引用格式:史文瑜,张珍翼,杨德昌.基于时间序列大模型TimeGPT光伏功率预测方法研究[J].电力科学与技术学报,2025,40(4):150-160.
Citation: Shi Wenyu, Zhang Zhenyi, Yang Dechang. Research on the photovoltaic power forecast method based on time series large model TimeGPT [J]. Journal of Electric Power Science and Technology,2025,40(4):150-160.

基于时间序列大模型TimeGPT光伏功率预测方法研究

史文瑜,张珍翼,杨德昌
(中国农业大学信息与电气工程学院,北京市 100083)

摘　要:目前,各种统计和机器模型已经广泛的应用到光伏功率预测中,但在光伏历史数据稀缺的情况下,这些方法普遍存在预测准确性较低的情况。为此,将时间序列大模型(time generative pre-trained transformer,TimeGPT)引入到光伏功率短期预测中。先基于1 000亿数据点的大规模和多样化的时间序列数据集(如金融、交通、银行、网络流量、天气、能源、医疗等)构建时间序列大模型;再利用少量光伏功率历史数据对TimeGPT进行微调,以适应与光伏发电功率预测相关的数据分布和特征;然后,在具有用户隐私的光伏数据集中进行仿真,并与现有统计和机器模型进行对比。以案例1为例,当预测步长为1 h时,TimeGPT的平均绝对误差(mean absolute error, MAE)较对比模型的均有所降低;最后,总结了TimeGPT应用条件和改进方向。该文可为TimeGPT在新型电力系统中的应用提供借鉴。

关　键　词:机器学习;光伏功率预测;时间序列大模型;新型电力系统
DOI:10.19781/j.issn.1673-9140.2025.04.014　　**中图分类号**:TM615　　**文章编号**:1673-9140(2025)04-0150-11

Research on photovoltaic power forecasting method based on time series large model TimeGPT

SHI Wenyu, ZHANG Zhenyi, YANG Dechang
(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Currently, various statistical and machine models have been widely applied to photovoltaic (PV) power forecasting, but low forecasting accuracy is common with scarce PV historical data. Therefore, a time generative pre-trained transformer (TimeGPT) is introduced into the short-term forecasting of PV power. Firstly, a time series large model is constructed based on a large-scale and diverse time series dataset of 100 billion data points (such as finance, traffic, banking, network traffic, weather, energy, and healthcare). Then, TimeGPT is fine-tuned using a small amount of PV power historical data to adapt to the data distribution and characteristics related to PV power forecasting. TimeGPT is simulated in the PV dataset with user privacy and compared with existing statistical and machine models. By taking case 1 as an example, the mean absolute error (MAE) of TimeGPT is reduced compared with the comparison models when the forecasting step is 1 h. Finally, the conditions for TimeGPT application and the direction of improvement are summarized for its application in new electric power systems.

Key words: machine learning; photovoltaic power forecasting; time series large model; new electric power system

随着全球对可再生能源的需求不断增长,光伏发电作为一种清洁、可持续的能源形式,正在成为能源领域的重要组成部分。然而,光伏发电存在着波动性和不确定性,光伏并网会对电力系统的稳定

收稿日期:2024-07-19;**修回日期**:2025-07-08
基金项目:国家自然科学基金智能电网联合基金重点项目(U2166208)
通信作者:杨德昌(1983—),男,博士,教授,主要从事电力系统运行优化、综合能源系统运行等方面的研究;E-mail:yangdechang@cau.edu.cn

性带来许多不利影响[1-2]。因此，精确预测光伏发电功率成为当今能源领域的热点问题之一。精确的预测不仅可以帮助电力系统更好地调配各种能源资源、确保电网的平稳运行，还可以为能源规划、经济效益和环境保护等提供重要支持。

光伏发电功率时间序列预测可据时间尺度可分为 4 类[3-4]：长期预测（1 至 10 年）和中期预测（1 周至几个月）主要用于电网的长期与中期规划和电站的运维；短期预测（1 小时至 1 周）主要用于优化经济负荷分配和电力系统的运行；超短期预测（不到 1 小时）对电力市场定价、实时调度以及确保电网安全运行至关重要。过去几十年来，人们提出了各种预测方法，这些方法大致分为 2 大类：统计模型和机器学习模型[5]。

统计模型通过分析历史数据中的趋势和周期性来估计未来的负荷值。经典的统计模型包括持续性模型（persist model，PM）、自回归移动平均（auto-regressive moving average model，ARMA）、指数平滑、自回归积分移动平均（auto-regressive integrated moving average model，ARIMA）、线性回归（linear regression，LR）、自适应滤波模型和灰色模型等。文献[6-7]使用 ARIMA 模型来预测分布式光伏发电出力。文献[8-9]引入了改进支持向量机（support vector regression，SVR）模型，对轨道交通光伏发电进行预测。文献[10]建立了基于自回归积分移动模型 ARIMA 和支持向量回归的功率预测模型，以实现光伏电站超短期功率的实时跟踪和预测。文献[11]通过对灰色模型拟合值的相对残差序列进行分析，建立了灰色马尔可夫链预测模型。这些统计模型都基于严格的数学定理，具有较高的可解释性和相对较低的计算成本，并不需要大量的历史数据，在短期预测中表现良好。

然而，统计模型的预测效果也受限于数据的质量和模型的选择。当数据受到复杂的非线性关系或极端天气影响时，应结合机器学习来进一步提升预测精度。通常，在光伏功率预测中的机器学习模型使用监督学习来预测历史数据与预测值之间的非线性关系。流行的机器学习模型包括回归树（regession tree，RT）、支持向量回归（surporting vector regression，SVR）、极梯度提升（extreme gradient boosting，XGBoost）、轻梯度提升机（light gradient boosting machine，LightGBM）、多层感知器（multilayer perceptron，MLP）、长短期记忆（long short term memory，LSTM）、门控递归单元（gate recurrent unit，GRU）、变压器神经网络（tensorizing neural network，TNN）、卷积神经网络（convolutional neural network，CNN）和图神经网络（graph neural network，GNN）[12]等。文献[13]提出了一种基于主成分分析法（principal component analysis，PCA）、变分模态分解（variational modal decomposition，VMD）和多元宇宙算法（multi verse optimizer，MVO）的对 SVM 进行优化的光伏输出功率短期预测组合模型，极大地提高了预测的准确性。文献[14]利用贝叶斯-长短期记忆神经网络（bayesian-long short-term memory，B-LSTM）预测分布式光伏出力需求，且其还考虑到分布式光伏的时空关联性。文献[15]采用了 CNN 和 LSTM 相结合的光伏功率预测模型。为从光伏数据中捕捉时间特征，文献[16-17]分别提出了 XGBoost 模型和 GRU 模型。仿真分析表明，在短期光伏功率预测方面，XGBoost 和 GRU 优于传统模型（如 MLP）。文献[18]提出了一种基于卷积神经网络-门控循环单元、改进麻雀搜索算法（improved squirrel search algorithm，ISSA）优化的 XGBoost 模型的短期光伏功率预测组合模型，该模型比单个模型具有更强的适应性和更高的精度。文献[19]针对非晴天天气类型历史数据量匮乏导致光伏功率预测精度低的问题，提出了一种含有梯度惩罚的改进生成对抗网络（wasserstein generative adversarial network with gradient genalty，WGAN-GP）和 CNN-LSTM-Attention 的光伏功率短期预测模型。文献[20]构建了一种基于改进灰狼学习算法（improved grey wolf optimization，IGWO）的脉冲神经网络（spiking neural network，SNN），并将其应用到光伏出力短期预测中。文献[21]针对光伏发电功率随机性和波动性较强、预测精度较低的问题，提出了一种基于变分模态分解 VMD 和改进松鼠觅食算法优化核极限学习机（improved squirrel search algorithm optimization kernel extreme learning machine，ISSA-KELM）的预测模型。总体而言，在处理大规模光伏功率数据时，机器学习模型可为光伏短期预测提供较高的预测准确性。这主要归功于它们自动从数据中提取潜在特征的能力与对复杂非线性关系的良好适应能力。

