图 18 所示，本文所提模型的预测结果同样以红色曲线表示。

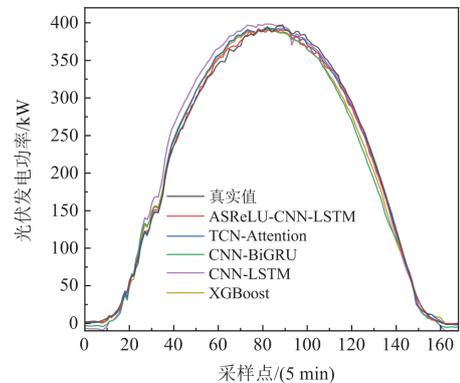


图 16 不同模型晴天时预测结果

Fig. 16 Prediction results of different models on a sunny day

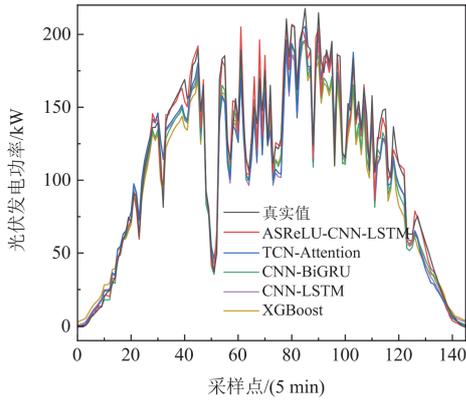


图 17 不同模型多云时预测结果

Fig. 17 Prediction results of different models on a cloudy day

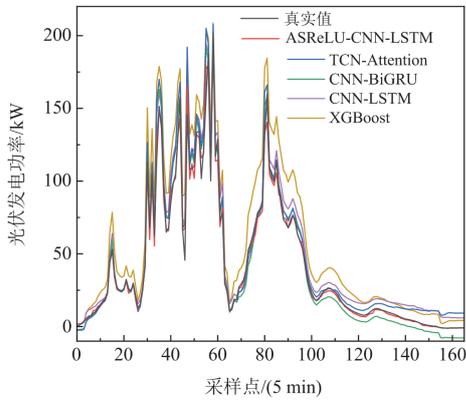


图 18 不同模型雨天时预测结果

Fig. 18 Prediction results of different models on a rainy day

由图 16—图 18 可知, ASReLU-CNN-LSTM 模型的预测曲线与真实曲线最为贴合, 优于其他对比模型。进一步计算 RMSE、MAE 与 R^2 指标, 结果见表 3。

由表 3 可知, 相较于 CNN-LSTM 模型, 在晴天条件下, 本文模型在测试集上的 RMSE、MAE 和 R^2 指标分别为 4.67 kW、2.40 kW 和 0.985, 两项误差指标分别下降 44.14% 和 64.07%, R^2 提升 0.019; 在雨天条件下, 3 项指标分别为 8.24 kW、5.65 kW 和 0.968, 两项误差指标分别下降 39.46% 和 48.07%, R^2 提升 0.056。结果表明, ASReLU 激活函数在干旱沙漠地区同样具备优秀的特征学习能力与非线性建模能力。

相较于其他模型, ASReLU-CNN-LSTM 同样表现出良好的性能。XGBoost 作为基于集成学习的梯度提升树模型, 在晴天场景下表现良好, 但由于其建模机制偏线性^[28], 导致在多云与雨天场景下 RMSE 与 MAE 显著上升, 雨天时甚至出现所有模型中最大的误差值; CNN-BiGRU 模型通过门控机

表 3 不同天气下各个模型误差对比表

Table 3 Error comparison of different models in different weather conditions

天气	模型	e_{RMSE}/kW	e_{MAE}/kW	R^2
晴天	ASReLU-CNN-LSTM	4.67	2.40	0.985
	TCN-Attention	7.39	5.60	0.978
	CNN-BiGRU	8.03	6.47	0.974
	CNN-LSTM	8.36	6.68	0.965
	XGBoost	6.52	5.26	0.980
多云	ASReLU-CNN-LSTM	4.92	3.65	0.976
	TCN-Attention	9.51	6.09	0.967
	CNN-BiGRU	7.72	5.52	0.970
	CNN-LSTM	9.77	7.82	0.947
	XGBoost	15.55	12.64	0.903
雨天	ASReLU-CNN-LSTM	8.24	5.65	0.968
	TCN-Attention	12.84	10.15	0.945
	CNN-BiGRU	12.92	10.37	0.939
	CNN-LSTM	13.61	10.88	0.912
	XGBoost	17.79	14.21	0.863