但是，机器学习模型需要大量数据进行训练，才能准确映射复杂的非线性关系。当历史训练数据匮乏时，这些机器学习模型的预测准确性就会降低[22-23]。在一些新兴市场或新建的社区，光伏发电设施尚未完善，这就导致该地缺乏足够的历史光伏

发电数据。此外,出于用户隐私考虑,公用事业公司可能无法获得详细的光伏发电数据。在这些情况下,机器学习模型可能会受到数据稀缺的限制,其预测准确性面临挑战。

近些年,预训练的大模型极大地推动了自然语言处理(natural language processing, NLP)、计算机视觉(computer vision, CV)和语音理解的快速发展。大型语言模型(large language model, LLM)中的 ChatGPT[24]和 Llama[25]在各种自然语言处理任务中表现出色;同样地,Midjourney[26]和 Sora[27]可以根据用户提示分别生成各种类型的图像和视频。大模型在不同任务中的能力也推动着时间序列建模中大模型的开发和应用。文献[28]提出了一种利用时间序列数据建模的时间序列大模型(time generative pre-trained transformer, TimeGPT)。其在 1 000 亿个数据点(如金融、交通、银行、网络流量、天气、能源、医疗保健等)上进行了训练,在少量学习任务(如空气质量和交通预测)中表现出了良好的性能。这为新能源发电预测带来了新的机遇,尤其是在历史数据稀缺的情况下。文献[29]利用 TimeGPT 对不同的负荷数据集进行训练与预测,其在历史数据稀缺下较短的预测时间内表现出了良好的性能。

综上所述,为解决传统的统计模型和机器学习模型在历史数据稀缺条件下,短期光伏发电功率预测性能较低的问题,本文将时间序列大模型 TimeGPT 引入到光伏功率预测中。先详细阐述 TimeGPT 的基本原理,并基于 1 000 亿数据点的大规模和多样化时间序列数据集,构建时间序列大模型;再利用真实的光伏发电数据对 TimeGPT 进行微调,并与传统统计模型和机器学习模型进行了全面的详细的对比分析;然后,验证 TimeGPT 在历史数据稀缺的条件下的短期光伏功率预测的优势,进一步对 TimeGPT 的应用条件和改进方向进行了总结;最后,对 TimeGPT 在新型电力系统中的应用前景进行展望。

1 TimeGPT 的构成与使用

1.1 TimeGPT 的架构

TimeGPT 以具有注意力机制的 Transformer 架构作为其核心构建,Transformer 块的基本架构如图 1 所示。

从图 1 中可以看出,Transformer 模型是一种基于注意力机制的神经网络模型,其由编码器和解码器两部分组成,这二者均是 Transformer 模型的核心。编码器负责将输入序列编码成一个高维向量,而解码器则将这个高维向量转换成目标序列。训练时,模型会接受一对输入序列,通过编码器-解码器结构对其进行处理,并尝试将目标序列与模型生成序列之间的差异最小化。其使 Transformer 模型能很好地处理各种序列任务。

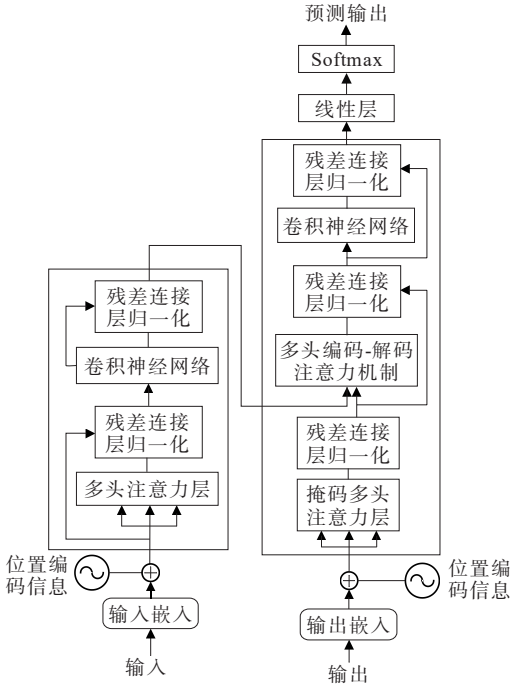

图 1 Transformer 块的基本架构

Figure 1 Basic architecture of Transformer block

此外,TimeGPT 还包括位置编码(positional encoding, PE)、多头注意力(multi-head attention)与 CNN。其中,残差连接(residual connections)和层归一化(layer normalization)的集成使模型训练更稳定和快速,防止梯度退化并加速算法收敛[21]。

1.2 位置编码

为使模型能准确理解输入特征中的顺序信息,函数 $P_{\mathrm{E}}(p,n)$ 的作用是通过正、余弦位置编码为每个特征分配位置信息,即

$$P_{\mathrm{E}}(p,n)=\begin{cases}\sin\left(\dfrac{p}{10\,000^{2i/d_{\mathrm{model}}}}\right), & n=2i\\ \cos\left(\dfrac{p}{10\,000^{2i/d_{\mathrm{model}}}}\right), & n=2i+1\end{cases}\tag{1}$$

式中,p 为输入序列的长度;i 为位置的维度索引;d_{model} 表示特征的长度。

在 $P_{\mathrm{E}}(p,n)$ 中,偶数项由正弦函数控制,而奇数项则由余弦函数控制,$P_{\mathrm{E}}(p,n)$ 值会随着位置

p 的增加而变化。有了 $P_{\mathrm{E}}(p,n)$，模型就能区分不同位置的特征，从而更好地理解输入序列中的顺序信息。

1.3　多头注意力机制

作为 Transformer 架构的核心单元，多头注意力可被看作是多个注意力头的整合，其基本结构如图 2 所示。在图 2 中，通过并行进行 h 次注意力计算，Transformer 可以扩展其对不同特征的关注能力[23]。该模型可先同时学习多组注意力权重，再将它们的输出进行拼接。假设有 j 个注意力头，则多头注意力 $\boldsymbol{f}_{\mathrm{MH}}$ 的计算式为

$$\boldsymbol{f}_{\mathrm{MH}}=C(\boldsymbol{h}_1,\boldsymbol{h}_2,\cdots,\boldsymbol{h}_j)\boldsymbol{W}_{\mathrm{O}} \tag{2}$$

$$\boldsymbol{h}_i=A(\boldsymbol{Q}_i,\boldsymbol{K}_i,\boldsymbol{V}_i) \tag{3}$$

$$A(\boldsymbol{Q}_i,\boldsymbol{K}_i,\boldsymbol{V}_i)=\mathrm{softmax}\left(\frac{1}{\sqrt{d}}\boldsymbol{Q}_i\boldsymbol{K}_i^{\mathrm{T}}\right)\boldsymbol{V}_i \tag{4}$$

$$\begin{cases}\boldsymbol{Q}_i=\boldsymbol{W}_Q\boldsymbol{X}\\ \boldsymbol{K}_i=\boldsymbol{W}_K\boldsymbol{X}\\ \boldsymbol{V}_i=\boldsymbol{W}_V\boldsymbol{X}\end{cases} \tag{5}$$

式(2)～(5)中，$C(\boldsymbol{h}_1,\boldsymbol{h}_2,\cdots,\boldsymbol{h}_j)$ 为多个注意力头的拼接；$A(\boldsymbol{Q}_i,\boldsymbol{K}_i,\boldsymbol{V}_i)$ 为第 i 个注意力函数；$\boldsymbol{X}$ 为输入矩阵；$\boldsymbol{W}_Q$、$\boldsymbol{W}_K$ 和 $\boldsymbol{W}_V$ 分别为线性变换 Q、K、V 的权重矩阵；$\boldsymbol{Q}_i$、$\boldsymbol{K}_i$ 和 $\boldsymbol{V}_i$ 分别为第 i 个查询矩阵、键矩阵和值矩阵；$\boldsymbol{W}_{\mathrm{O}}$ 为输出变换矩阵；d 为查询矩阵的维度。

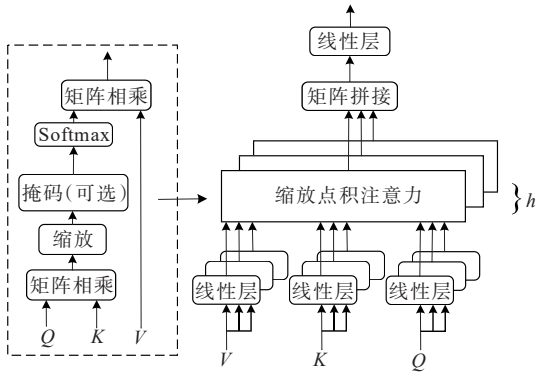

图 2　多头注意力机制的基本结构

Figure 2　Basic structure of multi-head attention mechanism

1.4　卷积神经网络

在编码器和解码器中，每个位置都会应用一个 CNN 来捕捉其潜在特征。CNN 由卷积层和池化层组成，其计算式分别为

$$\boldsymbol{X}_{\mathrm{conv,out}}=\sigma(\boldsymbol{W}_{\mathrm{conv}}*\boldsymbol{X}_{\mathrm{conv,in}}+\boldsymbol{B}_{\mathrm{conv}}) \tag{6}$$

$$\boldsymbol{X}_{\mathrm{pool,out}}=\max_{j,k\in R}\left(X_{\mathrm{pool,in}}^{j,k}\right) \tag{7}$$

式(6)、(7)中，$\boldsymbol{X}_{\mathrm{conv,out}}$ 和 $\boldsymbol{X}_{\mathrm{pool,out}}$ 分别为卷积层和池化层的输出向量；$\boldsymbol{X}_{\mathrm{conv,in}}$ 和 $\boldsymbol{X}_{\mathrm{pool,in}}$ 分别为卷积层和池化层的输入向量；σ 为激活函数；$\boldsymbol{W}_{\mathrm{conv}}$ 和 $\boldsymbol{B}_{\mathrm{conv}}$ 分别为卷积层的权重和偏置向量；$X_{\mathrm{pool,in}}^{j,k}$ 为 $\boldsymbol{X}_{\mathrm{pool,out}}$ 第 j 行，k 列的元素；R 为池化范围；$*$ 为卷积计算符号。

1.5　残差连接与层归一化

为加快模型训练的收敛速度，通常会使用层归一化来对各层的输出进行归一化，即

$$L(\boldsymbol{X}_{\mathrm{SL}})=\gamma\frac{\boldsymbol{X}_{\mathrm{SL}}-\bar{\boldsymbol{X}}_{\mathrm{SL}}}{\sqrt{\sigma_X^2+\varepsilon}}+\beta \tag{8}$$

式中，$L(\boldsymbol{X}_{\mathrm{SL}})$ 为层归一化函数；$\boldsymbol{X}_{\mathrm{SL}}$ 为子层的输出向量；$\bar{\boldsymbol{X}}_{\mathrm{SL}}$ 和 σ_X 分别为 $\boldsymbol{X}_{\mathrm{SL}}$ 输出的平均值和标准偏差；γ 和 β 分别为可学习的比例参数和偏移参数；ε 为一个小正数，以避免除以零错误的发生。

在训练深度网络时，为缓解梯度消失问题，每个子层都使用了残差连接，即

$$\boldsymbol{X}_{F,\mathrm{out}}=J(\boldsymbol{X}_{F,\mathrm{in}})+\boldsymbol{X}_{F,\mathrm{in}} \tag{9}$$

式中，$\boldsymbol{X}_{F,\mathrm{out}}$ 和 $\boldsymbol{X}_{F,\mathrm{in}}$ 分别为子层 F 的输出和输入向量；J 为连接函数。

1.6　TimeGPT 的训练和使用

TimeGPT 在大量公开数据集上进行了训练，TimeGPT 的训练和使用如图 3 所示。这些数据集包含 1 000 亿个数据点，如经济交通、银行、网络流量、天气、能源、医疗保健等[21]。在时间特征方面，这些训练数据包括不同季节性、不同持续时间周期和不同趋势类型的各种数据集。除时间特征外，数据集还包含异常值和各种噪声水平，一些数据集呈有序、可预测的模式，而另一些数据集则呈明显的噪声峰值或突发事件模式。丰富多样的数据可让模型更好地适应真实世界中的复杂情况，提供一个稳健的训练环境。