制提升时序特征建模能力, 在复杂天气下优于 XGBoost, 但整体表现仍不如本文模型; TCN-Attention 模型结合了时间卷积与注意力机制, 提升了对时序依赖特征的处理能力, 但因传统 TCN 结构对局部特征适应能力有限, 整体误差依旧高于本文模型。上述结果验证了 ASReLU-CNN-LSTM 模型在多变气象条件与复杂气候条件下的强适应性与良好泛化能力。

3 结论

本文提出了一种物理特征扩展的 ASReLU-CNN-LSTM 短期光伏功率预测方法。该方法首先基于改进的太阳轨迹模型对斜面辐照度数据进行校正, 进而通过光电转换模型对辐照度数据进行相对功率特征扩展, 在此基础上设计 ASReLU 激活函数替代传统 ReLU, 提升 CNN-LSTM 模型的特征提取能力。结合黑龙江(中温带)与澳大利亚(干旱沙漠)两地区光伏电站数据, 开展方法有效性与泛化能力对比实验, 得出以下结论。

1) 在中温带气候区, ASReLU-CNN-LSTM 模型在多种天气条件下均优于 CNN-LSTM、LSTM 与 CNN 等对比模型, 尤其在复杂气象条件下, 其预测曲线与真实值拟合更佳, 验证了 ASReLU 激活函数在提升模型预测稳定性方面的作用。

2) 在干旱沙漠气候区, ASReLU-CNN-LSTM 同样展现出良好的预测精度与稳定性。ASReLU 增强了模型对输入特征间及输入特征与光伏功率间复杂

非线性关系的建模能力,从而提升了模型在复杂天气条件下的表现,展现出较强的区域泛化能力。

本文所提方法在两个不同气候区的短期光伏功率预测任务中均表现出良好的预测性能,后续工作将进一步面向多气候区、多时间尺度的预测任务,探索模型在多气候区光伏电站部署中的实用性并提升其推理效率。