关于 TimeGPT 是否进行微调，本文将考虑 2 种情况：零样本学习和少样本学习。

零样本学习是指将历史光伏功率数据输入到 TimeGPT，在不调整 TimeGPT 参数的情况下预测光伏功率。少样本学习则是在进行光伏功率预测之前，利用稀缺的历史光伏功率数据对 TimeGPT 的权重进行微调，这种方式能使模型适应时间序列数据之间的差别并提高光伏功率预测的准确性。

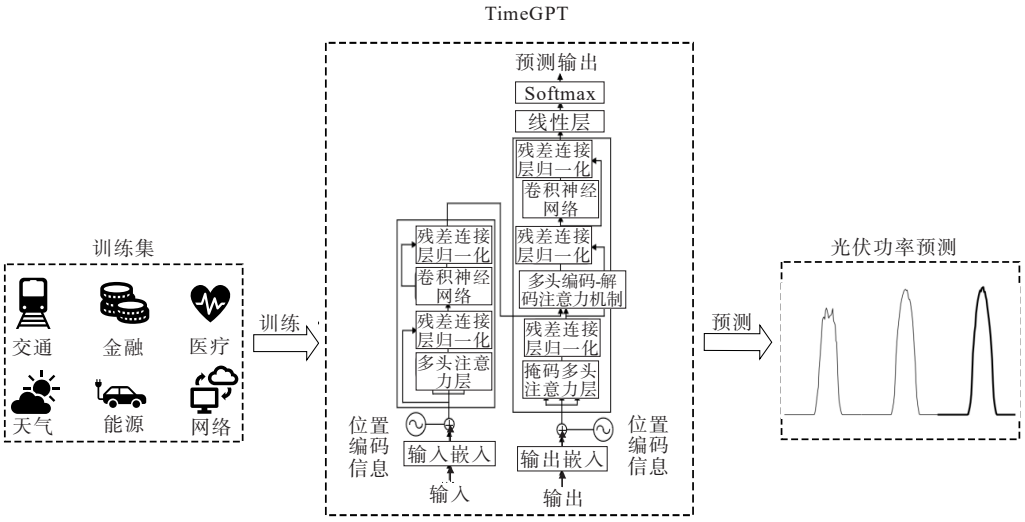

图 3 TimeGPT 的训练和使用

Figure 3 Training and use of TimeGPT

2 仿真设置

本文将在真实数据集下进行仿真和探讨，深入分析 TimeGPT 的性能。

2.1 模型设置

TimeGPT 是在大量公开的时间序列数据集上进行训练的。如果使用目前公开的光伏功率数据集进行仿真，这些数据集可能已被用于 TimeGPT 的参数化。一旦学习到了这些数据集的特征，就无法体现模型的泛化能力。为此，本文工作选取的数据集为中国北京市某地区的私密光伏发电功率数据，确保了 TimeGPT 的预训练参数与该数据集无关。利用3个月的光伏功率数据进行仿真测试，时间跨度为2022年5月6日至2022年8月6日，时间步长为1 h，各个数据集的描述见表1。由于 TimeGPT 是基于1 000亿数据点的大规模和多样化时间序列数据集进行预训练的，只需要少量光伏数据对其进行微调。因此，对基准模型而言，6～10 d 的训练数据属于“数据稀缺”的范畴；15～30 d 的训练数据属于“数据丰富”的情况。为测试 TimeGPT 在不同训练样本数量的数据集上的模型性能，将原始数据集分为案例1～5共5种情况，从案例1到案例5，训练样本的数量逐渐增加。

表 1 各个数据集的描述

Table 1 Description of each dataset

案例	样本集日期	测试集日期
1	5月6日—5月12日	5月13日—8月6日
2	5月6日—5月14日	5月17日—8月6日
3	5月6日—5月16日	5月19日—8月6日
4	5月6日—5月21日	5月22日—8月6日
5	5月6日—6月5日	6月6日—8月6日

2.2 基准模型

为全面评估 TimeGPT 的性能，将其与流行的机器学习模型和统计模型（LR、XGBoost、MLP 和 LSTM）进行比较。对于每个模型，输入仅包括历史光伏功率数据和时间（如过去 24 h 的数据），而输出则为未来光伏功率。具体方法为滚动窗口法，其基本思想是根据历史数据和模型，在每个时间点 t，利用过去的 $[t-h,t]$ 的数据作为训练集，预测未来时间点 $[t,t+a]$ 的数据。滚动窗口法预测能充分利用历史数据来训练模型，且可实时更新模型以适应变化的时间序列模式。其对一些具有季节性或周期性波动的时间序列有较好的适用性和准确性。本文工作仅考虑历史光伏功率数据的单变量时间序列预测，忽略气象条件等其他信息。

2.3 评估指标

为避免偶然性或巧合，每个模型运行30次以获得平均预测结果。利用广泛使用的预测衡量指标对模型性能进行评估，包括平均绝对误差（mean absolute error，MAE）、均方根误差（root mean square error，RMSE）和平均绝对百分比误差（mean absolute percentage error，MAPE）：

$$I_{\mathrm{MAE}}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-\hat{y}_i\right| \tag{10}$$

$$I_{\mathrm{RMSE}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2} \tag{11}$$

$$I_{\mathrm{MAPE}}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i-\hat{y}_i}{y_i}\right| \tag{12}$$

式(10)～(12)中，I_{MAE}、I_{RMSE}与I_{MAPE}分别为平均绝对误差、均方根误差与平均绝对百分比误差；n为样本数量；y_i为第i时刻的光伏功率真实值；$\hat{y}_i$为第i时刻的光伏功率预测值。

2.4　仿真设置

为研究 TimeGPT 在光伏功率预测中的潜力，本文将从以下 3 个角度进行仿真：

1）讨论 TimeGPT 在光伏功率预测中的模型性能，包括使用微调和不使用微调的情况，即零样本学习和少样本学习。

2）在历史数据稀缺的情况下，比较 TimeGPT 与基准模型在同一数据集下的预测性能。

3）在历史数据丰富的情况下，比较 TimeGPT 与基准模型在同一数据集下的预测性能。

本文设置的基准模型包括 LR、XGBoost、MLP 和 LSTM，其中 MLP 含 3 个 Dense 层（16 单元、16 单元、1 单元），训练轮次为 200，批量大小为 8，优化器为 Adam；LSTM 含 2 个 LSTM 层（16 单元、8 单元）和 2 个 Dense 层（8 单元、1 单元），学习率为 0.01，输入层与中间层激活函数为 ReLU，输出层为 Sigmoid 函数；LR 的截距参与计算；XGBoost 的最大深度为 4，叶子节点数为 25，学习率为 0.01，估计器数为 500，最小子样本数为 90，子样本比例为 0.8，早停为 400，损失函数为平方损失。

3　仿真分析

3.1　零样本和少样本微调下 TimeGPT 的性能分析

为评估 TimeGPT 在光伏功率预测中的性能，本文在案例 1 中分析了零样本学习和少样本学习（即微调前和微调后）的 TimeGPT 预测性能对比，从而直观地看出微调在光伏预测中的作用。其中，预测时间步长范围为 1～24 h，不同预测时间步长下平均绝对误差、均方根误差与绝对百分比误差的对比分别如图 4～6 所示。

虽然 TimeGPT 是在由 1 000 亿个数据点组成的多样化数据集上训练出来的，但在微调之前，其在 RMSE、MAE 和 MAPE 指标上的表现都较差。这表明该算法不能直接泛化到光伏功率预测中。这是训练数据无法充分表征与光伏功率预测相关的特定数据与模型分布与模式的泛化能力有限导致的。经过历史光伏数据微调后，TimeGPT 在光伏功率预测方面的性能有了显著提高，各种指标都有明显好转。这是微调对模型权重进行了调整，模型更好地适应与预测相关的数据分布、模式和特征所导致的。因此，微调可以显著提高 TimeGPT 的性能，使其在实际预测中更准确。

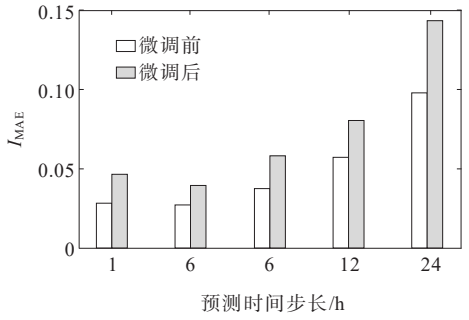

图 4　不同预测时间步长下平均绝对误差对比

Figure 4　Comparison of MAEs under different forecasting time steps

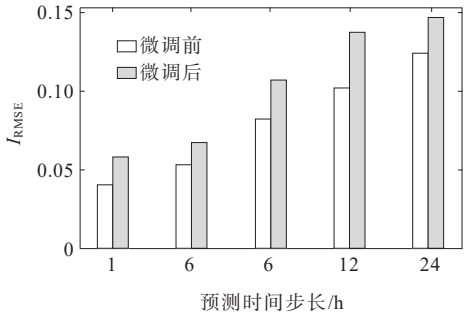

图 5　不同预测时间步长下均方根误差对比

Figure 5　Comparison of root mean square errors under different forecasting time steps

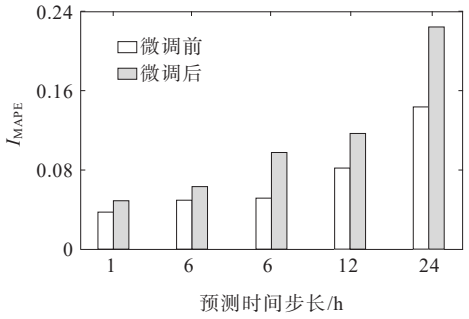

图 6　不同预测时间步长下平均绝对百分比误差对比

Figure 6　Comparison of root mean square errors under different forecasting time steps

3.2　数据稀缺情况下的性能比较

为比较 TimeGPT 与基准模型在数据稀缺情况下的性能，在案例 1～3 中分别使用这些模型进行光伏功率预测（训练集中的数据时间范围为 6～10 d）。案例 1～3 的不同预测模型在光伏功率数据稀缺下的预测评估结果依次见表 2～4。

在历史数据稀缺的情况下，与其他常用的机器学习和统计模型相比，TimeGPT 在预测时间步长范围为数小时（如 1～6 h）的光伏功率预测具有显著优势。例如，在预测时间步长为 1 h 的案例 1 中，TimeGPT 的 MAE 分别比 MLP、LSTM、LR、XGBoost 的降低了 18.2%、62.1%、33.3%、30.7%。

TimeGPT 在海量和多样化时间序列数据集的预训练后，具备了一定程度的泛化能力。即使在数据稀缺的情况下，其也能利用这些丰富数据的预训练模型，在功率预测方面表现出色。相比之下，传统的机器学习模型由于训练数据不足，很难捕捉光伏功率数据中的复杂模式，导致其预测准确率较低。

然而，日前功率预测（预测时间步长范围为 12～24 h）涉及较长的时间依赖性，超出 TimeGPT 在预训练期间所学习的范围。因此，与基准模型相比，其预测性能相对较差。

表 2 案例 1 的不同预测模型在光伏功率数据稀缺下的预测评估结果

Table 2 Forecasting evaluation results of different forecasting models with scarce PV power data in case 1 %

模型	预测时间步长为 1 h			预测时间步长为 4 h			预测时间步长为 6 h			预测时间步长为 12 h			预测时间步长为 24 h		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
TimeGPT	0.039	0.036	0.031	0.053	0.034	0.046	0.063	0.035	0.052	0.072	0.049	0.086	0.125	0.097	0.172
MLP	0.056	0.044	0.075	0.088	0.040	0.091	0.081	0.037	0.094	0.085	0.055	0.123	0.089	0.049	0.119
LSTM	0.072	0.095	0.091	0.083	0.049	0.098	0.187	0.058	0.092	0.199	0.076	0.121	0.245	0.093	0.147
LR	0.084	0.054	0.044	0.157	0.081	0.058	0.164	0.094	0.094	0.171	0.147	0.117	0.278	0.149	0.298
XGBoost	0.071	0.052	0.050	0.076	0.055	0.073	0.072	0.047	0.069	0.080	0.049	0.119	0.087	0.038	0.112

表 3 案例 2 的不同预测模型在光伏功率数据稀缺下的预测评估结果

Table 3 Forecasting evaluation results of different forecasting models with scarce PV power data in case 2 %

模型	预测时间步长为 1 h			预测时间步长为 4 h			预测时间步长为 6 h			预测时间步长为 12 h			预测时间步长为 24 h		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
TimeGPT	0.041	0.022	0.035	0.067	0.029	0.068	0.083	0.068	0.076	0.169	0.118	0.119	0.229	0.160	0.176
MLP	0.093	0.037	0.056	0.103	0.056	0.132	0.124	0.072	0.193	0.150	0.073	0.174	0.178	0.076	0.185
LSTM	0.098	0.088	0.103	0.098	0.091	0.118	0.106	0.098	0.152	0.113	0.125	0.161	0.119	0.136	0.170
LR	0.096	0.066	0.079	0.120	0.083	0.093	0.169	0.097	0.131	0.172	0.161	0.109	0.278	0.149	0.241
XGBoost	0.083	0.057	0.044	0.071	0.051	0.056	0.088	0.075	0.079	0.073	0.083	0.082	0.074	0.097	0.126