参考文献

- [1] 贾凌云, 云斯宁, 赵泽妮, 等. 神经网络短期光伏发电预测的应用研究进展[J]. 太阳能学报, 2022, 43(12): 88-97.
JIA Lingyun, YUN Sining, ZHAO Zeni, et al. Recent progress of short-term forecasting of photovoltaic generation based on artificial neural networks[J]. Acta Energetica Solaris Sinica, 2022, 43(12): 88-97.
- [2] 王光华, 张纪欣, 崔良, 等. 基于双重注意力变换模型的分布式屋顶光伏变电站级日前功率预测[J]. 全球能源互联网, 2024, 7(4): 393-405.
WANG Guanghua, ZHANG Jixin, CUI Liang, et al. Substation-level distributed rooftop photovoltaic power day-ahead prediction based on double attention mechanism transformer model[J]. Journal of Global Energy Interconnection, 2024, 7(4): 393-405.
- [3] 宋文乐, 张焯, 刘航旭, 等. 基于光伏组件老化特性解耦的渔光互补光伏短期出力预测方法[J]. 电力建设, 2024, 45(7): 25-33.
SONG Wenle, ZHANG Ye, LIU Hangxu, et al. Short-term output prediction method for complementary fishing and solar power decoupling the aging characteristics of photovoltaic modules[J]. Electric Power Construction, 2024, 45(7): 25-33.
- [4] 黄泽, 毕贵, 谢旭, 等. 基于 MBI-PBI-ResNet 的超短期光伏功率预测[J]. 电力系统保护与控制, 2024, 52(2): 165-176.
HUANG Ze, BI Guihong, XIE Xu, et al. Ultra-short-term PV power prediction based on MBI-PBI-ResNet[J]. Power System Protection and Control, 2024, 52(2): 165-176.
- [5] 吐松江·卡日, 吴现, 马小晶, 等. 基于地基云图数据多维特征融合的光伏功率预测算法[J]. 电力系统保护与控制, 2025, 53(11): 84-94.
TUSONGJIANG·Kari, WU Xian, MA Xiaojing, et al. Photovoltaic power prediction algorithm based on multidimensional features fusion of ground-based cloud images[J]. Power System Protection and Control, 2025, 53(11): 84-94.
- [6] 董存, 王铮, 白捷予, 等. 光伏发电功率超短期预测方法综述[J]. 高电压技术, 2023, 49(7): 2938-2951.
DONG Cun, WANG Zheng, BAI Jieyu, et al. Review of ultra-short-term forecasting methods for photovoltaic power generation[J]. High Voltage Engineering, 2023, 49(7): 2938-2951.
- [7] 于丹文, 李山, 刘航航, 等. 基于3DCNN与CLSTM混合模型的短期光伏功率预测[J]. 山东电力技术, 2024, 51(7): 10-18.
YU Danwen, LI Shan, LIU Hanghang, et al. Short-term photovoltaic power prediction based on 3DCNN and CLSTM hybrid model[J]. Shandong Electric Power, 2024, 51(7): 10-18.
- [8] ZHOU Xia, ZHANG Xize, DAI Jianfeng, et al. Photovoltaic power prediction technology based on multi-source feature fusion[J]. Symmetry, 2025, 17(3).
- [9] 张俊蔚. 基于物理模型的光伏电站输出功率预测[J]. 甘肃水利水电技术, 2015, 51(1): 46-49.
- [10] CUI Chenggang, ZOU Yuhang, WEI Liaoliao, et al. Evaluating combination models of solar irradiance on inclined surfaces and forecasting photovoltaic power generation[J]. IET Smart Grid, 2019, 2(1): 123-130.
- [11] MAYER M J, GRÓF G. Extensive comparison of physical models for photovoltaic power forecasting[J]. Applied Energy, 2021, 283.
- [12] OLIVEIRA S L, ALSKAIF T, BARROSO G C, et al. Photovoltaic power estimation and forecast models integrating physics and machine learning: a review on hybrid techniques[J]. Solar Energy, 2024, 284.
- [13] WANG Xiaoyang, SUN Yunlin, LUO Duo, et al. Comparative study of machine learning approaches for predicting short-term photovoltaic power output based on weather type classification[J]. Energy, 2022, 240.
- [14] 高寒旭, 袁祖晴, 张淑婷, 等. 基于 LSTM 模型的短期光伏功率预测[J]. 太阳能学报, 2024, 45(6): 376-381.
GAO Hanxu, YUAN Zuqing, ZHANG Shuting, et al. Short-term photovoltaic power prediction based on LSTM model[J]. Acta Energetica Solaris Sinica, 2024, 45(6): 376-381.
- [15] 雷柯松, 吐松江·卡日, 伊力哈木·亚尔买买提. 等. 基于 WGAN-GP 和 CNN-LSTM-Attention 的短期光伏功率预测[J]. 电力系统保护与控制, 2023, 51(9): 108-118.
LEI Kesong, TUSONGJIANG·Kari, YILIHAMU·Yaermaimait, et al. Prediction of short-term photovoltaic power based on WGAN-GP and CNN-LSTM-Attention[J]. Power System Protection and Control, 2023, 51(9): 108-118.
- [16] 韩晓, 王涛, 韦晓广, 等. 考虑阵列间时空相关性的超短期光伏出力预测[J]. 电力系统保护与控制, 2024, 52(14): 82-94.
HAN Xiao, WANG Tao, WEI Xiaoguang, et al. Ultrashort-