表 4 案例 3 的不同预测模型在光伏功率数据稀缺下的预测评估结果

Table 4 Forecasting evaluation results of different forecasting models with scarce PV power data in case 3 %

模型	预测时间步长为 1 h			预测时间步长为 4 h			预测时间步长为 6 h			预测时间步长为 12 h			预测时间步长为 24 h		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
TimeGPT	0.054	0.027	0.033	0.075	0.071	0.072	0.163	0.144	0.115	0.146	0.116	0.136	0.172	0.158	0.178
MLP	0.112	0.049	0.047	0.108	0.075	0.088	0.120	0.086	0.095	0.132	0.092	0.117	0.145	0.124	0.146
LSTM	0.087	0.085	0.061	0.089	0.092	0.138	0.093	0.099	0.142	0.108	0.111	0.156	0.120	0.096	0.172
LR	0.075	0.075	0.083	0.079	0.089	0.081	0.083	0.094	0.102	0.127	0.129	0.118	0.179	0.185	0.141
XGBoost	0.077	0.067	0.070	0.076	0.073	0.093	0.079	0.077	0.098	0.085	0.073	0.083	0.087	0.076	0.132

3.3 数据丰富情况下的性能比较

为比较 TimeGPT 与基准模型在训练数据相对丰富数据情况下的性能，在案例 4～5 中分别使用 TimeGPT 与基准模型进行光伏功率预测。这里的 TimeGPT 是根据历史光伏功率数据进行微调的。案例 4、5 的不同预测模型在光伏功率数据稀缺下的预测评估结果依次见表 5、6。

由表 5、6 可知，尽管利用历史数据对 TimeGPT 进行了微调，但在历史数据相对丰富的情况下，TimeGPT 在光伏功率预测方面的表现明显不如其他机器学习模型的。这可能是由于训练数据集和验证功率数据在分布和特征上不匹配。如果有足够的数据来训练机器学习模型，就可以为机器学习模型提供更多信息，使机器学习模型更准确地捕捉

表 5　案例 4 的不同预测模型在光伏功率数据丰富下的预测评估结果

Table 5　Forecasting evaluation results of different forecasting models with abundant PV power data in case 4　%

模型	预测时间步长为 1 h			预测时间步长为 4 h			预测时间步长为 6 h			预测时间步长为 12 h			预测时间步长为 24 h		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
TimeGPT	0.071	0.056	0.052	0.081	0.072	0.075	0.089	0.100	0.102	0.145	0.142	0.151	0.171	0.168	0.164
MLP	0.112	0.060	0.045	0.109	0.055	0.068	0.104	0.053	0.079	0.119	0.052	0.088	0.125	0.077	0.095
LSTM	0.037	0.029	0.049	0.046	0.038	0.075	0.059	0.051	0.080	0.052	0.042	0.083	0.067	0.052	0.085
LR	0.073	0.051	0.046	0.068	0.047	0.089	0.066	0.046	0.108	0.068	0.049	0.117	0.073	0.052	0.121
XGBoost	0.057	0.043	0.037	0.067	0.038	0.108	0.064	0.034	0.116	0.079	0.043	0.098	0.080	0.068	0.119

表 6　案例 5 的不同预测模型在光伏功率数据丰富下的预测评估结果

Table 6　Forecasting evaluation results of different forecasting models with abundant PV power data in case 5　%

Model	预测时间步长为 1 h			预测时间步长为 4 h			预测时间步长为 6 h			预测时间步长为 12 h			预测时间步长为 24 h		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
TimeGPT	0.075	0.044	0.046	0.118	0.061	0.065	0.143	0.081	0.099	0.194	0.130	0.137	0.242	0.181	0.189
MLP	0.098	0.047	0.056	0.085	0.038	0.132	0.083	0.039	0.193	0.094	0.048	0.174	0.114	0.049	0.186
LSTM	0.046	0.023	0.026	0.053	0.027	0.047	0.056	0.032	0.059	0.059	0.039	0.061	0.060	0.048	0.073
LR	0.071	0.040	0.046	0.081	0.054	0.073	0.087	0.057	0.091	0.087	0.059	0.096	0.090	0.065	0.113
XGBoost	0.067	0.032	0.031	0.072	0.035	0.054	0.069	0.035	0.066	0.070	0.039	0.068	0.072	0.042	0.078

数据的模式和趋势，产生良好泛化能力的预测结果。在这种情况下，选择经典机器学习模型比 TimeGPT 更为可取。

在预测时间步长为 1 h 的案例 1 中，TimeGPT 的 MAE 比 MLP、LSTM、LR、XGBoost 和 PM 的分别降低了 18.2%、62.1%、33.3%、30.7% 和 42.9%。评估结果表明，尽管 TimeGPT 在短预测时间步下表现较基准模型更出色，但其在较长预测时间步预测效果并不如基准模型的。为探讨 TimeGPT 在较长预测时间步长（12 h 和 24 h）下无法有效地进行光伏功率预测的原因，本文选择案例 5 进行分析，时间步长为 12 h 与 24 h 的功率对比分别如图 7、8 所示。

从图 7、8 中可以看出，长预测时间步长的功率

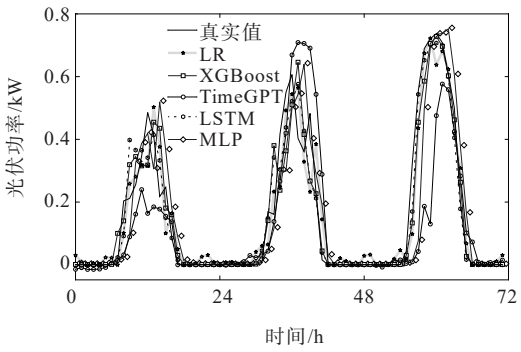

图 7　时间步长为 12 h 功率预测对比

Figure 7　Comparison of power forecasting with a time step of 12 hours

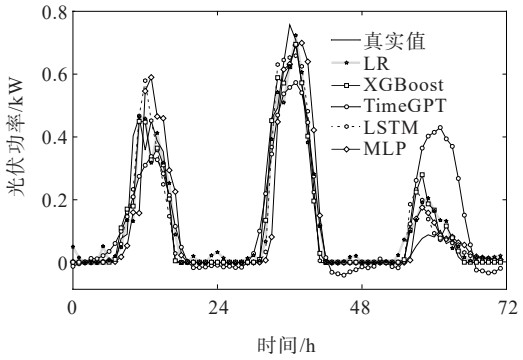

图 8　时间步长为 24 h 功率预测对比

Figure 8　Comparison of power forecasting with a time step of 24 hours

预测的情况。本文选用了 30 d 的光伏功率数据，并在较长的预测时间步下（12 h 和 24 h）进行光伏功率预测。TimeGPT 生成的预测曲线具有保守和平滑的特征。这种特征使 TimeGPT 难以捕捉光伏功率的峰值；另外，光伏的发电功率受气象因素的影响，其功率并不稳定，如在阴天，由于太阳辐射度较低，日功率曲线存在波动。在没有考虑气象相关影响因素情况下，TimeGPT 保守平滑的预测模式是其在较长的预测时间步下（12 h 和 24 h）功率预测准确率较低的原因。

4　TimeGPT 的应用与展望

新能源的预测对于系统运营和能源调度至关

重要。新型电力系统往往具有更高的新能源比例,包括分布式光伏、风电、电动汽车充电桩等。其资源的管理和调度需要高效的预测模型来支持决策。在推动系统友好型“新能源+储能”电站建设中,应深度融合新能源功率预测、智慧调控、新型储能等技术,系统友好型“新能源+储能”电站建设如图9所示。

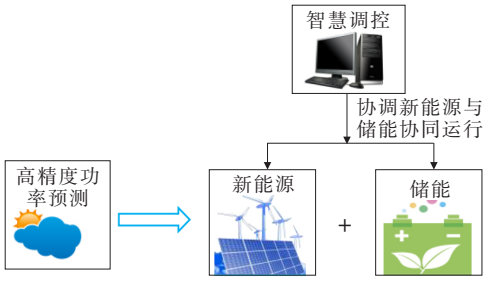

图9 系统友好型“新能源+储能”电站建设

Figure 9 Construction of system-friendly “new energy + energy storage” power stations

面对历史数据稀缺甚至极端场景下新能源功率预测的问题时,现有的机器学习模型无法进行高效预测。TimeGPT在稀缺历史数据条件下的短期预测优异性能,能够显著提升新能源出力预测准确性与可靠性,进而有效优化电力系统的运行调度与提高管理效率,增强系统的灵活性与经济性,并为极端场景下的新能源出力预测提供有力支撑。因此,在新型电力系统中,TimeGPT的应用展现出广阔的前景与巨大的发展潜力。

综上所述,TimeGPT可以为新型电力系统的运行和管理提供重要支持,其应用前景不限于光伏出力预测,还包括能源调度、智能决策等多个方面,将为电力行业的发展带来巨大的价值和机遇。然而,它也存在局限性:TimeGPT模型属于通用性的大模型,但预训练数据与功率数据在数据分布上的差异性限制了光伏功率预测的准确性。需要海量的光伏发电数据进行深度训练,构建适用于新能源功率预测的定制化大模型。

在实际应用中,可以采用以下策略来确定是否使用TimeGPT进行历史数据稀缺的光伏功率短期预测。首先,将历史数据分为训练集和验证集。其次,训练集用于微调TimeGPT的权重,而验证集用于测试TimeGPT和基准的性能。如果TimeGPT在验证集上的表现优于基准模型的,那么TimeGPT将成为利用稀缺历史数据进行光伏功率预测的最佳选择。

5 结语

受大语言模型在计算机视觉和自然语言处理中出色表现的启发,本文挖掘时间序列大模型TimeGPT在历史数据稀缺的光伏功率短期预测的潜力。通过对数据集的模拟和分析,得出以下结论:

1) TimeGPT是由1 000亿个数据点组成的海量、多样化数据集上预训练,但在微调之前,它不能直接用于功率预测,应经过模型微调以后使用。微调可以提高TimeGPT在特定数据集上对局部数据的适应度,使其在实际应用中更加准确。

2) TimeGPT在历史训练数据稀缺的场景下,其光伏功率预测性能优于基准模型的,特别是在较短的预测时间步长下,其预测性能会更好。

3) 在历史训练数据丰富的情况下,经过特定训练的传统统计与机器学习模型预测误差比TimeGPT预测误差更低,预测效果更好。

在TimeGPT的实际应用中,先通过将历史数据分为训练集和验证集,再使用验证集损失来决定TimeGPT是否是特定数据集的最佳模型选择。

本文在依赖单一的光伏输出功率数据作为参考训练TimeGPT时,忽略了光照强度、温度、光伏板清洁度等影响光伏出力的其他参数的影响。仅使用TimeGPT作为单变量预测模型时,针对其平滑保守的特性难以捕捉峰值以及在较长时间步长(如12 h、24 h)预测精度较低的问题,后续工作会继续考虑补充额外的气象数据(如温度,辐照度,功率波动特征)作为模型的输入特征,建立多变量时间预测模型提高预测精准度与实用价值。

参考文献:

[1] BERMUDEZ-GARCIA A, VOARINO P, RACCURT O. Environments, needs and opportunities for future space photovoltaic power generation: a review[J]. Applied Energy,2021,290:116757.

[2] 钱乙卫,田浩,刘财华,等.考虑概率分布的分布式光伏无功下垂控制策略[J].发电技术,2024,45(2):273-281.
QIAN Yiwei,TIAN Hao,LIU Caihua,et al.Droop control strategy of distributed photovoltaic reactive power considering probability distribution[J].Power Generation Technology,2024,45(2):273-281.

[3] ETXEGARAI G, LÓPEZ A, AGINAKO N, et al. An analysis of different deep learning neural networks for intra-hour solar irradiation forecasting to compute solar photovoltaic generators' energy production[J].Energy for Sustainable Development,2022,68:1-17.

[4] 张强,吴芷晗,张逸.基于改进相似时刻法的分布式光伏功率短期预测方法[J].供用电,2023,40(9):65-73.
ZHANG Qiang, WU Zhihan, ZHANG Yi. Short-term prediction of distributed PV power based on improved similar period method[J].Distribution & Utilization,2023,40(9):65-73.

[5] WANG C X,ZHOU Y Z,WEN Q S,et al.Improving load forecasting performance via sample reweighting[J].IEEE Transactions on Smart Grid,2023,14(4):3317-3320.

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

[7] 杨峻,彭乔,蔡永翔,等.考虑最大功率点估计模型校准的光伏功率备用控制[J].电力工程技术,2024,43(6):12-20+52.
YANG Jun, PENG Qiao, CAI Yongxiang, et al. Power reserve control of photovoltaic system considering parameter correction in maximum power point estimation[J]. Electric Power Engineering Technology, 2024,43(6):12-20+52.

[8] 黄元生,田立霞,孙仕泽,等.基于改进支持向量机的轨道交通光伏发电预测[J].河北大学学报(自然科学版),2021,41(3):238-244.
HUANG Yuansheng, TIAN Lixia, SUN Shize, et al. Photovoltaic power generation prediction of rail transit based on improved support vector machine[J].Journal of Hebei University (Natural Science Edition), 2021, 41(3): 238-244.