- term photovoltaic output forecasting considering spatiotemporal correlation between arrays[J]. *Power System Protection and Control*, 2024, 52(14): 82-94.
- [17] 阮广春, 何一鏊, 谭振飞, 等. 面向新型电力系统运行的数据-物理融合建模综述[J]. *中国电机工程学报*, 2024, 44(13): 5021-5037.
- RUAN Guangchun, HE Yiliu, TAN Zhenfei, et al. Review of hybrid data-driven and physics-based modeling for the operation of new-type power systems[J]. *Proceedings of the CSEE*, 2024, 44(13): 5021-5037.
- [18] CHEN Fan, DING Jinjin, ZHANG Qian, et al. A PV power forecasting based on mechanism model-driven and stacking model fusion[J]. *Journal of Electrical Engineering & Technology*, 2024, 19(8): 4683-4697.
- [19] 谈玲, 康瑞星, 夏景明, 等. 融合多源异构气象数据的光伏功率预测模型[J]. *电子与信息学报*, 2024, 46(2): 503-517.
- TAN Ling, KANG Ruixing, XIA Jingming, et al. A photovoltaic power prediction model integrating multi-source heterogeneous meteorological data[J]. *Journal of Electronics & Information Technology*, 2024, 46(2): 503-517.
- [20] 王东风, 宁笑歌, 张博洋, 等. 基于斜面辐照度机理模型的光伏功率组合模型预测研究[J/OL]. *华北电力大学学报(自然科学版)*: 1-14[2025-03-04]. <https://kns-cnki-net.webvpn.nepu.edu.cn/kcms/detail/13.1212.tm.20241122.1546.002.html>
- WANG Dongfeng, NING Xiaoge, ZHANG Boyang, et al. Research on photovoltaic power combination model prediction based on tilted irradiance mechanism model[J/OL]. *Journal of North China Electric Power University (Natural Science Edition)*: 1-14[2025-03-04]. <https://kns-cnki-net.webvpn.nepu.edu.cn/kcms/detail/13.1212.tm.20241122.1546.002.html>
- [21] 张沛, 刘金城, 张彬, 等. 面向光伏发电预测的公开数据集综述[J]. *电力信息与通信技术*, 2023, 21(8): 16-21.
- ZHANG Pei, LIU Jincheng, ZHANG Bin, et al. A review of public datasets for photovoltaic power generation forecasting[J]. *Electric Power Information and Communication Technology*, 2023, 21(8): 16-21.
- [22] RAMADHAN R A A, HEATUBUN Y R J, TAN S F, et al. Comparison of physical and machine learning models for estimating solar irradiance and photovoltaic power[J]. *Renewable Energy*, 2021, 178: 1006-1019.
- [23] MAAS A L, HANNUN A Y, NG A Y. Rectifier nonlinearities improve neural network acoustic models[C] // *Proceedings of the International Conference on Machine Learning*, June 16-21, 2013, Atlanta, USA: 1-3.
- [24] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Delving deep into rectifiers: surpassing human-level performance on imagenet classification[C] // *IEEE International Conference on Computer Vision*, December 7-13, 2015, Santiago, Chile: 1026-1034.
- [25] CLEVERT D A, UNTERHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units (ELUS)[J]. *Computer Science*, 2015, 44.
- [26] ZHAO Minghang, ZHONG Shisheng, FU Xuyun, et al. Deep residual networks with adaptively parametric rectifier linear units for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2020, 68(3): 2587-2597.
- [27] ZHANG Biao, ZHANG Ying, JIANG Xuchu. Feature selection for global tropospheric ozone prediction based on the BO-XGBoost-RFE algorithm[J]. *Scientific Reports*, 2022, 12(1).
- [28] 李永飞, 张耀, 林帆, 等. 基于气候特征分析及改进 XGBoost 算法的中长期光伏电站发电量预测方法[J]. *电力系统保护与控制*, 2024, 52(11): 84-92.
- LI Yongfei, ZHANG Yao, LIN Fan, et al. Medium-and long-term power generation forecast based on climate characterisation and an improved XGBoost algorithm for photovoltaic power plants[J]. *Power System Protection and Control*, 2024, 52(11): 84-92.

收稿日期: 2025-03-06; 修回日期: 2025-06-27

作者简介:

刘伟(1971—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为智能监测与诊断系统、可再生能源与智能控制; E-mail: 442780146@qq.com

李洋洋(1999—), 男, 硕士研究生, 研究方向为光伏功率预测。E-mail: 2399658624@qq.com

(编辑 魏小丽)