[9] 叶清泉,倪佳华,吴旭光,等.直流网光伏系统多时间尺度调度算法[J].电力建设,2024,45(1):125-137.
YE Qingquan, NI Jiahua, WU Xuguang, et al. Multi-timescale dispatching algorithm of PV systems in DC grid[J]. Electric Power Construction, 2024, 45(1): 125-137.

[10] 赫卫国,郝向军,郭雅娟,等.基于 ARIMA 和 SVR 的光伏电站超短期功率预测[J].广东电力,2017,30(8):32-37.
HE Weiguo, HAO Xiangjun, GUO Yajuan, et al. Ultra-short term power forecast based on ARIMA and SVR for photovoltaic power station[J].Guangdong Electric Power, 2017,30(8):32-37.

[11] 李燕斌,张久菊,肖俊明.灰色-马尔可夫链统计组合模型在光伏发电功率短期预测中的应用[J].电测与仪表,2015,52(23):111-116.
LI Yanbin, ZHANG Jiuju, XIAO Junming. Photovoltaic power short-term forecasting based on Gray-Markov chain statistical combination model[J]. Electrical Measurement & Instrumentation,2015,52(23):111-116.

[12] ZHANG X Y,KUENZEL S,COLOMBO N,et al.Hybrid short-term load forecasting method based on empirical wavelet transform and bidirectional long short-term memory neural networks[J]. Journal of Modern Power Systems and Clean Energy,2022,10(5):1216-1228.

[13] 邹港,赵斌,罗强,等.基于 PCA-VMD-MVO-SVM 的短期光伏输出功率预测方法[J].电力科学与技术学报,2024,39(5):163-171.
ZOU Gang, ZHAO Bin, LUO Qiang, et al. Prediction method of short-term PV output power based on PCA-VMD-MVO-SVM[J]. Journal of Electric Power Science and Technology,2024,39(5):163-171.

[14] 王海军,居蓉蓉,董颖华.基于时空关联特征与 B-LSTM 模型的分布式光伏功率区间预测[J].中国电力,2024,57(7):74-80.
WANG Haijun, JU Rongrong, DONG Yinghua. Distributed photovoltaic power interval prediction based on spatio-temporal correlation feature and B-LSTM model[J].Electric Power,2024,57(7):74-80.

[15] 王东风,刘婧,黄宇,等.结合太阳辐射量计算与 CNN-LSTM 组合的光伏功率预测方法研究[J].太阳能学报,2024,45(2):443-450.
WANG Dongfeng, LIU Jing, HUANG Yu, et al. Photovoltaic power prediction method combinating solar radiation calculation and cnn-lstm[J]. Acta Energiae Solaris Sinica,2024,45(2):443-450.

[16] 李晶晶,黄翔庚,张媛媛,等.基于 LightGBM-TextCNN-XGBoost 的超短期光伏功率预测研究[J].电力大数据,2023,26(10):26-33.
LI Jingjing,HUANG Xianggeng,ZHANG Yuanyuan,et al. Ultra-short-term photovoltaic power prediction research based on LightGBM-TextCNN-XGBoost algorithm[J]. Power Systems and Big Data,2023,26(10):26-33.

[17] 史加荣,殷诏.基于 GRU-BLS 的超短期光伏发电功率预测[J].智慧电力,2023,51(9):38-45.
SHI Jiarong, YIN Zhao. Prediction of ultra short term photovoltaic power generation based on GRU-BLS[J]. Smart Power,2023,51(9):38-45.

[18] 岳有军,吴明沅,王红君,等.基于 CNN-GRU-ISSA-XGBoost 的短期光伏功率预测[J].南京信息工程大学学报,2024,16(2):231-238.
YUE Youjun,WU Mingyuan,WANG Hongjun,et al.Short

term photovoltaic power prediction based on CNN-GRU-ISSA-XGBoost[J]. Journal of Nanjing University of Information Science & Technology,2024,16(2):231-238.

[19] 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·Yaermaimaiti, 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.

[20] 董志强,郑凌蔚,苏然,等.一种基于IGWO-SNN的光伏出力短期预测方法[J].电力系统保护与控制,2023,51(1):131-138.
DONG Zhiqiang, ZHENG Lingwei, SU Ran, et al. An IGWO-SNN-based method for short-term forecast of photovoltaic output[J]. Power System Protection and Control,2023,51(1):131-138.

[21] 商立群,李洪波,侯亚东,等.基于VMD-ISSA-KELM的短期光伏发电功率预测[J].电力系统保护与控制,2022,50(21):138-148.
SHANG Liqun, LI Hongbo, HOU Yadong, et al. Short-term photovoltaic power generation prediction based on VMD-ISSA-KELM[J]. Power System Protection and Control,2022,50(21):138-148.

[22] ZHANG Z Y,ZHAO P F,WANG P,et al.Transfer learning featured short-term combining forecasting model for residential loads with small sample sets[J]. IEEE Transactions on Industry Applications,2022,58(4):4279-4288.

[23] 陈习勋,吴凯彤,何杰,等.基于集成机器学习模型的短期光伏出力区间预测[J].智慧电力,2024,52(2):87-93+107.
CHEN Xixun, WU Kaitong, HE Jie, et al. Short term photovoltaic output interval prediction based on integrated machine learning model[J].Smart Power,2024,52(2):87-93+107.

[24] BROWN M, MANN B, RYDER N. et al. Language models are few-shot learner[C]//Advances in Neural Information Processing Systems, Dec 6 – 12, 2020, Vancouver Canada.New York:Red Hook,2020,159,1877-1901.

[25] TOUVRON H, LAVRIL T, IZACARD G. et al. LLaMA: open and efficient foundation language models[EB/OL] (2023-02-27) [2024-07-10]. https://doi. org/ 10.48550/arXiv.2302.13971.

[26] ZHANG Y B, LIU C L. Unlocking the potential of artificial intelligence in fashion design and E-commerce applications: the case of midjourney[J]. Journal of Theoretical and Applied Electronic Commerce Research, 2024,19(1):654-670.

[27] YU H K, LIU X Y, TIAN Y L, et al. Sora-based parallel vision for smart sensing of intelligent vehicles: from foundation models to foundation intelligence[J]. IEEE Transactions on Intelligent Vehicles, 2024, 9(2): 3123-3126.

[28] GARZA A and MERGENTHALER-CANSECO M. TimeGPT-1[EB/OL]. (2023-10-05) [2024-07-10]. https://doi.org/10.48550/arXiv.

[29] LIAO W L, WANG S X, YANG D C, et al. TimeGPT in load forecasting:a large time series model perspective[J]. Applied Energy,2025,379:124973.